

مقارنة الشبكات العصبية ذات الذاكرة قصيرة المدى المطولة ونماذج بوكس وجينكنز
بالتطبيق على سلسلة الوفيات اليومية الناتجة عن الإصابة بفيروس كورونا بمصر

د. حنان خضارى مهدى محمود*

(*). د. حنان خضارى مهدى محمود : مدرس الاحصاء التطبيقي بمعهد النيل العالي للعلوم التجارية
وتكنولوجيا الحاسب بالمنصورة وتتمثل الاهتمامات البحثية في التحليل الاحصائي باستخدام العديد من البرامج
الإحصائية SPSS، Eviews، Stata، Warp pls، Smart pls، واهتمت مؤخرًا ببرامج تعلم الآلة والتعلم
العميق Weka، Orange

Email : : hanankhdary@gmail.com

المُلخَص

لقد بات من المؤكد أن انتشار فيروس كورونا ومتحور كورونا الجديد (أوميكرون) يفوق كل القدرات المعروفة للدول، وأصبح العالم في ظل الجائحة يواجه مختلف الأزمات، وعلى رأسها الأزمة الصحية العالمية المتمثلة في ارتفاع معدلات الوفيات التي تهدد أسس المجتمعات الاجتماعية والاقتصادية على المستوى العالمي في وقت واحد، لذلك أُجريت العديد من الدراسات التي تحاول البحث عن اساليب تستخدم في التنبؤ بالوفيات الناتجة عن الإصابة بفيروس كورونا وقد تم في هذا البحث مقارنة أداء نموذج الشبكات العصبية ذات الذاكرة قصيرة المدى المطولة (LSTM-Long Short Term Memory) مع نماذج بوكس وجينكنز (ARIMA Auto Regressive. Integrated Moving Average) في التنبؤ بالوفيات الناتجة عن الإصابة بفيروس كورونا في مصر، وتم تجربة كل نموذج للتنبؤ بثلاث ايام جديدة. ومن خلال تطبيق النماذج وُجِدَ أنَّ الشبكات العصبية ذات الذاكرة قصيرة المدى تتفوق على النماذج بدرجة ملحوظة. حيث لا يلزمها افتراض نماذج مسبقة لتمثيل البيانات أو العلاقة الرياضية التي تربطها، وعدم اعتمادها على الخطية ، وبالإضافة الى تطبيقها بنجاح في التنبؤ بالسلاسل الزمنية اليومية الطويلة **الكلمات المفتاحية:** فيروس كورونا، نموذج الشبكات العصبية ذات الذاكرة قصيرة المدى، نماذج بوكس وجينكنز ، الذكاء الاصطناعي، التعلم الآلي.

١. مقدمة وأهمية الدراسة:

بدأ فيروس كورونا (COVID-19) بالظهور للمرة الأولى في شهر ديسمبر ٢٠١٩ في الصين، وبحلول شهر يناير لعام ٢٠٢١، ووصل عدد الحالات التي تم الإبلاغ عنها لأكثر من ٩٥ مليون حالة في جميع أنحاء العالم، وبلغ معدل الوفيات ٢٪ من إجمالي الحالات المؤكدة المصابة بالفيروس (Worldometers, 2020).

ويعتبر فيروس كورونا كوفيد-١٩ أحد أكثر الأمراض تهديداً للصحة العامة على مختلف المستويات العمرية في جميع أنحاء العالم. لذلك أصيب كثير من الأشخاص بالقلق والاكتئاب والاضطراب بسبب سرعة انتشار الفيروس الغير متوقعة. ووصلت الاستجابة للوقاية من الالتهاب الرئوي الناجم عن فيروس كورونا الجديد ومكافحته إلى نقطة حاسمة. لذلك أصبح التنبؤ بسرعة تفشي الفيروس أمر ضروري خلال هذا الوقت الصعب للسيطرة على معدل الوفيات. (Omran et al., 2021).

وفي الآونة الأخيرة، أُجريت العديد من الدراسات التي تؤكد على أهمية تقنيات الذكاء الاصطناعي (Artificial Intelligence) AI والتعلم الآلي (Machine Learning) ML في الحد من تأثير انتشار الفيروس (Zagrouba et al., 2021). وقد تم تطبيق ML على بيانات المرضى ضمن مجموعة من الاتجاهات البحثية المختلفة، ومن أهم اتجاهات البحث التنبؤ بمعدل الإصابة ومعدل الوفيات وبناء نموذج لتصنيف المرضى بناءً على النتائج السريرية التي توصلوا إليها (Chowdhury et al., 2021). لذلك تتضح أهمية هذه الدراسة البحثية والتي ستساعد الأشخاص في القطاعات الصحية بشكل كبير على الاستعداد الجيد واتخاذ الاحتياطات اللازمة لتقليل انتشار الفيروس.

٢. الدراسات السابقة:

قام (Nam & Schaefer, 1995) بفحص إمكانية استخدام الشبكات العصبية بدلاً من الوسائل الإحصائية التقليدية للتنبؤ بحركة مسافري الطيران الدولي وقد اتضح بأن الشبكات العصبية قد عززت دقة التنبؤ وتوقفت على الطرق التقليدية للتنبؤ، وأوصي بالاستفادة من الشبكات العصبية في التنبؤ بحمولة مسافري الطيران.

بينما قام (مسعود بدري وآخرون، ١٩٩٦) بدراسة للمقارنة بين استخدام الشبكات العصبية الاصطناعية (Artificial Neural Networks (ANN) وأسلوب تحليل التمايز المتعدد (MDA) في القدرة على التنبؤ بمخاطرة العميل المصرفي، وأشارت نتائج هذه الدراسة أن الشبكات العصبية أفضل من تحليل التمايز المتعدد في مجال الحكم على درجة اعتمادية العميل المصرفي.

ومن ناحية أخرى قام (عبد الكريم الصفار، ١٩٩٨) بدراسة استخدم فيها الشبكات العصبية للتنبؤ باستهلاك الكهرباء بالكويت، حيث درجة الحرارة المرتفعة طوال أشهر الصيف، وذلك لما فيها من أهمية في الجدوى الاقتصادية لكي يتم تحسين معدلات الصرف، وتشير نتائج البحث إلى أن استخدام الشبكات العصبية يؤدي إلى تنبؤ دقيق، وأيضاً تشير النتائج إلى أن نموذج الشبكات لا يبنى على افتراضات إنما على بيانات تاريخية حول الهدف المراد دراسته.

وفي دراسة كل من (Faraway & Chatfield, 1998) استخدموا بيانات حالة عملية لشركة طيران اعتمدت على بيانات موسمية لسلسلة زمنية لكل من أسلوبي الشبكات العصبية وبوكس . جنكنز، وأكدت النتائج من وجود خلل كبير في أساليب الشبكات، حيث بينا أنه من غير الحكمة تطبيق هذه الأساليب دون معرفة تامة بنمط black-box، وعضاً عن ذلك بينا أن المحلل الخبير

يحتاج استخدام مهارات الأساليب التقليدية لاختيار نموذج جيد للشبكات العصبية، وذلك عند حسن اختيار شكل المتغيرات المدخلة. وذلك وفقا لمعيار (Bayesian Information Crfiterion) BIC للمقارنة بين الأساليب والنماذج المختلفة للشبكات. كما يجب اتباع الحذر الشديد في تطبيق الشبكات واستخدامها للحصول على التنبؤات، ويجب اختيار أساليب تشخيص النتائج السطحية المتحصل عليها من أسلوب الشبكات، وكذلك الأساليب البديلة باستخدام نماذج الانحدار.

وكشفت دراسة كل من (Kao & Huang, 2000) عن استخدامات الأساليب التقليدية للسلاسل الزمنية مقارنة بأساليب الشبكات العصبية للتنبؤ بجودة الجو المحيط، واستخدما بيانات عن ثاني أكسيد الكبريت والأوزون التي تم جمعها في محطتين مختلفين ومن محطة صناعية أخرى، وكان أداء كلا الأسلوبين جيد للتنبؤ على مدى فترة واحدة، وأما بالنسبة للتنبؤ على مدى ٢٤ فترة، فكانت نتائج الشبكات العصبية بنفس جودة الأساليب التقليدية أو تفوقها في الجودة.

وأوضح (Baker, 2001) في مقال له عن دور النماذج الغير خطية Non linear في إضافة معلومات جديدة حول الإنتاجية التربوية استخدم فيها الشبكات العصبية عن طريق تطبيق ثلاث نماذج في ١٨٣ مدرسة ابتدائية واستخدم أيضاً نماذج غير خطية للانحدار المتعدد وأوضحت نتائج هذه الدراسة اضافة معالم جديدة في الإنتاجية التربوية.

