

تحسين التنبؤ بدرجة خطورة حالة المرضى المصابين بالفيروس التاجي كورنا

د.م. فطمة الطراب¹ ، أ.د. عصام الأمين² ، م. دعاء حمرة³

الملخص

خلفية البحث وهدفه: رغم مرور أكثر من عامين على بداية انتشار فيروس كورونا لا تبدو المؤشرات على أن الجائحة على وشك الرحيل بالرغم من حملات اللقاحات الضخمة والإجراءات ضد هذا الوباء، وكذلك توافر اختبارات اكتشاف العدوى مبكراً.

وقدم خلال السنستان الماضيتان نماذج متعددة للتعلم العميق باستخدام الشبكات العصبية للوصول إلى نماذج آلية سريعة تساعد في الكشف عن الحالات المصابة بمرض فيروس كورونا كوفيد 19، واعتمد الباحثون فيها على مجموعة كبيرة من السمات.

يهدف البحث إلى تخفيض عدد هذه السمات مع المحافظة على أداء المصنف ومعرفة أهم السمات التي تساعد في كشف درجة خطورة الإصابة بهذا المرض وفق حالات الشفاء والوفاة من أجل إيقاف انتقال المرض وانتشاره وخاصة في أماكن العمل الشديدة الخطورة مثل بيئات العمل في الرعاية الصحية.

مواد البحث وطرائقه: استخدمت الخوارزميات الآتية لتخفيض السمات: خوارزمية Boruta، خوارزمية الوراثية، خوارزمية الجار الأقرب KNN، معامل Ridge مع الشبكات العصبية، ونوقشت كل منها وفقاً لعدد السمات المستخلصة في كل طريقة.

النتائج: أظهرت النتائج أن كل خوارزميات الاستخلاص تتفق بسمة العمر كأهم سمة لتزايد خطر الإصابة بفيروس كورونا. وأن ارتفاع درجة الحرارة سمة مشتركة بدرجات أهمية مختلفة بين خوارزميات الاستخلاص. كما أن السعال وارتفاع السوائل وعدد العدلات تلعب دوراً مهماً في ازدياد احتمال الإصابة بفيروس كورونا.

الاستنتاج: إن أقل عدد من السمات التي ساعدت في كشف خطورة حالة المرضى للإصابة بفيروس كورونا مع البقاء على دقة أداء الشبكة في كشف الإصابة هو ثلاثة سمات حسب كل من الخوارزميات خوارزمية Ridge ومعامل Boruta، بينما أكبر عدد من السمات هو خمسة وذلك حسب كل من الخوارزمية الوراثية وخوارزمية الجار الأقرب KNN.

كلمات مفتاحية: كوفيد19، الخوارزمية الجينية، الشبكات العصبية، خوارزمية الجار الأقرب KNN.

¹ مدرسة - قسم أمراض وجراحة الأنف والأذن والحنجرة والوجه والعنق - كلية الطب البشري - جامعة دمشق .
eng.fatmah.tarab@gmail.com

² أستاذ مساعد - قسم أمراض وجراحة الأنف والأذن والحنجرة والوجه والعنق - كلية الطب البشري - جامعة دمشق .

³ باحثة - قسم الهندسة الطبية- كلية الهمك - جامعة دمشق .

Improving the prediction of the severity of the condition of patients infected with the Corona virus

Dr.Fatmah Tarrab⁴, Dr.Isam Alamin⁵, Eng. Doaa Hmra⁶

Abstract

Background and aim: Although more than two years have passed since the beginning of the spread of the Corona virus, there are no indications that the pandemic is about to leave, despite the massive vaccination campaigns and measures against this epidemic, as well as the availability of tests to detect infection early.

During the past two years, were multiple models of deep learning using neural networks presented to reach rapid automated models that help detect cases of COVID-19, and researchers relied on a wide range of features.

This research aims to reduce the number of these features while keeping the performance of the classifier intact and knowing the most important features that help in detecting the degree of risk of infection according to the cases of recovery and death in order to stop the transmission and spread of the disease, especially in high-risk workplaces such as work environments in health care.

Materials and methods: The following algorithms were used for feature reduction: Boruta algorithm, genetic algorithm, KNN algorithm and Ridge coefficient with neural networks, and each of them was discussed according to the number of features extracted in each method.

