

## دراسة مقارنة لنتائج تشخيص مرض كوفيد-19 في اشعة الصدر السينية باستخدام بعض نماذج الشبكة العصبية التلافيفية

محمد علي بليلو\*

(تاريخ الإيداع 11 / 10 / 2020. قُبِلَ للنشر في 16 / 8 / 2021)

### □ ملخص □

يهدف البحث إلى تقديم إطار جديد لمفهوم التعلم العميق وأهميته في توفيره لتقنيات مختلفة تقدم المساعدة لأطباء الأشعة في تشخيص الإصابة بفيروس كورونا (Covid-19) في صور الصدر الشعاعية البسيطة ومن إحدى تقنيات التعلم العميق المستخدمة في البحث الشبكة العصبية التلافيفية Resnet50 وهي إحدى أنواع الشبكات العصبية الصناعية العميقة وإجراء مقارنة بنتائج أبحاث حول الموضوع نفسه تمت على شبكات عصبية صناعية أخرى. تمت عملية الحصول على الصور الشعاعية من قاعدة بيانات D. Joseph Paul Cohen البروفيسور في جامعة مونتريال وهي متاحة على الشبكة العالمية على موقع github مجاناً ومحدثة دائماً بصور جديدة. تتضمن عدد كبير من الصور الشعاعية البسيطة والتصوير المقطعي المحوسب للصدر وبأبعاد مختلفة لأشخاص طبيعيين ولمرضى يعانون بشكل أساسي من متلازمات تنفسية مختلفة من ضمنها فيروس كورونا.

تم دراسة الخطوات العملية في البحث من خلال صندوق أدوات DeepLearning في MATLAB 2018B على جهاز لابتوب بمعالج 2 غيغا هرتز ثنائي النواة وذاكرة 4 غيغابايت حيث أظهرت النتائج 98.1% من الدقة و100% من الحساسية.

**الكلمات المفتاحية:** تعلم عميق، رؤية حاسوبية، شبكة عصبونية تلافيفية، فيروس كورونا، ذكاء صناعي، تعلم تمثيلي، تعلم الميزة، تعلم آلي.

\*مشرف بالأعمال - قسم هندسة الحاسبات والتحكم الآلي - كلية الهندسة الميكانيكية والكهربائية - جامعة تشرين - اللاذقية - سورية.

## **A Comparative Study of the Results of the Diagnosis of Covid-19 Disease in Chest x-ray Using Some Models of Convolutional Neural Network**

**Mohammad Ali Blailo\***

**(Received 11 / 10 / 2020. Accepted 16 / 8 / 2021)**

### **□ ABSTRACT □**

Economic literature

The research aims to provide a new framework for the concept of deep learning and its importance in providing various techniques that provide assistance to radiologists in diagnosing infection with the Corona virus (Covid-19) in simple chest radiographs from one of the deep learning techniques used in research, the convolutional neural network Resnet50, which is one of the types of neural networks and comparison of results with research results on the same topic conducted on other artificial neural networks.

The x-rays were obtained from the database of D. Joseph Paul Cohen, Professor at the University of Montreal, which is available on the World Wide Web on github free of charge and always updated with new images. It includes a large number of simple radiographs and computed tomography of the chest with different dimensions of normal people and patients who mainly suffer from various respiratory syndromes, including the Corona virus.

The practical steps in the research were studied through the DeepLearning toolbox in MATLAB 2018B on a laptop with a 2 GHz dual-core processor and 4 GB memory, the results showed 98.1% accuracy and 100% sensitivity

**Keywords:** Deep learning (DL), computer vision, convolutional neural network (CNN), corona virus, artificial intelligence (AI), Representation Learning, Feature Learning, Machine Learning(ML).

---

\* Work Supervisor, Department of Computer and Automatic Control, Faculty of Mechanical and Electrical Engineering, Tishreen University, Lattakia Syria.