وتشير دراسة صادرة عن (معهد التخطيط القومي، ٢٠٠٢) بعنوان " الشبكات العصبية تحل مشكلة الفجوة الغذائية في مصر " إلى إمكانية تطبيق الشبكات العصبية في مجال الزراعة وأوضحت الدراسة إجراء العديد من الدراسات للتنبؤ بكميات الأمطار باستخدام نموذج إحصائي تقليدي. وقد أعطى النموذج نتائج إيجابية في بعض السنوات وأخرى غير إيجابية، مما أفقد الثقة في هذا النموذج ولذلك أضطر الباحثون إلى استخدام نموذج الشبكات العصبية للحصول على تنبؤ طويل المدى لمنطقة مرسى مطروح باستخدام نفس البيانات.

كما قدم (العنبي، ٢٠٠٣) دراسة خص فيها التنبؤ بالأرقام القياسية في الكويت. وقد قام بمقارنة التنبؤ بالشبكات العصبية والسلاسل الزمنية لنماذج بوكس وجينكنز وأفادت نتائج تلك الدراسة بأن التنبؤ بالشبكات العصبية كان أكثر دقة.

وقام (Mostafa, 2004) بدراسة للتنبؤ بحركة العبور في قناة السويس للفترة ما بين (١٩٧٥-١٩٩٨)، استخدم فيها السلاسل الزمنية لنماذج بوكس وجينكنز والشبكات العصبية. وقد تم قياس أداء النماذج التقليدية، وأثبتت الدراسة جدوى التنبؤ باستخدام الشبكات العصبية وكفاءتها.

وقدم (Al-Shawadfi, 2003) دراسة مقارنة للتنبؤ بالسلاسل الزمنية بأسلوب بوكس جينكنز واستخدام تقنية الشبكات العصبية الاصطناعية على ١٦٠٠٠ عينة عشوائية مولدة من نماذج $ARMA(p,q)$ ، وكذلك لخمس سلاسل زمنية واقعية، وأظهرت نتائج الدراسة أن الشبكات العصبية لها قدرة أكبر على التنبؤ بالقيم المستقبلية، حيث ثبت أن متوسط مربعات أخطاء التنبؤ، ومتوسط القيمة المطلقة لخطأ التنبؤ، ومتوسط أخطاء التنبؤ أقل من نظيرتها في أسلوب بوكس - جينكنز. وخلال الدراسة التي أجراها (طاهر، ٢٠٠٦) للتقدير الدقيق لمعدلات التبخر القصوى وخصوصاً في المناطق الجافة كالمملكة العربية السعودية تم بناء أربع شبكات عصبية اصطناعية يتكون كل منها من ثلاث طبقات لتقدير معدلات التبخر الشهرية في مدينة الرياض بالاعتماد على العوامل الجوية. كما تم اختبار هذه الشبكات باستخدام قراءات سابقة لكل من الرطوبة النسبية، الأشعة الشمسية، درجة الحرارة، سرعة الرياح والتبخر على مدى ٢٢ سنة ماضية. وأظهرت النتائج أن الشبكات قد استطاعت وبكفاءة عالية تقدير التبخر تحت معطيات جديدة، وهذه النتائج المحفزة بنيت على القيم المرتفعة لمعامل الترابط وكذلك القيم المنخفضة لمتوسط الأخطاء والتي وصلت الى ٩٨.٠ و٠٠١٥.٠ على التوالي. كما أن الدراسة شملت مقارنة بين الشبكات العصبية الاصطناعية والطرق التقليدية وأثبتت كفاءة وقدرة الشبكات العصبية.

وهدفت دراسة (Nabipour, Nayyeri, Jabani, Shahab, & Mosavi, 2020) إلى تقليل مخاطر التنبؤ بحركة سوق الأوراق المالية بشكل كبير باستخدام التعلم الآلي وخوارزميات التعلم العميق على أربع مجموعات من أسواق الأوراق المالية، واستخدمت الدراسة تسعة نماذج للتعلم الآلي (eXtreme، Adaptive Boosting (Adaboost) ، Random Forest ، Decision Tree) Naïve ، Support Vector Classier (SVC) ، Gradient Boosting (XGBoost) ، Bayes ، K Nearest Neighbours (KNN) ، الانحدار اللوجستي ، والشبكات العصبية (ANN) وطريقتان قويتان للتعلم العميق (الشبكة العصبية المتكررة (RNN) والذاكرة طويلة المدى (LSTM)). واستخدم في هذه الدراسة قيم المدخلات لعشرة مؤشرات فنية خلال عشر سنوات من البيانات التاريخية، ويفترض طريقتان لتوظيفها. أولاً، حساب المؤشرات من خلال قيم تداول الأسهم كبيانات مستمرة، وثانياً، تحويل المؤشرات إلى بيانات ثنائية قبل الاستخدام. وتوصلت نتائج الدراسة الى أنه بالنسبة للبيانات المستمرة فإن RNN هي الأفضل ويتفوق LSTM في الأداء على نماذج التنبؤ الأخرى مع اختلاف كبير. اما بالنسبة للبيانات الثنائية، فان طرق التعلم العميق هي الأفضل.

وفي دراسة (Tian, Luthra, & Zhang, 2020) تم جمع بيانات مرضي مصابون بمرض COVID-19 من ٢٢ يناير ٢٠٢٠ إلى ١٤ أبريل ٢٠٢٠ دول لمقارنة كفاءة النماذج المختلفة في التنبؤ بحالات COVID-19. حيث تم تقييم أداء ٣ نماذج للتعلم الآلي (نموذج سلسلة ماركوف المخفي (HMM)، ونموذج Bayes الهرمي، ونموذج الذاكرة طويلة المدى (LSTM) باستخدام خطأ الجذر التربيعي (RMSE). وتوصلت نتائج الدراسة الى ان نموذج LSTM هو أكثر النماذج ملائمة بأقل معدلات أخطاء التنبؤ.

وأوضحت دراسة (Chimmula & Zhang, 2020) كيفية تطوير نموذج تنبؤ لتقسي مرض COVID-19 في كندا باستخدام أحدث نماذج التعلم العميق (DL) (Deep Learning) وهو شبكات الذاكرة طويلة المدى (LSTM) كطريقة تعلم عميق للتنبؤ بحالات COVID-19 المستقبلية. حيث قدمت الدراسة مقارنة لمعدلات الإصابة في كندا بإيطاليا والولايات المتحدة الأمريكية وتوصلت هذه الدراسة الى اهمية استخدام شبكات LSTM للتنبؤ بالأمراض المعدية.

في دراسة (Omran et al., 2021) تم مقارنة نموذجين من نماذج التعلم العميق (الذاكرة قصيرة المدى (LSTM) والبوابات المتكررة تم تطبيق الوحدة (GRU) للتنبؤ بالحالات المؤكدة وحالات الوفيات من COVID-19. على بيانات السلاسل الزمنية في ثلاثة بلدان: مصر والمملكة العربية السعودية والكويت خلال الفترة من ٢٠٢٠/٥/١ إلى ٢٠٢٠/١٢/٦. وتوصلت الدراسة إلى أن نموذج LSTM قد حقق أفضل أداء في الحالات المؤكدة في البلدان الثلاثة، ونموذج GRU هو الافضل أداء في حالات الوفاة في مصر والكويت.

وأخيراً وليس آخراً دراسة (Aljameel, Khan, Aslam, Aljabri, & Alsulmi, 2021) قدمت طريقة تنبؤ لتحديد المبكر لنتائج مريض COVID-19، بناءً على خصائص المرضى التي تتم مراقبتها في المنزل، أثناء وجودهم في الحجر الصحي. وتم إجراء الدراسة باستخدام ٢٨٧ شخص مصاب بفيروس COVID-19 لمرضى من مستشفى جامعة الملك فهد بالمملكة العربية السعودية. تم تحليل البيانات باستخدام ثلاث خوارزميات تصنيف، وهي الانحدار اللوجستي *Logistic Regression* (LR)، والغابات العشوائية *random forest* (RF)، وتعزيز التدرج الشديد *extreme gradient boosting* (XGB). وتم إجراء التجارب باستخدام عشرين خاصية سريرية، تم تحديدها على أنها مهمة للتنبؤ بالبقاء على قيد الحياة مقابل مرضى COVID-19 المتوفين. وأظهرت النتائج أن أسلوب (XGB) تفوق على الاساليب الأخرى بدقة ٠.٩٥. وأن المنطقة الواقعة تحت المنحنى (AUC) تبلغ ٠.٩٩.