Results: The results showed that all the extraction algorithms agreed about the age as the most important for the increased risk of infection with COVID-19. The high temperature is a common feature with various degrees of importance among the extraction algorithms. In addition, coughing, fluid leaching and the number of neutrophils play an important role in increasing the possibility of infection with the Corona virus.

Conclusion: The least number of features that helped in detecting the severity of the patients' case of infection is three according to (the Boruta algorithm and the Ridge coefficient), while the largest number of features is five, according to both the genetic algorithm and the KNN algorithm.

Keywords: COVID-19, genetic algorithm, neural networks.

4 Lecturer in ENT Department -Faculty of Medicine-Damascus University.

5 Associated Professor in ENT Department -Faculty of Medicine-Damascus University.

6 Researcher – Department of Biomedical Engineering- Faculty of Mechanical &Electrical Engineering - Damascus University.

1-المقدمة:

والتقرير الطبي لموجودات الصور الشعاعية للصدر السينية والطبقي المحوري بالإضافة إلى نتائج اختبارات تحليل الدم ، وأظهرت النتائج كفاءة النموذج التصنيفي المقترن في التنبؤ بحالات الشفاء والوفاة بأعلى أداء تصنيف بدقة 95.9% [8] .

وتحققت النماذج السابقة نجاحاً، واعتمد الباحثون فيها على مجموعة من السمات يتم الحصول عليها من صور الأشعة السينية والمقطوعية المحورية للصدر (CT) أو من السمات الديموغرافية وبعض الأعراض السريرية والفيزيولوجية للمرضى بالإضافة إلى نتائج اختبارات تحليل الدم.

يهدف هذا البحث إلى تخفيف عدد هذه السمات مع المحافظة على أداء المصنف ومعرفة أهم السمات التي تساعد في كشف درجة خطورة الإصابة بهذا المرض وفق حالات الشفاء والوفاة من أجل إيقاف انتقال المرض وانتشاره وخاصة في أماكن العمل الشديدة الخطورة مثل بيئات العمل في الرعاية الصحية وذلك عن طريق استخدام خوارزميات تخفيف الأبعاد عن الشبكات العصبية في استخلاص السمات.

2-الطرق المستخدمة في البحث:

فيما يلي مخطط صندوقى لام مراحل العمل خلال هذا البحث، حيث يبدأ بتأمين قاعدة البيانات ومعالجتها ثم مرحلة تخفيف الأبعاد من خلال أربعة خوارزميات وبعدها مرحلة الحصول على النتائج ومناقشتها. فيما يلي مخطط صندوقى لام مراحل العمل خلال هذا البحث المبين في الشكل (1).

2-1 قاعدة البيانات وتهيئتها:

استخدمنا في هذه الدراسة مجموعة بيانات لـ (100) مريض من كلا الجنسين، وتم تأكيد تشخيص إصابتهم بمرض فيروس كورونا كوفيد 19 من خلال إيجابية


رغم مرور أكثر من عامين على بداية انتشار فيروس كورونا لا تبدو المؤشرات على أن الجائحة على وشك الرحيل بالرغم من حملات اللقاحات الضخمة والإجراءات ضد هذا الوباء، وكذلك توافر اختبارات اكتشاف العدوى مبكرا.

إن العقبة الرئيسية في السيطرة على انتشار هذا المرض هو عدم الكفاءة في الكشف المبكر عن هذا المرض وخاصة في الأشخاص الذين لا يعانون من أي اعراض [1,2].

وقد أظهرت الدراسات الحديثة بمجرد أن يبدأ نقاشي مرض فيروس كورونا كوفيد 19 سيستغرق أقل من أربعة أسابيع لتقتلى المشافي بالحالات المصابة وتطغى على نظام الرعاية الصحية ويزداد عدد الوفيات[4]. مما يستدعي البحث عن آلية فعالة في الكشف المبكر عنه من أجل إيقاف انتقال المرض وانتشاره وخاصة في أماكن العمل الشديدة الخطورة مثل بيئة العمل في الرعاية الصحية.