**مقدمة:**

تعتبر الفيروسات التاجية (CoV) عائلة كبيرة من الفيروسات الخطيرة [3]. واكتسبت تسميتها بسبب ظهورها بشكل يشبه التاج عند ملاحظتها تحت المجهر الإلكتروني [4]. وتسبب هذه الفيروسات أمراضاً شديدة ومعديّة كمتلازمة الالتهاب الرئوي الحاد (SARS-CoV) ومتلازمة الشرق الأوسط التنفسية (MERS-CoV)، وآخر الفيروسات التي تم رصدها وتسميتها هو فيروس كورونا (Covid-19) الذي تم تشخيصه كفيروس جديد في مدينة ووهان الصينية في أواخر تشرين الثاني من عام 2019 بؤرة ظهور الفيروس ثم جائحة عالمية كما أعلنته منظمة الصحة العالمية في 11 فبراير 2020. يعتبر اختبار تفاعل البوليميراز المتسلسل في الوقت الحقيقي (RT-PCR) للبلغم المعيار الذهبي لتشخيص فيروس كورونا، وهو اختبار يستغرق وقتاً طويلاً لتأكيد الإصابة بـ COVID-19 [1]. لذلك يمكن أن تلعب طرق التصوير الطبي كالأشعة السينية للصدر (CXR) والتصوير المقطعي المحوسب (CT) دوراً رئيسياً في تأكيد الإصابة بالفيروس خاصة في حالات النساء الحوامل والأطفال المصابين [2,6].

تعتبر صور الأشعة السينية للصدر (CXR) الخيار الأول للأطباء لاكتشاف أمراض الصدر وذلك لأن التصوير المقطعي المحوسب (CT) ذو تكاليف أعلى بكثير [13]. إضافة لتوافر أجهزة التصوير الشعاعي التقليدية (CXR) في جميع المستشفيات والعيادات لإنتاج صور إسقاط ثنائية الأبعاد (2D) لصدر المريض. وقد تم تطبيقها لتأكيد الإصابة بالمرض أو نفيها في عدد صغير من المرضى [2، 9]. لهذا السبب كان البحث الذي سيركز فقط على استخدام طريقة التصوير بالأشعة السينية (CXR) لمرضى COVID-19 المحتملين.

ومع ذلك فإن صور الأشعة السينية لا يمكنها بسهولة تمييز الأنسجة الرخوة مع تباين ضعيف لتحديد نسبة التعرض للمرض [7,10]. وللتغلب على هذه القيود تم تطوير أنظمة التشخيص بمساعدة الكمبيوتر (CAD) لمساعدة الأطباء على الكشف التلقائي عن الأمراض المشتبه فيها للأعضاء الحيوية وتحديدتها في صور الأشعة السينية.

**الذكاء الصناعي والتعلم العميق**

يعرف التعلم الآلي بأنه أحد مجالات الذكاء الصناعي ويتضمن عدة فروع منها التعلم العميق باستخدام الشبكات العصبية الاصطناعية من خلال التدريب على الاكتشاف التلقائي للسمات أو تصنيف البيانات من خلال سمات محددة مسبقاً [16].

**الشبكة العصبية التلافيفية (Convolutional Neural Network (ConvNet / CNN))**

إحدى خوارزميات التعلم العميق الخاصة بالشبكات العصبونية العميقة تعتمد بنية الشبكات العصبية ذات التغذية الأمامية وهي مشابهة لشبكة برسيبترون متعددة الطبقات إلا أن الاختلاف يكمن فيما تتعلمه الشبكة وكيف تُبنى وماهية الهدف المنشود منها واكتسبت هذه الشبكات اسمها من طبيعة عملها حيث أنها تستخدم طبقات التفاضلية حيث يستخدم مبدأ الالتفاف الرياضي والذي يشير إلى عملية جمع بين دالتين وينتج دالة جديدة منهما.