٣. مصدر البيانات:

تعتمد هذه الدراسة بصفة أساسية على النتائج المنشورة بالتقرير الصادر من وزارة الصحة العالمية الناتجة عن الوفيات اليومي للإصابة بفيروس كورونا خلال الفترة من ٢٠٢٠/٢/١٤ حتى ٢٠٢١/٥/٣٠، وتحتوي مجموعة البيانات هذه على معلومات يومية عن عدد الحالات المصابة والوفيات والمتعافين من فيروس كورونا الجديد لعام ٢٠١٩ للعديد من الدول، ولقد تم استخدام بيانات الوفيات الخاصة بمصر. والجدول التالي يوضح الاحصاء الوصفي لبيانات الدراسة

جدول رقم (١): الاحصاء الوصفي لبيانات الدراسة

المقاييس	Confirmed (المصابين)	Deaths (الوفيات)	Recovered (المتعافين)
Mean	106514.15	6003.53	79380.14
Median	103902.00	6001.00	97449.00
Std. Deviation	74510.286	4423.608	60924.385
Minimum	1	0	0
Maximum	260659	15001	191475

٤. أهداف وفروض الدراسة:

تهدف هذه الدراسة إلى:

- (١) رصد ظاهرة فيروس كورونا والوفيات الناتجة عنه، وأهم المؤشرات التي توضح حجم المأساة.
- (٢) المقارنة بين نموذج الشبكات العصبية ذات الذاكرة قصيرة المدى المطولة LSTM ونماذج بوكس وجينكنز ARIMA للتنبؤ بأعداد الوفيات اليومية الناتجة عن الإصابة بفيروس كورونا في حالة السلاسل الزمنية الطويلة.

وذلك من خلال التحقق من الفرضيات التالية:

١. أن الوفيات الناتجة عن الإصابة بفيروس كورونا تتبع التوزيع الطبيعي.
٢. لا توجد فروق معنوية بين الفعلي والمقدر من اسلوب نماذج بوكس وجينكنز والشبكات العصبية ذات الذاكرة قصيرة المدى المطولة LSTM،

٣. توجد أفضلية لنموذج الشبكات العصبية ذات الذاكرة قصيرة المدى المطولة LSTM عن نماذج بوكس وجينكنز ARIMA.

٥. - رصد ظاهرة فيروس كورونا والوفيات الناتجة عنه، وأهم المؤشرات التي توضح حجم المسألة:

بلغت حصيلة الوفيات حول العالم نتيجة الإصابة بفيروس كورونا أكثر من أربعة ملايين، وفق ما أعلنته منظمة الصحة العالمية الأربعاء (الموافق ٧/٧/٢٠٢١). وحذر مديرها تيدروس أدهانوم غيبريسوس من أن العالم "في مرحلة خطيرة من هذه الجائحة"، نظرا لازدياد حداثتها مجددا مع انتشار متحورات جديدة وأن حصيلة وفيات فيروس كورونا تجاوزت عتبة الأربعة ملايين، وتمر العديد من البلدان من مرحلة دقيقة جراء هذا الوضع، فيما تحاول الدول النامية مواجهة الأزمة الصحية والاقتصادية أيضا بوسائل محدودة.

وأصدرت مراكز السيطرة على الأمراض والوقاية منها (CDC Centers for Disease Control and Prevention) ومنظمة الصحة العالمية إرشادات مؤقتة لحماية السكان ومحاولة منع المزيد من انتشار فيروس SARS-CoV-2 من الأفراد المصابين.

وقد سبب وباء كورونا أضرارا جسيمة علي المستويان الاجتماعي والاقتصادي العالمي (Editorial, 2020)، وتتضمن تلك الأضرار ركود اقتصادي عالمي كبير لم يكن له نظير منذ الكساد الكبير، بالإضافة إلى إلغاء أو تأجيل معظم الأحداث سواء كانت سياسية أو ثقافية أو دينية أو رياضية. وحدث نقص كبير في الإمدادات والمعدات نتيجة حدوث حالة من هلع الشراء بين الأفراد ، وايضا انخفاض انبعاثات الملوثات والغازات الدفيئة (Jonathan & Niko, 2020). وعلي الصعيد التعليمي الوطني والمحلي أغلقت الجامعات والكليات والمدارس فيما يقرب من ١٩٠ دولة حول العالم، ما أثر على نحو ٧٣.٥% من الطلاب حول العالم. وقد أدت تلك الأضرار الجسيمة إلى انتشار كثير من المعلومات الخاطئة حول الفيروس على الشبكة الدولية للمعلومات (الانترنت) (Rachel, 2020)، وظهرت حالات من التمييز العنصري ضد الصينيين أو من ينتمون إلى مناطق ذات معدلات إصابة عالية.

٦. رصد استجابة منظمة الصحة العالمية

أشادت منظمة الصحة العالمية بمجهودات السلطات الصينية، حيث قدمت الحكومة المركزية في الصين تقارير عن انتشار وباء كورونا بشكل مستمر، وذلك على نقيض ما حدث بين عامي

٢٠٠٢-٢٠٠٤ حينما تفشى مرض السارس بالصين. حيث أتهمت السلطات الصينية بالتستر على الوباء آنذاك. ولكن وجهت الانتقادات إلى منظمة الصحة العالمية بالتعامل مع الجائحة بطريقة سيئة، حيث أشار النقاد إلى تأخر منظمة الصحة العالمية بإعلان حالة طوارئ الصحة العامة وعدم تصنيف التفشي بالجائحة (BRADLEY A. THAYER & LIANCHAO, 2020).

ديسمبر ٢٠١٩:

قامت كلاً من الصين وتايوان بإعلان منظمة الصحة العالمية بوجود فيروس جديد في كلا البلدين في يوم ٣١ ديسمبر لعام ٢٠١٩. ولكن لاحقاً حدث خلاف بين تايوان ومنظمة الصحة العالمية حول مضمون رسالة تايوان وعدم استجابة منظمة الصحة العالمية لها. ولا تعتبر تايوان مراقباً لمنظمة الصحة العالمية بسبب الضغط الدبلوماسي من الصين (Ben, 2020).

يناير ٢٠٢٠:

صدرت أول توجيهات فنية من منظمة الصحة العالمية في يومي ١٠ و ١١ يناير لعام ٢٠٢٠ (WHO, 2020a) محذرةً بذلك دول العالم أجمع باحتمالية انتقال الفيروس من إنسان إلى إنسان آخر، حيث أكدت المنظمة علي ضرورة اتخاذ الاحتياطات اللازمة للوقاية من الفيروس بسبب التشابه مع تفشي وباء السارس وميرس. وصرحت منظمة الصحة العالمية في يوم ٢٠ يناير لعام ٢٠٢٠ بأن الفيروس قد انتقل بين البشر وبعضهم البعض، حيث أصيب عدد كبير من العاملين بالمجال الطبي بالفيروس. وجاء تصنيف منظمة الصحة العالمية للفيروس في يوم ٢٧ يناير، حيث صنّف الفيروس بأنه "خطر عالي على المستوى العالمي". (Glenn, 2020)

وأعقب ذلك تصريح منظمة الصحة العالمية في يوم ٣٠ يناير بأن التفشي أصبح ضمن حالات طوارئ الصحة العامة محل الاهتمام الدولي (PHEIC)، كما حذرت المنظمة جميع الدول بأن تكون علي أتم الاستعداد لمواجهة واحتواء تفشي الفيروس، وذلك من خلال المراقبة الفعالة، والترصد المبكر، وعزل الحالات والتعامل معها، وتتبع المخالطين لحالات الإصابة، واتخاذ كافة الإجراءات الاحترازية للوقاية من زيادة تفشي الفيروس (MERRIT, 2020; WHO, 2020b). وجاء هذا التحذير بعد الزيادة الكبيرة في أعداد حالات الإصابة بالفيروس خارج الصين.

ويعتبر هذا الإعلان سادس إعلان لحالة طوارئ الصحة العامة محل الاهتمام الدولي منذ أول تطبيق لهذه الحالة أثناء جائحة إنفلونزا الخنازير عام ٢٠٠٩. ويتضح السبب وراء هذا الإعلان في تصريح المدير العام لمنظمة الصحة العالمية، تيدروس أدهانوم، حيث قال إن هذا الإعلان كان

بسبب الخطورة الكبيرة لانتشار الفيروس في جميع انحاء العالم، خاصةً الدول ذات الدخل المنخفض والمتوسط والتي تفتقر للأنظمة الصحية القوية، وأضاف تيدروس بأنه لا توجد أي أسباب لاتخاذ تدابير من شأنها التأثير على التجارة الدولية والسفر بين الدول بلا داعٍ. وأكد على أن منظمة الصحة العالمية لا توصي بتقليل الحركة والتجارة، وأن المنظمة تدعو جميع دول العالم إلى اتخاذ قرارات متناسقة وقائمة على الدليل (WHO, 2020b)

فبراير ٢٠٢٠:

أطلقت منظمة الصحة العالمية اسم "كوفيد ١٩" في مؤتمر صحفي يوم ١١ فبراير ليكون اسماً للمرض المنتشر. وأعقب الإعلان تصريح تيدروس بأن الأمين العام للأمم المتحدة، أنطونيو غوتيريش، وافق على توفير كامل قوة نظام الأمم المتحدة لمواجهة الأزمة. حيث تم بعد ذلك تفعيل فريق إدارة الكوارث بالأمم المتحدة والذي أدي إلى التنسيق بين جميع دول الأمم المتحدة، ولذلك صرحت منظمة الصحة العالمية أن تلك الخطوة ستتمكنها من التركيز على الاستجابة الصحية بشكل أفضل ومن ناحية أخرى تقوم الوكالات الأخرى بجمع خبراتها للتعامل مع الآثار الاقتصادية والاجتماعية، والتنمية لهذا الوباء (WHO, 2020d).