وقدم خلال السنستان الماضيتان نماذج متعددة للتعلم العميق باستخدام الشبكات العصبية للوصول إلى نماذج آلية سريعة تساعد في الكشف عن الحالات المصابة بمرض فيروس كورونا كوفيد 19 في صور الأشعة المقطوعية المحورية للصدر (CT) وفي صور الأشعة السينية البسيطة للصدر [3-5] .

كما قامت أبحاث أخرى في تصنيف حالات الإصابة بمرض فيروس كورونا حسب درجة العدوى بالاعتماد على قواعد البيانات المتاحة عن المرضى المصابين باستخدام صور الأشعة المقطوعية المحورية للصدر [6,7] ، وفي دراسة حديثة تم تقديم نموذج تنبؤ تصنيفي باستخدام الشبكات العصبية للتنبؤ بدرجة خطورة الحالة المصابة بمرض فيروس كورونا كوفيد 19 ، حيث يتوقع النموذج المقترن مخاطر الوفيات على أساس المعلومات الديموغرافية والأعراض الفيزيولوجية للمرضى



الشكل (1) مخطط صندوقى لام مرحل العمل خلال هذا البحث

الجدول (1) السمات المدروسة وعددها (15)

في قاعدي البيانات

السمات	
العمر	المعلومات الديموغرافية
الجنس	
درجة الحرارة	
نسبة الاشبع بالاكسجين	الأعراض الفيزيولوجية
الحمى	
السعال	
ضيق التنفس	
عدد الكريات البيضاء WBCs	الاختبارات الدموية
عدد العدالت	
عدد المقاوميات	
ارتشاح السوائل	
العنامة الخالية	موجودات الصور
الاندماج السنخي	الشعاعية للصدر
سمكية البنية النسيجية	
السكري، أمراض القلب والأوعية الدموية، ارتفاع ضغط الدم، أمراض الكلى	وجود أحد هذه الأمراض المزمنة المصاحبة

وفي مرحلة تنظيف البيانات، أزلينا عناصر البيانات غير المفيدة والمتركرة، بالإضافة إلى البيانات غير الكاملة والمفقودة. وتم اختيار (49) مريض من مستودع GitHub بمتوسط عمر (57) من كلا الجنسين (31) ذكور و (18) إناث بنسبة (40.9%) حالة وفاة و (59.1%) حالة شفاء، و (51) مريض

تفاعل سلسلة البوليميراز العكسي (Reverse transcription polymerase chain reaction) . وهذه البيانات قسم منها مأخوذ من قاعدة بيانات خاصة بصور الأشعة السينية للصدر وكذلك الطبقي المحوري لـ(586) مريض من مستودع GitHub [15-16]. يتتألف هذا المستودع من صور بالأشعة السينية / التصوير المقطعي المحوسب للمرضى الذين يعانون بشكل رئيسي من عدة متلازمات للأمراض التنفسية وهي: متلازمة الضائقة التنفسية الحادة ARDS، كوفيد 19 COVID-19، متلازمة الشرق الأوسط التنفسية (MERS)، الالتهاب الرئوي، المتلازمة التنفسية الحادة الوخيمة (SARS). والقسم الثاني من البيانات تم الحصول عليه من تقارير المرضى بمشفى الموسعة الجامعي. وتتضمن قاعدي البيانات العديد من المتغيرات بما في ذلك المعلومات الديموغرافية والأعراض الفيزيولوجية بالإضافة إلى الاختبارات الدموية والتقارير الطبية لموجودات الصور الشعاعية والملحوظات السريرية والتي تتضمن الأمراض المزمنة والقصة السريرية للمرضى واستخلصنا منها (15) متغير (سمة) كما هو موضح في الجدول (1).