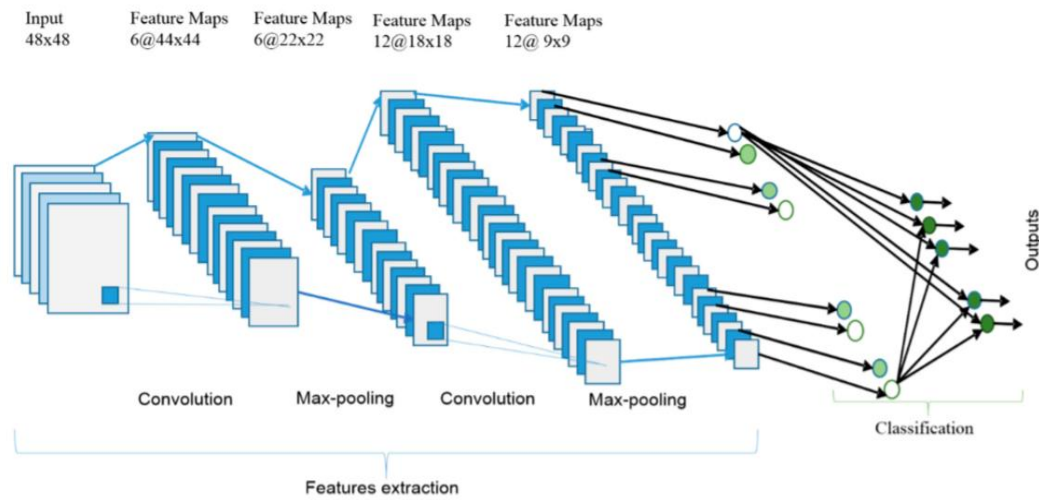
عادةً ما تُستخدم شبكات CNN في تطبيقات الرؤية الحاسوبية وتحليل المشاهد المرئية إذ تتميز بوجود طبقة مخفية واحدة أو أكثر من شأنها استخراج السمات الموجودة في الصور أو مقاطع الفيديو وطبقة كاملة الارتباط لإنتاج الخرج المطلوب وبالتالي فهي تتعامل مع الصورة كدخل لها، تهتم بالأوزان القابلة للتعلم والانحيازات التابعة لمعاملات الصورة المختلفة وتكون قادرة على التمييز بين بعضها البعض.

تم اقتراح بنية الشبكة لأول مرة من قبل Fukushima في عام 1988 [5]. ومع ذلك لم يتم استخدامها على نطاق واسع بسبب القدرة المحدودة للعتاد الصلب للحواسيب على تدريب الشبكة، وفي تسعينات القرن الماضي قام LeCun وآخرون بتطبيق خوارزمية التعلم على أساس التدرج على شبكات CNNs وحصلت على نتائج ناجحة لحل مشكلة

التصنيف الرقمي المكتوب بخط اليد، وبعد ذلك قام الباحثون بتحسين شبكات CNNs وأبلغوا عن نتائج متطورة في العديد من مهام التعرف [5].

تتضمن بنية CNNs كما الشكل (1) جزأين رئيسيين:

- جزء استخلاص السمات وهو مزيج نوعين من الطبقات في المستوى المنخفض والمتوسط من الشبكة، طبقة الالتفاف Convolutional layers وطبقة التجميع الأقصى max-pooling layers، تعطى الأرقام الزوجية لطبقات الالتفاف في جزء استخلاص الميزات والأرقام الفردية لطبقات عمليات التجميع القصوى، تستقبل كل طبقة من شبكة طبقات استخلاص الميزات الخرج من الطبقة التي تسبقها مباشرة كدخل لها وتكرر خرجها كدخل إلى الطبقة التالية.
- جزء طبقة التصنيف.



الشكل (1): البنية العامة للشبكة العصبية التلافيفية

تتضمن عملية التصنيف في الشبكة العصبية الالتفافية أربع عمليات أساسية هي المكون الأساسي لكل الشبكات العصبية التلافيفية:


#### ١- الالتفاف أو الترشيح Convolution

إن الهدف الأساسي من عملية الالتفاف في حالة ConvNet هو استخراج الخصائص من الصورة المدخلة حيث إن عملية الالتفاف أو الترشيح تحتفظ بالعلاقة المكانية بين البكسلات في الصورة عن طريق تعلم خصائص الصورة باستخدام مرشح (filter) أو مصفوفة النواة (Kernel) على البيانات المدخلة.


يتعتبر المرشح filter أو مصفوفة النواة (kernel) أو محدد الخصائص (feature detector) مصفوفة ثنائية البعد تتعلق أبعادها بأبعاد الصورة المدخلة وينتج من تمرير مصفوفة النواة على المصفوفة الأصلية (الصورة المدخلة) مصفوفة جديدة تعرف باسم (الخصائص الملتفة convolved feature) أو (خريطة التنشيط Activation map) أو الاسم الأكثر شيوعاً (خريطة الخصائص feature map) مع التأكيد أن هذه المرشحات تعمل كمحدد للخصائص من الصورة المدخلة.

تختلف القيم الموجودة في مصفوفة المرشح تبعاً لنوع المرشح حيث أن كل نوع يقوم بتأثير معين على الصورة المدخلة واختيار المرشح.