وفي يوم الخامس والعشرين من فبراير لعام ٢٠٢٠، جاء تصريح منظمة الصحة العالمية باحتمالية وقوع جائحة لفيروس كورونا المستجد وعلى العالم أن يقوم بالمزيد من الإجراءات ليكون مستعداً لمواجهة الأزمة المقبلة. وأضاف التصريح بأنه يجب على الدول أن تكون في مرحلة التأهب لمواجهة هذه الجائحة، على الرغم انه من المبكر جداً إطلاق لفظ "جائحة" على هذا التفشي حتى الآن (BBC News, 2020).

وصدر تصريح عن منظمة الصحة العالمية في يوم ٢٨ فبراير لعام ٢٠٢٠ ينص على رفع درجة تقييم خطر فيروس كورونا المستجد من "خطر عالي" إلي أعلى مستوى من تقييم الخطر وهو "خطر عالي للغاية" وذلك على المستوى العالمي. كما حذر مايك جيه رايان، المدير التنفيذي لبرنامج حالات طوارئ الصحة بمنظمة الصحة العالمية جميع الحكومات على كوكب الأرض بقوله "انهضوا، واستعدوا، يمكن أن يكون الفيروس في طريقه إليكم ويجب أن تكونوا جاهزين" وأكد رايان خلال تصريحه على أن التدابير الصحية يمكن أن تساعد في تجنب "أسوأ ما في هذا التفشي". واختتم رايان قوله بأن "البيانات الحالية لم تتح للمسؤولين الصحيين إعلان حالة الجائحة العالمية،

حيث أن هذا الاعلان يعني أننا نقر بصورة أساسية أن كل إنسان على هذا الكوكب سيكون مُعرضاً لهذا الفيروس" (Berkeley, 2020).

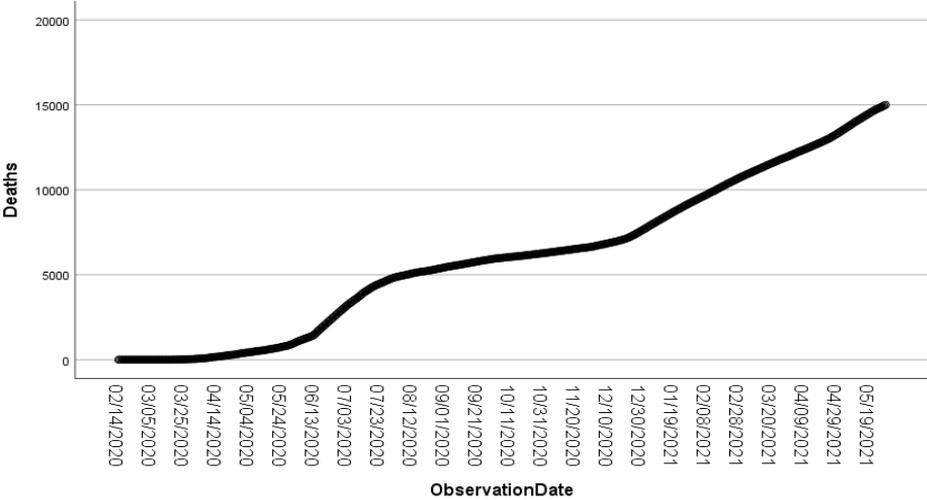
مارس ٢٠٢٠:

صرحت منظمة الصحة العالمية في يوم ١١ مارس لعام ٢٠٢٠ بأن تفشي فيروس كورونا المستجد أصبح جائحةً. وأضاف المدير العام لمنظمة الصحة العالمية بأن المنظمة تهتم للغاية بمستويات تنبيه انتشار الفيروس ومستويات تنبيه تراجع الفيروس على حد سواء. (WHO, 2020c).

أغسطس ٢٠٢٠:

جاء تحذير منظمة الصحة العالمية في يوم ٣ أغسطس على لسان المدير العام للمنظمة، تيدروس أدهانوم غيبريسوس، بأنه لا يوجد حل سحري للقضاء على الفيروس، وقد يظهر الحل وقد لا يظهر. وأكد تيدروس على ضرورة الالتزام بكافة التدابير الوقائية مثل التباعد الاجتماعي وغسل الأيدي وارتداء الكمامة وإجراء الفحوصات الطبية الدورية.

ويشير جدول (١) الاحصاء الوصفي لاعداد الوفيات اليومي للإصابة بفيروس كورونا خلال الفترة من ٢٠٢٠/٢/١٤ حتى ٢٠٢١/٥/٣٠ شكل (١) المنحنى التاريخي للوفيات الناتجة عن الوفيات اليومي للإصابة بفيروس كورونا خلال الفترة من ٢٠٢٠/٢/١٤ حتى ٢٠٢١/٥/٣٠

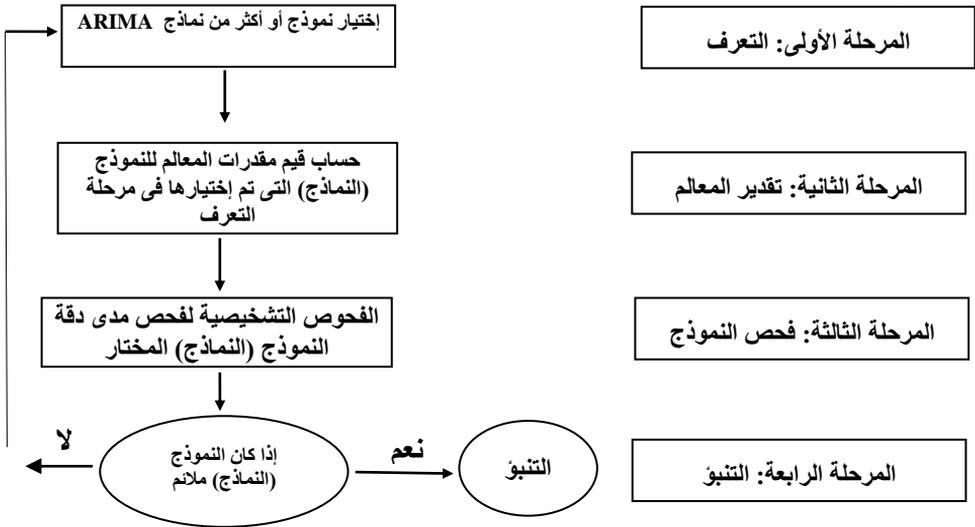


شكل (١) أعداد الوفيات اليومي للإصابة بفيروس كورونا خلال الفترة من ٢٠٢٠/٢/١٤ حتى ٢٠٢١/٥/٣٠ المصدر: النتائج المنشورة بالتقرير الصادر من منظمة الصحة العالمية

٧. نماذج بوكس وجينكنز للتنبؤ بأعداد الوفيات اليومية الناتجة عن الإصابة بفيروس

كورونا في مصر

في هذا الجزء نقوم باستخدام نماذج بوكس - جينكنز للتنبؤ بالوفيات اليومية الناتجة عن الإصابة بفيروس كورونا في مصر خلال الفترة من ٢٠٢٠/٢/١٤ حتى ٢٠٢١/٥/٣٠، وتشمل عملية بنائها أربعة مراحل هي مرحلة التعرف Identification، مرحلة التقدير Estimation، والفحوص التشخيصية Diagnostic checking، وأخيراً مرحلة التنبؤ Forecasting. ويبين الشكل رقم (٢) خريطة لمسار هذا الأسلوب.



شكل (٢): خريطة مسار نماذج بوكس وجينكنز (ARIMA)

١/٧ مرحلة التعرف

وتم توفير النماذج باستخدام حزمة Eviews 11، وتحديد أعلى رتبة لمعامل الانحدار الذاتي، وللمتوسطات المتحركة العادي، وللفروق العادية 2، وبعد التأكد من سكون السلسلة بعد اخذ الفرق الثاني، تم تقدير معالمها وإيجاد المعايير الاحصائية المستخدمة للمقارنة بينها وبين الشبكات في حالة السلاسل الزمنية الطويلة. (Ngo & Bros (2013, April).