- بوضع جميع أفراد الجيل القديم في مجموعة، واختيار المناسب منها حسب قيمه الملاعمة.
- **الزواج أو العبور (Crossover):** ويتم فيها المزاوجة بين كروموسومين (Parents) وتوريث الجينات لتشكل كروموسومين جديدين (Offsprings).
- **الطفرة (Mutation):** وهي المرحلة الأخيرة وتسهم بشكل جيد في الوصول إلى الحل الأمثل، حيث أن حدوث تغير مفاجئ غير متوقع (عشوائي) في الجيل يكون له تأثير إيجابي في الاقتراب من الحل الأمثل.
- وتحت هذه العمليات بشكل عشوائي وبنسبة معينة. يتم تمثيل مجموعة فرعية من المميزات بكروموسوم ويكون من n ، حيث n هو عدد المميزات في هذا الكروموسوم، وكل جين أو عنصر في الكروموسوم تشير إلى ميزة من المميزات. لاستخدام الخوارزمية الجينية تقوم في البداية بإنشاء مجتمع عشوائي من الكروموسومات أو الأفراد، وتقوم الخوارزمية بقييم أداء كل كروموسوم. واستناداً إلى نتائج المجتمع الأول تتطور الخوارزمية من خلال عمليات الانتقاء، والتنقاطع، والطفرة (ويتم تحديد طول الكروموسوم وعددتها في المجتمع بشكل عشوائي). حيث تعمل هذه العمليات على تعديل هذا المجتمع وتوليد مجتمع جديد. حيث تم بناء الخوارزمية بالاعتماد على البارامترات التالية:

Population size=50, Number pf generation=50, Elitism=5, number of iteration=11, Fitness Function=Roc/Vars , number of variable in chromosome=12, Crossover rate=0.7, Mutation Rate=0.03, maxiter=50.

2-2-4-خوارزمية الجار الأقرب : (KNN)K-Nearest Neighbors

هي خوارزمية بسيطة تخزن جميع الحالات المتاحة لديها من بيانات التدريب وتصنف الحالات الجديدة

من مشفى الموسعة الجامعي بمتوسط عمر (48) وبنسبة (53%) ذكور و(47%) إناث بنسبة (7.8%) حالة وفاة و(92.2%) حالة شفاء، وتأكدت إصابتهم بكورونا 19 ولديهم جميع المعلومات المطلوبة في هذه الدراسة.

2-2 تطبيق تقنيات تخفيف الأبعاد

استخدمت أربعة تقنيات لتخفيف الأبعاد للوصول إلى عدد مناسب للميزات. وهي:

2-2-1-خوارزمية Boruta

تعتمد على إجراء العديد من خوارزميات الغابات العشوائية، نسب أهمية جميع السمات لكل تشغيل. ومن ثم إجراء اختبار إحصائي لجميع السمات Two-Sided Equality Test لرفض وقبول السمات [10].

2-2-2-معامل انحدار (Ridge): تعد Ridge من التقنيات القوية المستخدمة عموماً لإنشاء نماذج بارزة في وجود عدد كبير من الميزات [11]. يضيف معامل تصحيح (plenty) يعادل مربع مطال المعاملات (الأوزان)، من خلال تابع (التكلفة) المعطى في المعادلة (1):

$$\text{cost}(w) = \sum_{i=1}^N \left\{ y_i - \sum_{j=0}^M w_j x_{ij} \right\}^2 + \lambda \sum_{j=0}^M w_j^2$$

λ هي المعلمة التي تحقق التوازن بين مجموع المرءات المتبقية (residual sum of squares) و مجموع مربعات الأوزان. وكانت أفضل قيمة لها $1 = \lambda$.

2-2-3-الخوارزمية الوراثية : (Genetic Algorithm)

تمر الخوارزمية الجينية بثلاث مراحل مهمة [12]:

- انتقاء الوالدين (Parent Selection): وهي المرحلة الأولى حيث يتم اختيار الجيل الجديد


3-النتائج ومناقشتها:

تم تخفيض عدد السمات الى عدد أصغر، وخالف العدد باختلاف الطريقة المستخدمة.

1-نتائج خوارزمية Boruta:

اختارت خوارزمية **Boruta** السمات التالية كأهم السمات التي تلعب دوراً مهماً في ظهور covid19 وهي العمر والسعال والحمى كما يبين الشكل (2).

حسب أغلبية جيرانها، وذلك عن طريق وظيفة حسابية لقياس المسافة بينهم. يمثل مصنف الجار الأقرب كل كائن نقطة بيانات في فراغ أبعاده d ، حيث أن d هو عدد السمات. فإذا كان لدينا كائن اختبار. فإننا نحسب قربته (proximity) إلى بقية نقاط البيانات في مجموعة الاختبار وذلك باستخدام مقاييس التشابه [13]. وقد تم بناء الخوارزمية باختيار $k=33$ وتتابع التشابه هو المسافة الإقليدية.