- يحدد حجم خريطة الخصائص بثلاث معاملات اساسية يجب معرفتها قبل تنفيذ خطوة الالتفاف او الترشيح
- العمق (Depth) ويرمز إلى عدد المرشحات المستخدمة لعملية الالتفاف حيث أن كل مرشح سيولد خريطة خصائص مختلفة عن مرشح آخر، وستعدو الخرائط كأنها مصفوفات مرصوصة فوق بعضها البعض.
  - الخطوة التمريرية (Stride) وهي عدد البكسلات التي سنقوم باستخدامها عند تمرير مصفوفة المرشح على مصفوفة الصورة المدخلة، فعندما تكون قيمة الخطوة التمريرية واحد، فإننا نقوم بتحريك المرشح بكسل واحد فقط في كل مرة وعندما تكون القيمة 2 فإن المرشح يقفز بكسلان اثنان في كل مرة مع التنويه إلى أنه عندما يكون لدينا حجم كبير للخطوة التمريرية فهذا يعني الحصول على خرائط خصائص صغيرة الحجم.
  - التبطين الصفري (Zero-padding) وهي عملية تبطين مصفوفة الصورة المدخلة بأصفار حول اطرافها وبالتالي إمكانية القيام بتمرير مرشح على هذه الأطراف، والخصائص المستخرجة من عملية التبطين الصفري ستسمح لنا بالتحكم في حجم خرائط الخصائص، وتعرف عملية إضافة التبطين الصفري ايضا بالالتفاف العريض (convolutionwide) وعدم اضافته يعرف بالالتفاف الضيق (convolutionnarrow).
2. انعدام الخطية (Non Linearity) وهي عملية غير خطية تستخدم تابع تنشيط غير خطي يسمى تابع التصحيح الخطي (ReLU: Rectified Linear Unit)، يأخذ التابع قيمة الصفر إذا كانت قيمة الدخل أصغر من الصفر ويحافظ على قيمة الدخل نفسها إذا كانت أكبر أو تساوي الصفر كما في الشكل (2).
- تطبيق ReLU بعد كل عملية التفاف على مستوى العنصر للمصفوفة، أي تطبق لكل بكسل حيث تقوم باستبدال كل قيم البكسلات السالبة في خريطة الخصائص بالقيمة صفر بهدف بناء لاختية في الشبكة العصبية التلافيفية لأن معظم المشكلات الحقيقية تكون غير خطية وفي الأساس فإن عملية الالتفاف Convolution هي عملية خطية على مستوى العنصر في المصفوفة من ناحية عمليات الضرب والجمع، هذا ويوجد توابع تنشيط لاختية أخرى كدالة tanh أو sigmoid لكن ReLU أظهرت أداء افضل في معظم الحالات.
3. التجميع أو أخذ عينات فرعية Pooling or Subsampling
- هي عملية أخذ عينات فرعية subsampling أو اختزال downsampling يقوم بتقليص الأبعاد لكل خريطة خصائص مع اعتبار الإبقاء على المعلومات المهمة، ولعملية التجميع المكاني أنواع عدة أفضلها في إظهار النتائج عملية التجميع باستخدام اعلى قيمة (Max Pooling) ويتم فيها تجزئة خريطة الخصائص إلى مصفوفات بحجم 2x2 كما في الشكل (3) ثم يتم استخراج عنصر الصورة (البكسل) صاحب اعلى قيمة في الجزء المحدد من خريطة الخصائص المصححة، أما التجميع باستخدام قيمة المتوسط (Average Pooling) أو باستخدام المجموع (Sum Pooling) فيتم بحساب متوسط الاعداد في تلك النافذة فقط او مجموعهم في حال Sum على الترتيب.
- من مزايا عملية التجميع تقليص حجم مصفوفة الخصائص بشكل مستمر فهي قلصت ابعاد خريطة الخصائص من 4x4 إلى 2x2 كما في الشكل (3) مما يجعل تمثيل الدخل في مصفوفة الخصائص اصغر حجما من ناحية حجم ابعاد المصفوفة وبالتالي سهولة ادارتها.