٢/٧ فحص وتشخيص النماذج التقليدية:

في مرحلة فحص وتشخيص النماذج يتم دراسة مدي ملائمة النماذج لتحليل سلسلة البيانات اليومية لأعداد الوفيات الناتجة عن الإصابة بفيروس كورونا والذي تم التعرف عليها وتم تقدير

معالمها وفحص مدي كفاءتها وملاءمتها باستخدام معيار (Akaike Information Criteria) AIC كما هو موضح بالجدول رقم (٢)،

جدول رقم (٢): المعايير الإحصائية المستخدمة للمقارنة بين النماذج الموقفة

Model	RMSE	MAE	MA	ME	AIC	HQC	SBI
PE							C
(K)	50.28	30.62	11.	0.142	3.33	3.33	3.34
ARIMA(1,2,0)	4	294	501	611	361	708	243
(L)	50.28	30.61	1.8	0.294	3.33	3.34	3.35
ARIMA(2,1,0)	266	821	28	786	735	429	499
(M)	50.29	30.61	1.4	0.162	3.33	3.34	3.34
ARIMA(0,2,1)	407	865	94	23	742	089	624
(N)	50.28	30.62	1.5	0.143	3.33	3.34	3.35
ARIMA(2,2,0)	952	042	02	777	995	689	759
(O)	50.26	30.60	1.5	0.164	3.34	3.35	3.37
ARIMA(2,2,2)	758	812	1	006	013	401	541

من خلال الجدول رقم (٢) يتضح أن نموذج ARIMA (1,2,0) يعد الأفضل والأكثر ملائمة للبيانات لأن له أقل قيمة لمعيار AIC

٣/٧ أفضلية النموذج:

تم استخدام بعض المعايير للحكم على أفضلية النماذج، وتتابع البواقي وعشوائيتها، لتعبر عن الوفيات اليومية الناتجة عن الإصابة بفيروس كورونا في مصر ويوضحها الجدول التالي:

جدول رقم (٣): مقارنة البواقي لنماذج بوكس وجينكنز للتنبؤ بالوفيات اليومية الناتجة عن الإصابة بفيروس كورونا في مصر حسب المعايير المختارة

Model	RMSE	RUNS	RUNM	AUTO	MEAN	VAR
(K)	5.224	***	***	***	***	***
(L)	5.28266	*	OK	*	OK	***
(M)	5.29407	OK	OK	**	OK	***
(N)	5.28952	**	*	*	OK	***
(O)	5.26758	OK	OK	*	OK	***

Key:

RMSE = Root Mean Squared Error

RUNS = Test for excessive runs up and down

RUNM = Test for excessive runs above and below median

AUTO = Box–Pierce test for excessive autocorrelation

MEAN = Test for difference in mean 1st half to 2nd half

VAR = Test for difference in variance 1st half to 2nd half

OK = not significant ($p \geq 0.05$)

* = marginally significant ($0.01 < p \leq 0.05$)

** = significant ($0.001 < p \leq 0.01$)

*** = highly significant ($p \leq 0.001$)

٨. اسلوب الشبكات العصبية ذات الذاكرة قصيرة المدى المطولة LSTM

التنبؤ بأعداد الوفيات اليومي للإصابة بفيروس كورونا

تعد الشبكات العصبية واحدة من طرق الذكاء الاصطناعي بوجه عام وواحدة من طرق التعلم الآلي بوجه خاص (الصقير وآخرون، ٢٠٠١). كما تعد الشبكات العصبية حقل متشعب من ناحية الدراسة، حيث تقدم طريقة مناسبة في تمثيل العلاقات بين المتغيرات بشكل مختلف عن الطرق التقليدية. ولقد طورت الشبكات العصبية لاستخدام الحاسوب في تخصصات كانت محصورة فقط للذكاء الإنساني.

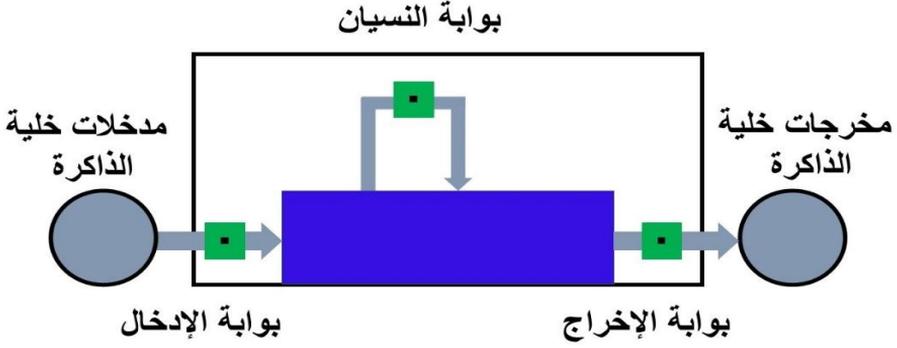
وتعرف الشبكات العصبية المتكررة كنوع من الشبكات العصبية الاصطناعية التي تعتمد على البيانات التسلسلية، وتستخدم في تطبيقات التعلم العميق التي تتعامل مع البيانات المتتابعة والسلاسل الزمنية مثل، ترجمة اللغات، ومعالجة اللغة الطبيعية، والتعرف التلقائي على الكلام المنطوق. ومن أهم الأمثلة على استخدامها، المساعدات الصوتية مثل، سيرري، وأليكسا، والبحث الصوتي، وخدمة الترجمة من جوجل.

وتعتبر الشبكات العصبية المتكررة (Convolutional neural network) CNN قديمة نسبياً، حيث ظهرت لأول مرة في ثمانينيات القرن الماضي ولكن لم تتم الاستفادة من إمكانياتها بالشكل الأمثل إلا في السنوات الأخيرة تزامناً مع توفر البيانات الضخمة والقدرات الحاسوبية العالية. وتتمتع هذه الشبكات بميزة "الذاكرة" التي تسمح لها بأخذ معلومات من بيانات الوفيات السابقة للتأثير على بيانات الوفيات والمخرجات الحالية. فعلى عكس الشبكات العصبية العميقة الأخرى التي تفترض أن

المدخلات مستقلة عن المخرجات، يعتمد الخرج في الشبكات المتكررة على العناصر السابقة في تسلسل البيانات (O'Shea & Nash 2015).

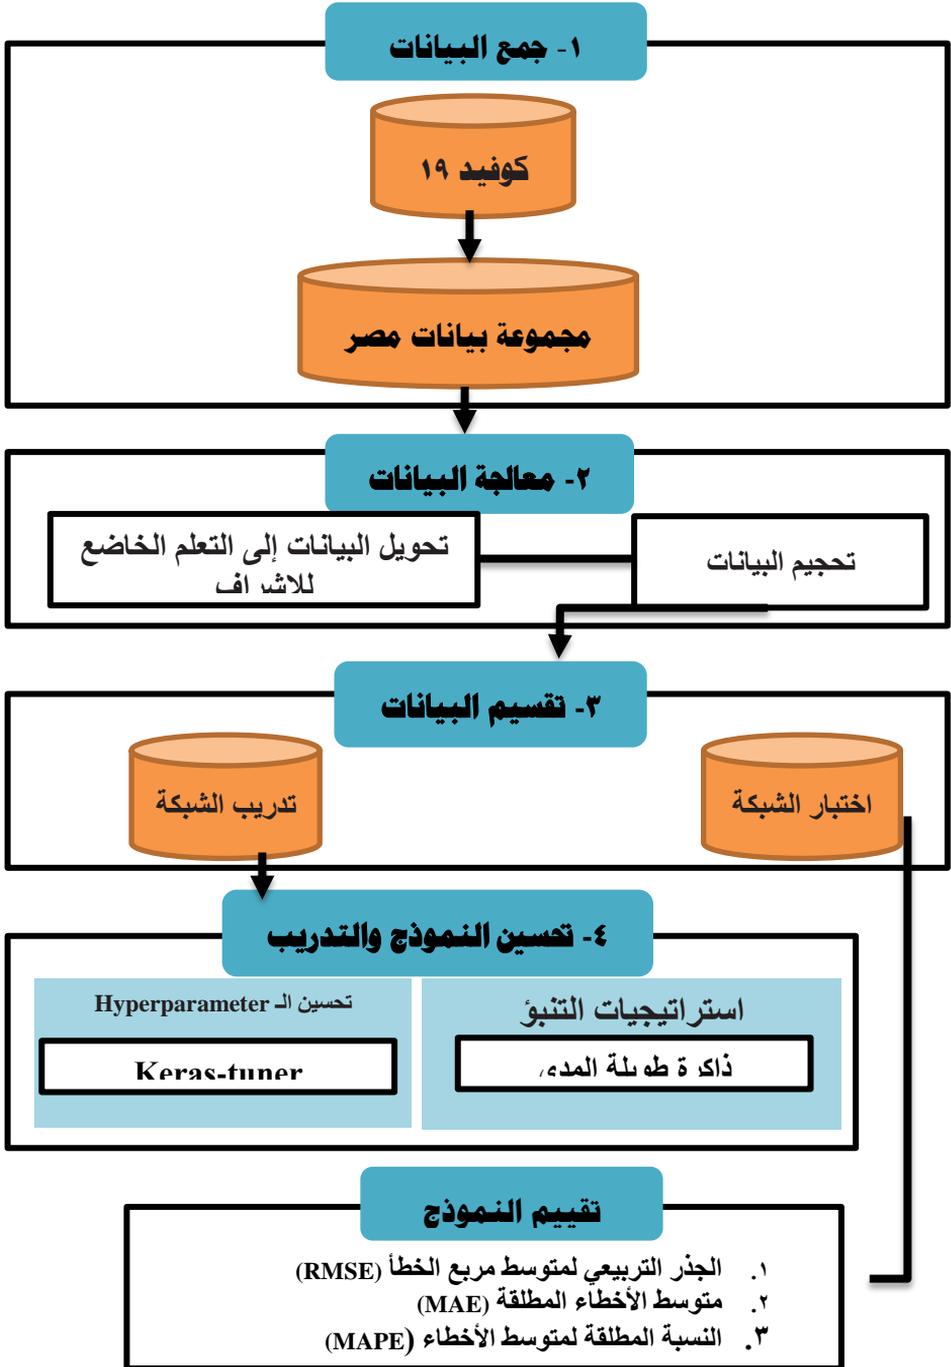
وتختلف الشبكات العصبية المتكررة عن شبكات التغذية إلى الأمام (RNN) (Rete neurale) و (feed-forward)، فشبكات التغذية إلى الأمام تأخذ كمية ثابتة من بيانات الدخل دفعة واحدة وتعطي كمية ثابتة من المخرجات في كل مرة. على الجانب الآخر، لا تأخذ الشبكات العصبية المتكررة جميع بيانات الدخل معاً، إنما تأخذ عنصراً واحداً من تلك البيانات في كل مرة بشكل متسلسل. ثم تجري عليه مجموعة من العمليات الحسابية المتسلسلة قبل إنتاج الخرج الموافق، ويعرف هذا الخرج باسم الحالة المخفية (Hidden State). يتم بعد ذلك دمج الخرج الناتج عن المرحلة الحالية مع عنصر الدخل التالي لإنتاج خرج جديد. وتستمر العملية حتى انتهاء تسلسل بيانات الدخل، ويمكن أيضاً برمجة النموذج للتوقف عند مرحلة معينة (Yee, 1998).