الشكل (2) نتائج استخدام خوارزمية Boruta

الجدول(2) نتائج استخدام الخوارزمية الوراثية

features	importance
age	100%
infiltrate	100%
fever	66.7%
p02_saturation	66.7%
neutrophil_count	66.7%


2-3 نتائج الخوارزمية الوراثية : (Genetic Algorithm)

سمحت الخوارزمية الجينية بخفض عدد السمات الى خمسة سمات وهي العمر وارتفاع السوائل والحمى وعدد العدارات وتشبع po2 كما يظهر في الجدول (2).

معامل Ridge وهي العمر(1) وارتشاح السوائل (0.17) والسعال (0.12)

3-3 نتائج معامل Ridge

تم خفض عدد السمات من خلال عامل مستوى الامانة الى ثلاثة سمات بنسب اهمية متفاوتة. وبين الشكل(3) مقدار اهمية السمات من خلال



الشكل (3) نتائج استخدام معامل Ridge

2. إن ارتفاع درجة الحرارة سمة مشتركة بدرجات أهمية مختلفة بين خوارزميات الاستخلاص.

3. إن السعال وارتشاح السوائل وعدد العدارات تلعب دوراً مهماً في ارتفاع احتمال الإصابة بفيروس كورونا.

4- نتائج تصنيف الشبكات العصبية قبل وبعد استخلاص السمات:

تم بناء الشبكة بحيث احتوت طبقة الدخل على 15 عقدة والطبقة الخفية تضمنت طبقتين في كل منها العصبونات التالية على الترتيب (5 و2) عند عتبة قدرها 0.01 وطبقة خرج واحدة وذلك عند التعامل مع كامل قاعدة البيانات أي قبل استخلاص السمات أما بعد استخلاص السمات فقد تم بناء الشبكة بطبقة دخل وهو عدد السمات الناتجة عن خوارزمية الاستخلاص و2 طبقة خفية في كل منها العصبونات التالية على الترتيب (5,1) وبعتبة قدرها (0.01). حيث تم تقسيم البيانات 70% تدريب و30% اختبار ويظهر الجدول (4) نتائج التصنيف

4-3 نتائج خوارزمية الجار الأقرب KNN:

عند استخدام خوارزمية الجار الأقرب KNN ملاحظة خفض عدد السمات الى خمسة سمات بحسب مستوى الأهمية إلى العمر والسعال والحمى والقصبة السيريرية وعدد المفيات كما يظهر في الجدول (3).

الجدول(3) نتائج استخدام خوارزمية الجار الأقرب

KNN

features	Importance
age	100.000
cough	47.902
fever	32.517
medical.history	23.776
leukocyte_count	22.378

5- العوامل المشتركة بين المورثات المستخلصة:

1. تتفق كل خوارزميات الاستخلاص بسمة العمر كأهم سمة لتزايد خطر الإصابة بفيروس كورونا.

من خلال الشبكات العصبية قبل وبعد استخلاص السمات .

الجدول (4) التصنيف من خلال الشبكات العصبية قبل وبعد استخلاص السمات

الدقة Accuracy	النوعية Specificity	الحساسية Sensitivity	الخوارزمية Algorithm	
0.956	0.95	0.95	الشبكات العصبية MLP	قبل استخلاص السمات
0.95	1.0000	0.9333	الشبكات العصبية Boruta + MLP	بعد استخلاص السمات
1	1	1	+GA MLP	الشبكات العصبية
1	1	1	+KNN MLP	الشبكات العصبية
0.8	1	0.5	+Ridge MLP	الشبكات العصبية

6- خلاصة:

يسهم هذا البحث في تحديد أهم السمات لدرجة خطورة الإصابة بفيروس كورونا باستخدام الشبكات العصبية مع خوارزميات تخفيف السمات، وأظهرت النتائج أن كل خوارزميات الاستخلاص تتفق بسمة العمر كأهم سمة لتزايد درجة خطورة حالة المرضى المصابين بفيروس كورونا، وأن ارتفاع درجة الحرارة سمة مشتركة بدرجات أهمية مختلفة بين خوارزميات الاستخلاص. كما أن السعال وارتجاع السوائل وعدد العدلات تلعب دوراً مهماً في زيادة احتمال درجة خطورة حالة المرضى المصابين بفيروس كورونا.