الشكل (3): عملية Max Pooling على خريطة خصائص للصورة




الشكل (2): عملية الوحدة الخطية المصححة ReLU

#### 4. طبقة الاتصال الكاملة (Connected Layer Fully)


هي طبقة لتصنيف البيانات وتعتبر طبقة تقليدية متعددة الطبقات تستخدم تابع التنشيط (SoftMax) مع إمكانية استخدام دوال أخرى، ويشير مصطلح "كاملة الاتصال" إلى أن كل عصبون في الطبقة السابقة متصلة بكل عصبون في الطبقة التالية. يمثل الخرج من طبقتي الالتفاف والتجميع خصائص عالية المستوى للصورة المدخلة وتعمل الطبقة كاملة الاتصال على استخدام هذه الخصائص لعملية تصنيف الصورة المدخلة إلى عدة فئات بناء على تدريب البيانات [13,14]. أما الشبكة العصبية التلافيفية (ResNet(50) المستخدمة في البحث فهي إحدى أنواع شبكات Resnet والتي تعرف باسم شبكات الرواسب (residual Network) والوحدة الأساسية لهذه الشبكة موضحة كما في الشكل (4).

تسمى عملية تمرير الدخل إلى عقدة جمع باسم قفزة الرواسب وهذا هو الاختلاف عن الشبكات العصبية التقليدية، حيث يتم جمع الدخل  $x$  مع تابع  $F(x)$  وهو تابع الخرج لمجموعة من الطبقات غير الخطية ويعرف بتابع الرواسب أو خريطة الرواسب (residual mapping)، ويكون خرج الكتلة بعد تابع Relu هو التابع  $H(x)=F(x)+x$ ، أما هدف التدريب فهو تقريب قيمة تابع الرواسب  $F(x)$  من الصفر بحيث لا تقل الدقة مع تعمق الشبكة.

يتم في الشبكة العصبية التلافيفية Resnet50 تكديس 50 وحدة أساسية من Resnet لعمل 50 طبقة مع تغيير الكتلة الأساسية فينظرًا لزيادة وقت التدريب كما في الشكل (5).



الشكل (5): الكتلة الأساسية لشبكة Resnet50



الشكل (4): الكتلة الأساسية لشبكات Resnet

تتضمن الكتلة الأساسية في ResNet50 التفاف واحد فقط 3x3 بدلاً من اثنين كما في شبكات Resnet34، وتستخدم التفاف 1 × 1 لرسم خريطة بأبعاد أقل ثم إجراء التفاف 3 × 3 ثم إعادة تخطيطها إلى أبعاد أعلى وبهذه الطريقة سيكون وقت التدريب ثم تم استخدام التفاف 1x1.

ويمكن تقسيم بنية الشبكة التلافيفية 50 resnet كما في الشكل (6) إلى ستة مراحل كما يلي:

1. مرحلة طبقة التفاف أولى من 64 نواة مختلفة بحجم 7x7 بخطوة اختزال بحجم 2 تعطينا طبقة واحدة، ثم يلي ذلك طبقة تجميع أقصى مع حجم خطوة 2.
2. مرحلة طبقة التفاف ثانية يتضمن 64 نواة مختلفة بحجم 1x1 يتبع ذلك 64 نواة مختلفة بحجم 3x3 وأخيراً 256 نواة مختلفة بحجم 1x1، وتكرر المرحلة الثانية 3 مرات مما يمنحنا 9 طبقات في هذه الخطوة.
3. مرحلة طبقة التفاف ثالثة تتضمن 128 نواة مختلفة بأبعاد 1x1 يليها أيضاً 128 نواة مختلفة بأبعاد 3x3 وأخيراً 512 نواة مختلفة بأبعاد 1x1، ويتم تكرار هذه المرحلة 4 مرات مما يمنحنا 12 طبقة في هذه الخطوة.
4. مرحلة طبقة التفاف رابعة تتضمن 256 نواة مختلفة بأبعاد 1x1 يليها 256 نواة مختلفة بأبعاد 3x3 وأخيراً 1024 نواة بأبعاد 1x1 وتكرر هذه المرحلة 6 مرات مما يعطينا إجمالي 18 طبقة.
5. مرحلة طبقة التفاف خامسة تتضمن 512 نواة مختلفة بأبعاد 1x1 يليها 512 نواة مختلفة بأبعاد 1x1 وأخيراً 2048 نواة مختلفة بأبعاد 1x1 ويتم تكرار هذه المرحلة 3 مرات مما أعطانا إجمالي 9 طبقات.
6. مرحلة سادسة تتضمن التجميع باستخدام قيمة المتوسط average pool
7. طبقة اتصال كامل تحتوي على 1000 عقدة مع تابع تفعيل SoftMax.