وتعتبر الذاكرة طويلة المدى [LSTM] هي نوع خاص من بنية الشبكة العصبية الاصطناعية المتكررة (RNN) المصممة لنمذجة مشكلة التبعية طويلة الأمد والمتسلسلة الزمنية وتعمل بشكل أكثر دقة من RNN التقليدية. وقد ظهرت للمرة الأولى على يد العالمين هورخيتز سيب وبورغن شميوتبر (Hochreiter & Schmidhuber, 1997) في عام ١٩٩٧ وكان الهدف الرئيسي من تصميمها هو تفادي مشاكل الشبكات العصبية المتكررة البسيطة والحصول على نتائج أفضل. وتتألف خلية الذاكرة قصيرة المدى المطولة من ثلاث بوابات هي بوابة الإدخال (Input Gate) التي تقوم بإضافة المعلومات المفيدة إلى حالة الخلية، وبوابة النسيان (Forget Gate) التي تقوم بإزالة المعلومات التي لم يعد لها فائدة في حالة الخلية، وأخيراً بوابة الإخراج (Output Gate) التي تقوم باستخراج المعلومات المفيدة من حالة الخلية الحالية لتقديمها كمخرج. وكل بوابة عبارة عن خلية عصبية تحتوي على متجه الحالة السابقة $(ht - 1)$ (Chimmula & Zhang, 2020) كما يتضح في الشكل التالي:



شكل رقم (٣): خلية الذاكرة قصيرة المدى المطولة

فالهدف الرئيسي من تصميم الشبكات العصبية ذات الذاكرة قصيرة المدى المطولة هو التخفيف من وطأة الاعتمادية طويلة المدى وتأثيرها السلبي على عملية التعلم. وتتم تصميم هذه الشبكات بخمس مراحل، الاولى جمع البيانات، والثانية معالجة البيانات، والثالثة تقسيم البيانات، والرابعة تحسين النموذج والتدريب، والخطة الخامسة والاخيرة تقييم النماذج (Omran et al., 2021). والشكل التالي يوضح خطوات عمل الشبكات العصبية ذات الذاكرة قصيرة المدى المطولة



الشكل رقم (٤): النموذج المقترح للتنبؤ بـ "كوفيد-١٩"

(١) الخطوة الأولى (جمع البيانات): تم أخذ مجموعة بيانات Novel Corona Virus 2019 من Kaggle وتتضمن مجموعة البيانات هذه معلومات على المستوى اليومي لعدد الحالات المؤكدة وحالات الوفاة بفيروس كورونا. وتتكون من بيانات سلاسل زمنية في بلدان مختلفة من ٢٢/١/٢٠٢٠ إلى ٦/١٢/٢٠٢٠. قمنا بعمل نتائج تجريبية على سلسلة زمنية لحالات الوفاة في: مصر.

(٢) الخطوة الثانية (معالجة البيانات): ويتم تطبيق خطوتين على بيانات السلسلة الزمنية في مصر وهي تحويل البيانات إلى تعلم خاضع للإشراف وتحجيم البيانات.

١/٢ تحويل البيانات إلى التعلم الخاضع للإشراف حيث تم تقسيم مجموعة البيانات إلى عينات إدخال (X) وخرج (Y) ويتم إجراء التنبؤ بخطوة واحدة فقط (يوم واحد)، والخرج (Y) هي الخطوة الزمنية التالية (t + 1) وبالنسبة لعينات الإدخال (X) تم استخدام ٥ فترات تأخير (٥ أيام).

٢/٢ تحجيم البيانات. أي إعادة قياس البيانات من النطاق الأصلي إلى نطاق جديد بين ٠ و ١. على وجه التحديد، وذلك لان نماذج LSTM يفضل العمل على البيانات في نطاق وظيفة التنشيط الخاصة بها [9] feature_range [0,1] MinMaxScaler، وتم استخدام دالة التنشيط ReLU في مرحلة التقييم.

(٣) الخطوة الثالثة (تقسيم مجموعة البيانات): تم تقسيم مجموعة البيانات إلى جزئين (٨٠٪) لمجموعة التدريب و (٢٠٪) لمجموعة الاختبار حيث تُستخدم مجموعة التدريب لتحسين النماذج وتدريبها، بينما تُستخدم مجموعة بيانات الاختبار لتقييم النماذج. حيث تم تقسيم مجموعة البيانات إلى عينات إدخال المتغير المستقل (X) والمتغير التابع (Y) لان نماذج التعلم العميق تم تدريبها تحت إشراف التعلم، وبما أننا لم نعلم إلا بخطوة واحدة إلى الأمام التنبؤ (١ يوم)، والتابع (Y) هي الخطوة التالية (t + 1) فان نقاط البيانات. بالنسبة لعينات الإدخال (X)، استخدمنا ٥ تأخيرات (٥ أيام)

(٤) الخطوة الرابعة (تحسين النموذج والتدريب): حيث تم استخدام الذاكرة طويلة المدى (LSTM) كنموذج مرشح للتنبؤ بوفيات COVID-19، وتم تطبيق عدد مختلف من الطبقات المخفية: طبقة واحدة وطبقتان (طبقة مسقط مع طبقة مخفية). وتشتمل طبقة المخرجات على خلية عصبية واحدة، ووظيفة التنشيط ReLU، ومحسن آدم Tuner.

(٥) الخطوة الخامسة (تقييم النماذج لقياس أدائها): وتم استخدام ثلاثة معايير للأخطاء لتقدير دقة التنبؤ للنماذج؛ اثنان من هذه الأخطاء عبارة عن أخطاء تعتمد على المقياس حيث تكون

هذه الأخطاء على نفس مقياس البيانات نفسها وبالتالي لا يمكن استخدامها لإجراء مقارنات بين مجموعات بيانات السلاسل الزمنية الموجودة على مستويات مختلفة. وهما

١. الجذر التربيعي لمتوسط مربع الخطأ **RMSE (Root Mean Squared Error)** ويمكن إيجاده بالصيغة الآتية:

$$RMSE = \sqrt{\sum e_T^2/n} \quad e_T = Y_T - F_T \quad (1)$$

حيث أن:

e_T : تمثل الخطأ أو البواقي, Y_T : تمثل القيم الحقيقية للمتغير,

F_T : تمثل القيم المتنبأ بها للمتغير Y_T

٢. متوسط الأخطاء المطلقة **Mean Absolute Error**

وتحسب بالشكل الآتي:

$$MAE = \sum (|e_T|/n) \quad (2)$$

ويستخدم الاختبار الأول والثاني لمعرفة القوة التنبؤية للنموذج المستخدم والمقياس الأخطاء الثالث المستخدم في المقارنات بين عدة نماذج تنبؤية هو خطأ النسبة المئوية، أي، متوسط الخطأ المطلقة في النسبة المئوية (MAPE)، ويحسب بالشكل الآتي

٣. النسبة المطلقة لمتوسط الأخطاء **mean absolute percentage error**

$$MAPE = \sum (|e_T/Y_T|/n) \quad (3)$$

وتستخدم هذه الصيغة للمقارنة بين عدة نماذج تنبؤية

وتستخدم هذه الصيغة لمعرفة التحيز في الأخطاء نحو الاتجاه الموجب أو السالب وكلما كانت

القيمة قريبة من الصفر يشير هذا إلى دقة التنبؤ

٩. المقارنة بين نموذج **LSTM** ونموذج **ARIMA** للوفيات اليومية الناتجة عن الإصابة

بفيروس كورونا:

بعد التعرف على النماذج الملائمة للبيانات وتقدير معالمها، كان لابد من فحص أو اختبار هذه النماذج للتحقق من مدى ملائمتها لعملية التنبؤ وتحديد أي الاساليب أفضل والجدول رقم (٤) يوضح اوجه المقارنة بين النماذج.