5- أداء تصنيف الشبكات العصبية قبل وبعد استخلاص السمات:

تم الوصول إلى دقة جيدة عند إدخال كافة السمات إلى الشبكة العصبية ولكن بعد تخفيف السمات بالطرق الموجودة تم الوصول إلى دقة أعلى، ومن ذلك نستنتج أن الصفات المستخلصة من أغلب الطرق ذات أهمية كبيرة وتعبر عن قاعدة البيانات هذا ما أدى بدوره إلى تخفيف الكلفة وزيادة سرعة المعالجة، إلا أننا نلاحظ انخفاض دقة خوارزمية الشبكة العصبية بعد استخلاص السمات بطريقة ridge وذلك لأن عدد السمات كان قليل ثلاثة سمات فقط مقارنة مع باقي الطرق المستخدمة سمة لم تكن موجودة عند باقي الطرق المستخدمة ذات أهمية أقل مقارنة بباقي السمات.

المراجع:

- [1] World Health Organization. Novel Coronavirus (2019-nCoV) situation reports.
- [2] Chung M, et al (2020) CT imaging features of 2019 Novel Coronavirus (2019-NCov). Radiology, p. 200230. DOI.org (Crossref).
- [3] Ozcan, T. (2020). A Deep Learning Framework for Coronavirus Disease (COVID-19) Detection in X-Ray Images.
- [4] Trent McConghy, Bruce Pon, Eric Anderson (2020),“When does Hospital Capacity Get Overwhelmed in USA? Germany? A model of beds needed and available for Coronavirus patients” trent.st.
- [5] Ozturk, T., Talo, M., Yildirim, E. A., Baloglu, U. B., Yildirim, O., & Acharya, U. R. (2020). Automated detection of COVID-19 cases using deep neural networks with X-ray images. Computers in Biology and Medicine, 103792.
- [6] Singh, D., Kumar, V., & Kaur, M. (2020). Classification of COVID-19 patients from chest CT images using multi-objective differential evolution-based convolutional neural networks. European Journal of Clinical Microbiology & Infectious Diseases, 1-11.
- [7] Pourhomayoun, M., & Shakibi, M. (2020). Predicting mortality risk in patients with COVID-19 using artificial intelligence to help medical decision-making. medRxiv.
- [8] د. م. فطمة الطراب. (2021). التنبؤ بدرجة خطورة حالة المرضى المصابين بالفيروس التاجي كورونا باستخدام الشبكات العصبية. مجلة جامعة دمشق للعلوم الهندسية.(4), 37(4).
- [9] <https://github.com/UCSD-AI4H/COVID-CT>.
- [10] KURSA ,M., RUDNICKI,W., 2010- Feature Selection with Boruta Package, Journal of Statistical Software, vol. 36, 1–13pp.
- [11] OGUTU, J. O., SCHULZ-STREECK, T., PIEPHO, H. P. 2012-Genomic selection using regularized linear regression models: ridge regression, LASSO, elastic net and their extensions. In BMC proceedings ,Vol. 6, No. 52, S10 p.
- [12] L. Haldurai., T, Madhubala., R, Rajalakshmi ,2016- A Study on Genetic Algorithm and its Applications. International Journal of Computer Sciences and Engineering,vol 4. 139-143pp.
- [13] NEGNEVITSKY, M., 2005- Artificial Intelligence, A guide to intelligent systems. 2nd edition, pearson Education..
- [14] U. S. N. L. o. M. R. P. M. U. National Center for Biotechnology Information, National Center for Biotechnology Information.
- [15] Huang C, Wang Y, Li X, et al. (2020),Clinical features of patients infected with 2019 novel coronavirus in Wuhan, China. Lancet.395(10223):497-506.
- [16] Lippi, G., & Plebani, M. (2020). Laboratory abnormalities in patients with COVID-2019 infection. Clinical Chemistry and Laboratory Medicine (CCLM), 58(7), 1131-1134