layer name	output size	18-layer	34-layer	50-layer	101-layer	152-layer
conv1	112×112	7×7, 64, stride 2				
		3×3 max pool, stride 2				
conv2.x	56×56	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
conv3.x	28×28	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 8$
conv4.x	14×14	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 36$
conv5.x	7×7	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
	1×1	average pool, 1000-d fc, softmax				
FLOPs		1.8×10 <sup>9</sup>	3.6×10 <sup>9</sup>	3.8×10 <sup>9</sup>	7.6×10 <sup>9</sup>	11.3×10 <sup>9</sup>

الشكل (6): الهيكلية المعيارية للشبكة العصبية التلافيفية Resnet50

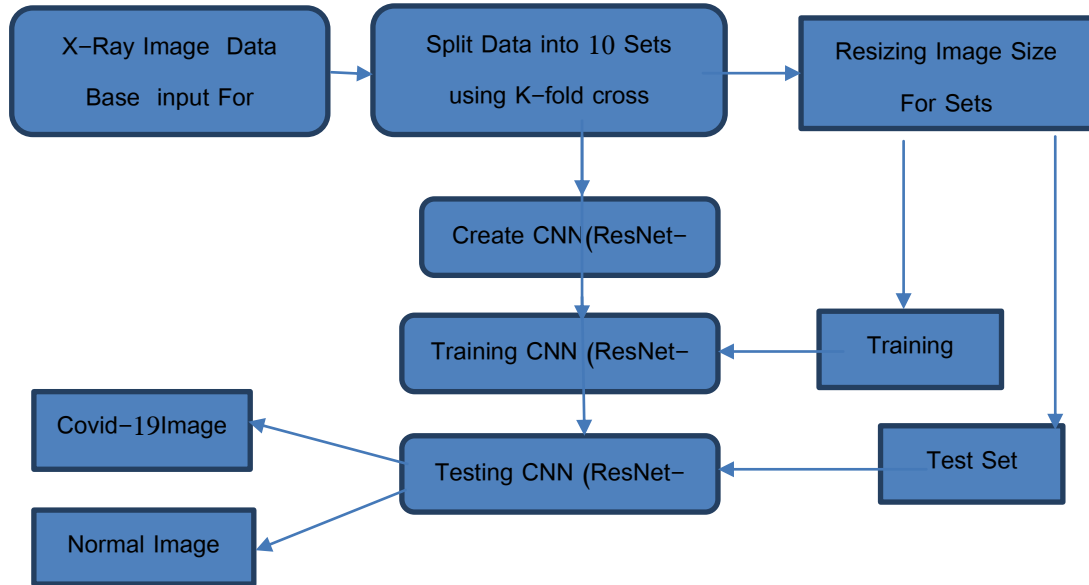
تتعلم الطبقة الأولى من CNN دائماً كشف سمات مثل الحواف وأنماط الخطوط واللون، أما شبكة الطبقة الأعمق فتقوم بالكشف عن السمات الأكثر تعقيداً مثل الآفات المرضية وبشكل عام تنشئ كل طبقات خريطة سماتها بدمج سمات من طبقات سابقة.

### أهمية البحث وأهدافه:

يقدم البحث آلية جديدة تساهم في المساعدة الفعالة لتشخيص الإصابة بفيروس كورونا من خلال صورة شعاعية بسيطة للصدر غير مكلفة كما باقي اختبارات الكشف عن المرض في ظل بحث العالم عن لقاح لهذه الجائحة العالمية، وذلك من خلال تسليط الضوء على الإمكانيات التي يقدمها التعلم العميق باستخدام الشبكات العصبية العميقة في مجال التصنيف والرؤية الحاسوبية.

## طرائق البحث ومواده:

تشتمل خوارزمية البحث على ثلاث خطوات رئيسية كما في الشكل (7):