جدول رقم (٤): المقارنة لأفضل النماذج للوفيات اليومية الناتجة عن الإصابة بفيروس كورونا حسب المعايير المختارة

النموذج	الجذر التربيعي لمتوسط مربع الخطأ RMSE	المتوسط المطلق للخطأ MAE	المتوسط النسبي المطلق للخطأ MAPE
ARIMA	50.292	30.62294	1.50
LSTM	29.8605	28.5944	0.4454

ويتضح من الجدول (٤) السابق ان نموذج الشبكات LSTM يعد الأفضل والأكثر ملائمة للبيانات حيث أن له أقل المعايير المستخدمة مقارنة مع نموذج ARIMA (1,2,0) ١٠. التنبؤ باستخدام النماذج المقترحة:

وتم التنبؤ بالقيم للحالات الجديدة، وعلى هذا الأساس ولهدف المقارنة تم استخدام عدد 5 مشاهدات (وفيات الخمس ايام التالية ليوم ٢٤/٥/٢٠٢١) كمجموعة اختبار. ويوضح الجدول رقم (٥) القيم المتنبأ بها ونسبة التغير، ومنه نجد أن هناك دليلا واضحا على كفاءة نموذج LSTM وبالتالي فإن نموذج LSTM يعد الأفضل والأكثر ملائمة عن نموذج ARIMA، وبهذا نقبل صحة الفرض القائل " توجد أفضلية لنموذج الشبكات العصبية ذات الذاكرة قصيرة المدى المطولة LSTM عن نماذج بوكس وجينكنز ARIMA".

جدول رقم (٥): القيم الفعلية والمتنبأ بها لأفضل النماذج ونسبة التغير للوفيات الناتجة عن الإصابة بفيروس كورونا

اليوم	الفعلي	المتوقع	نسبة التغير عن الفعلي %	
			LSTM	ARIMA
٢٠٢١/٥/٢٥	14807	14812.7	14809.3	-0.04%
٢٠٢١/٥/٢٦	14850	14850.71	14851.11	-0.01%
٢٠٢١/٥/٢٧	14904	14893.89	14903.85	0.07%
٢٠٢١/٥/٢٨	14950	14953.86	14951	-0.03%
٢٠٢١/٥/٢٩	15001	14998.67	14999.8	0.02%
الجملة	74512	74509.83	74515.06	0.015%

ويتضح من الجدول (٥) السابق ان نموذج الشبكات LSTM يعد الأفضل والأكثر ملائمة للبيانات

١١. نتائج الدراسة:

توصلت الدراسة الي النتائج التالية:

- أن الشبكات العصبية الاصطناعية LSTM أكثر دقة وكفاءة في التنبؤ عن نماذج بوكس وجينكنز ARIMA حيث وصلت الشبكات العصبية LSTM لمعدل مرتفع وعالي من الدقة مع بقاء أفضليتها في التنبؤ للسلاسل الزمنية الطويلة.
- إن استخدام نموذج الشبكات العصبية LSTM في التنبؤ، ورسم الخطط سواء الطويلة الأجل والقصيرة الأجل لما يتميز به هذا النموذج من سرعة ودقة في البيانات أكثر منه في نماذج ARIMA.
- من خلال التطبيق لكل من نماذج بوكس وجينكنز ARIMA والشبكات العصبية LSTM يتبين لنا أن الشبكات العصبية LSTM قد تميزت عنها بأن لديها منهجية في عدم الاعتماد على الخطية في البيانات.
- تعتبر الذاكرة طويلة المدى [LSTM] من أفضل الخوارزميات المصممة لنمذجة مشكلة التبعية طويلة الأمد والمتسلسلة الزمنية
- الذاكرة طويلة المدى [LSTM] تعمل بشكل أكثر دقة من RNN التقليدية
- يجب على كل من يقوم بدراسة يتطلب فيها نظرة مستقبلية أن يقوم باستخدام الشبكات العصبية LSTM وأن يتم تحليلها باستخدام الأساليب الإحصائية الحديثة، وذلك لتحقيق الاستفادة القصوى منها حيث أن الشبكات لديها السرعة والدقة.

١٢. توصيات الدراسة:

- توجد عدة توصيات رئيسية يمكن بذلها أو أخذها بعين الاعتبار للتقليل من وفيات الاصابة بفيروس كورونا الخسائر الناتجة عنها خاصة وهي:
- التنسيق مع وسائل الاعلام لتقديم البرامج الإعلامية والنشرات الدورية عن التوعية الطبية، وبت حملات توعية للحد من معدلات الاصابة التقليل الوفيات والخسائر في الارواح الناتجة عنها خاصة استخدام وسائل السلامة، ومبادئ الاسعافات الأولية،
 - زيادة الاهتمام بالرعاية الطبية ودورها الفعال واقتراح وضع الاسعاف بشكل جيد في المستشفيات المتنقلة ، حيث أن وجود نظام خدمة طبية مجهزة ومنظم يمكن أن ينقذ حياة عدد كبير من الذين يموتون.

- زيادة استخدام التقنيات الحديثة ونقترح إعادة تصميم استمارة جمع البيانات عن الوفيات بحيث تسمح بتسجيل المعلومات الضرورية واللازمة وإنشاء قاعدة بيانات والتأكيد على ضرورة دقة هذه البيانات.
- إجراء العديد من الدراسات باستخدام تقنيات الذكاء الاصطناعي AI والتعلم الآلي ML والتي ستساعد الأشخاص في العديد من القطاعات وخاصة القطاع الصحي على الاستعداد الجيد واتخاذ الاحتياطات اللازمة لتقليل انتشار العديد من الأمراض والأوبئة.
- إعداد دراسات متكاملة على أساس علمي وعملي يشتمل جميع عناصر الإصابة على أن يتم ذلك وفقا للمعايير العلمية والآليات والتقنية السائدة عالميا بهدف الوصول للاستخدام الأمثل للإمكانيات الطبية.
- دراسة معدلات الوفيات وطبيعتها في كل محافظة ومنطقة على حدة والمؤثرات على هذه الوفيات وسرعتها ومعدل الطلب على التطعيم ليتم بعد ذلك وضع تقييم واختيار الحلول المناسبة لكل محافظة بما يناسبه ويعطي أفضل النتائج الممكنة.

الخلاصة والاستنتاج:

حاول البحث مقارنة أداء نموذج الشبكات العصبية LSTM مع نماذج بوكس وجينكينز ARIMA لكي يتم التنبؤ بالوفيات الناتجة عن الإصابة بفيروس كورونا في مصر، وتم تجربة كل نموذج للتنبؤ بثلاث أيام جديدة. ومن خلال تطبيق النماذج وُجِدَ أنَّ الشبكات العصبية LSTM تتفوق على نماذج ARIMA بدرجة ملحوظة. وتميزت منهجية الشبكات العصبية LSTM في عدم اعتمادها على الخطية فإن أداءها الأفضل مقارنة بنماذج بوكس وجينكينز، وبالتالي فإنه يمكن تطبيق الشبكات العصبية ذات الفجوات الزمنية قصيرة المدى المطولة LSTM بنجاح في التنبؤ بالسلاسل الزمنية اليومية الطويلة بالإضافة إلى أنه لا يلزمها افتراض نماذج مسبقة لتمثيل البيانات أو العلاقة الرياضية التي تربطها.

المراجع:

- بدري، مسعود والمطوع، أحمد وهادي، عقيل ١٩٩٦: " استخدام تحليل التمايز والشبكات العصبية في التنبؤ بدرجة اعتمادية العميل المصرفي"، المجلة العربية للعلوم الإدارية، الكويت مجلد (٣) عدد (٢)، ص (٢٩٥-٣١٥).
- الصفار، عبد الكريم ١٩٩٨: "استخدام الشبكات العصبية للتنبؤ باستهلاك الكهرباء في الكويت"، مجله العلوم الاقتصادية والإدارية، العدد (١٤) الامارات العربية المتحدة، ص (١٢٥-١٤٣)
- ظاهر، سعود بن عبد القادر ٢٠٠٥: "تقدير معدلات التبخر المحتملة: الشبكات العصبية الاصطناعية مقارنة بالطرق التقليدية"، مجلة العلوم الهندسية، جامعة الملك سعود، المملكة العربية السعودية، مجلد (١٧) العدد (١)، ص (١٥-٢٦).
- العتيبي، فوزي ٢٠٠٣: " استخدام السلاسل الزمنية والشبكات العصبية في التنبؤ بالأرقام القياسية " رسالة ماجستير في الأحساء التطبيقي، جامعة قناة السويس، بورسعيد، مصر.
- معهد التخطيط القومي ٢٠٠٢: " الشبكات العصبية تحل مشكلة الفجوة الغذائية في مصر

" متاحة بالموقع: <http://www.inBlanning.gov.eg/activities.html>

- Al-Shawadfi, G. A. (2003). A comparison between neural network and Box-Jenkins Forecasting Techniques With Application to Real data. *The Research Bulletin, Human Resources Development and Research Center, College of Business and Economics, King Saud University PO. Box.*
- Aljameel, S. S., Khan, I. U., Aslam, N., Aljabri, M., & Alsulmi, E. S. (2021). Machine learning-based model to predict the disease severity and outcome in COVID-19 patients. *Scientific programming, 2021.*
- Baker, B. D. (2001). Can flexible non-linear modeling tell us anything new about educational productivity? *Economics of Education Review, 20(1), 81-92.*
- BBC News. (2020). Coronavirus: World must prepare for pandemic, says WHO. *BBC News.* Retrieved from <https://web.archive.org/web/20200517064614/https://www.bbc.com/news/world-51611422>
- Ben, B. (2020). Taiwan, WHO spar again over coronavirus information sharing. *Reuters.* Retrieved from <https://web.archive.org/web/20200511160806/https://www.reuters.com/artic>

le/us-health-coronavirus-taiwan/taiwan-who-spar-again-over-coronavirus-information-sharing-idUSKCN21T0BA

- Berkeley, L. (2020). WHO raises coronavirus threat assessment to its highest level: 'Wake up. Get ready. This virus may be on its way'. *CNBC*. Retrieved from <https://web.archive.org/web/20200511175101/https://www.cnb.com/2020/02/28/who-raises-risk-assessment-of-coronavirus-to-very-high-at-global-level.html>
- BRADLEY A. THAYER , & LIANCHAO, H. (2020). China and the WHO's chief: Hold them both accountable for pandemic. *The Hill* Retrieved from <https://thehill.com/opinion/international/487851-china-and-the-whos-chief-hold-them-both-accountable-for-pandemic/>
- Chimmula, V. K. R., & Zhang, L. (2020). Time series forecasting of COVID-19 transmission in Canada using LSTM networks. *Chaos, Solitons & Fractals*, 135, 109864.
- Chowdhury, M. E., Rahman, T., Khandakar, A., Al-Madeed, S., Zughair, S. M., Hassen, H., & Islam, M. T. (2021). An early warning tool for predicting mortality risk of COVID-19 patients using machine learning. *Cognitive Computation*, 1-16.
- Editorial. (2020). Here Comes the Coronavirus Pandemic: Now, after many fire drills, the world may be facing a real fire. *The New York Times*. Retrieved from <https://web.archive.org/web/20200408114100/https://www.nytimes.com/2020/02/29/opinion/sunday/corona-virus-usa.html>
- Faraway, J., & Chatfield, C. (1998). Time series forecasting with neural networks: a comparative study using the air line data. *Journal of the Royal Statistical Society: Series C (Applied Statistics)*, 47(2), 231-250.
- Glenn, K. (2020). Trump's false claim that the WHO said the coronavirus was 'not communicable'. *The Washinoton Post*. Retrieved from <https://web.archive.org/web/20200516020825/https://www.washingtonpost.com/politics/2020/04/17/trumps-false-claim-that-who-said-coronavirus-was-not-communicable/>
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- Jonathan, W., & Niko, K. (2020). Coronavirus pandemic leading to huge drop in air pollution. *The Guardian*. Retrieved from <https://web.archive.org/web/20200517062638/https://www.theguardian.com/>

environment/2020/mar/23/coronavirus-pandemic-leading-to-huge-drop-in-air-pollution

- Kao, J.-J., & Huang, S.-S. (2000). Forecasts using neural network versus Box-Jenkins methodology for ambient air quality monitoring data. *Journal of the Air & Waste Management Association*, 50(2), 219-226.
- MERRIT, K. (2020). WHO Declares Coronavirus Outbreak A Global Health Emergency. *NPR*. Retrieved from <https://web.archive.org/web/20200516040848/https://www.npr.org/sections/goatsandsoda/2020/01/30/798894428/who-declares-coronavirus-outbreak-a-global-health-emergency>
- Mostafa, M. M. (2004). Forecasting the Suez Canal traffic: a neural network analysis. *Maritime Policy & Management*, 31(2), 139-156.
- Nabipour, M., Nayyeri, P., Jabani, H., Shahab, S., & Mosavi, A. (2020). Predicting stock market trends using machine learning and deep learning algorithms via continuous and binary data; a comparative analysis. *IEEE Access*, 8, 150199-150212.
- Nam, K., & Schaefer, T. (1995). Forecasting international airline passenger traffic using neural networks. *The Logistics and Transportation Review*, 31(3), 239-252.
- Omran, N. F., Abd-el Ghany, S. F., Saleh, H., Ali, A. A., Gumaei, A., & Al-Rakhami, M. (2021). Applying deep learning methods on time-series data for forecasting COVID-19 in Egypt, Kuwait, and Saudi Arabia. *Complexity*, 2021.
- Rachel, C. (2020). Coronavirus and the Black Death: spread of misinformation and xenophobia shows we haven't learned from our past. *The Conversation*. Retrieved from <https://web.archive.org/web/20200503023736/https://theconversation.com/coronavirus-and-the-black-death-spread-of-misinformation-and-xenophobia-shows-we-havent-learned-from-our-past-132802>
- Tian, Y., Luthra, I., & Zhang, X. (2020). Forecasting COVID-19 cases using Machine Learning models. *MedRxiv*.
- WHO. (2020a). Pneumonia of unknown cause – China. *World Health Organization*. Retrieved from <https://web.archive.org/web/20200519015241/https://www.who.int/csr/don/05-january-2020-pneumonia-of-unkown-cause-china/en/>
- WHO. (2020b). Statement on the second meeting of the International Health Regulations (2005) Emergency Committee regarding the outbreak of novel coronavirus (2019-nCoV). *World Health Organization*. Retrieved

from

[https://web.archive.org/web/20200131005904/https://www.who.int/news-room/detail/30-01-2020-statement-on-the-second-meeting-of-the-international-health-regulations-\(2005\)-emergency-committee-regarding-the-outbreak-of-novel-coronavirus-\(2019-ncov\)](https://web.archive.org/web/20200131005904/https://www.who.int/news-room/detail/30-01-2020-statement-on-the-second-meeting-of-the-international-health-regulations-(2005)-emergency-committee-regarding-the-outbreak-of-novel-coronavirus-(2019-ncov))

- WHO. (2020c). WHO Director-General's opening remarks at the media briefing on COVID-19 - 11 March 2020. *World Health Organization*. Retrieved from

<https://web.archive.org/web/20200519064740/https://www.who.int/dg/speeches/detail/who-director-general-s-opening-remarks-at-the-media-briefing-on-covid-19---11-march-2020>

- WHO. (2020d). WHO Director-General's remarks at the media briefing on 2019-nCoV on 11 February 2020. *World Health Organization*. Retrieved from

<https://web.archive.org/web/20200518010545/https://www.who.int/dg/speeches/detail/who-director-general-s-remarks-at-the-media-briefing-on-2019-ncov-on-11-february-2020>

- Worldometers. (2020). Worldometers-COVID-19 Coronavirus Pandemic. *Worldometers*, 2020(Januaray 17). Retrieved from [https://www.worldometers.info/coronavirus/?utm_campaign=homeAdvegas1?%20\(accessed%20January%2017,%202020\)](https://www.worldometers.info/coronavirus/?utm_campaign=homeAdvegas1?%20(accessed%20January%2017,%202020))

- Yee, V. P. (1998). *Regularized radial basis function networks: theory and applications to probability estimation, classification, and time series prediction*. (PhD). McMaster University, , Hamilton, Ontar.

- Zagrouba, R., Khan, M. A., Atta Ur, R., Muhammad Aamer, S., Muhammad Faheem, M., Rehman, A., & Muhammad Farhan, K. (2021). Modelling and simulation of COVID-19 outbreak prediction using supervised machine learning. *Computers, Materials, & Continua*, 2397-2407.