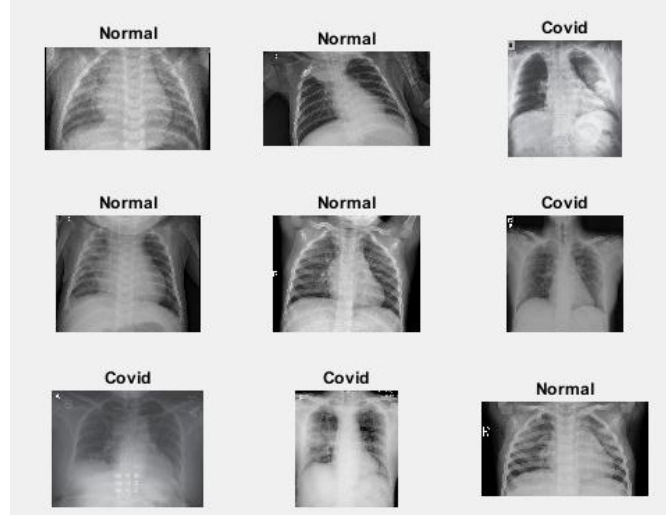


الشكل (7): مخطط خوارزمية البحث

1. إعداد البيانات وذلك من خلال تنزيل صور الأشعة السينية من قاعدة البيانات المذكورة في بداية البحث وتجميعها في مجموعتين الأولى تتضمن الصور السليمة والأخرى الصور المصابة وفي البحث تم تضمين كل مجموعة 25 صورة لتغدو المجموعتين معا كقاعدة بيانات خاصة بالبحث لدينا، ثم تحميل المجلد كاملا إلى MATLAB من خلال تعليمة imageDatastore وهي وظيفة متوفرة في النسخة MATLAB 2018B وما بعد، وتعتبر فعالة حسابياً لتحميل الصور مع ملصقاتها للتحليل.

2. اختيار عينة صور من قاعدة بيانات البحث بشكل عشوائي كما في الشكل (8) مما يساعد في التعرف على الصور ومعرفة الاختلافات بين مجموعتي قاعدة بيانات البحث وفي تحديد نوع تقنية التصنيف التي يمكن تطبيقها لتمييز الفئتين بناءً على الصور وبالتالي إمكانية تحديد تقنيات المعالجة المسبقة التي ستساعد على عملية التصنيف واختيار نوع بنية CNN التي يمكن استخدامها للدراسة بناءً على أوجه التشابه داخل المجموعة والاختلافات بين المجموعتين.

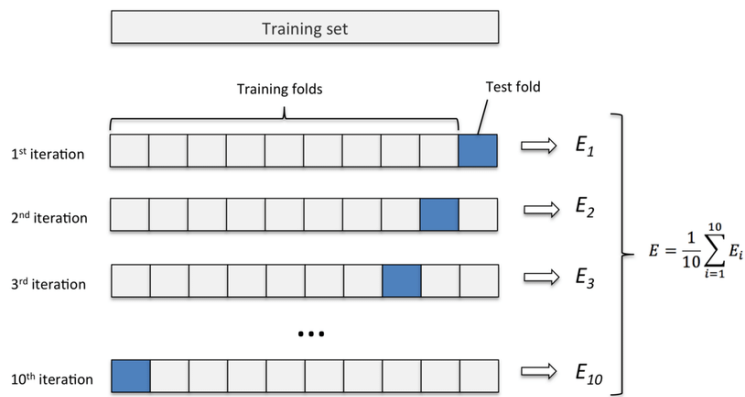




الشكل (8): اختيار عشوائي لعينة من الصور في قاعدة بيانات البحث

3. تجزئة البيانات لمحدوديتها إلى مجموعات باستخدام إحدى تقنيات خوارزمية التحقق المتقاطع (Cross Validation) الخاصة بالتعليم تحت الإشراف وهي خوارزمية التقسيم المتشابك K-fold cross validation التي تنفذ على البيانات الخطوات التالية:

- تقسيم البيانات بشكل عشوائي إلى K من المجموعات .
  - نقوم بالتدريب لكل مجموعه باستخدام كل القيم التي لا تنتمي إلى هذه المجموعة .
  - حساب مجموع نسبة الخطأ في هذه المجموعة .
  - تكرار الخطوات من 2- 3 حتى ننتهي من جميع المجموعات .
  - حساب متوسط الخطأ من المجموع الكلي للخطأ من كل المجموعات .
- لا يوجد نظرية ثابتة لاختيار قيمة k لكن الشائع اختيار k=10 ويظهر الشكل (9) آلية عمل الخوارزمية.



الشكل (9): آلية عمل خوارزمية التقسيم المتشابك ومتوسط الخطأ الناتج

4. اعتماد الشبكة العصبية التلافيفية ResNet50 الافتراضية في MATLAB مع استبدال الطبقات الثلاث الأخيرة بطبقة الاتصال كامل جديدة ثم طبقة تابع تصنيف SoftMax وهو المصنف الافتراضي للشبكة العصبية التلافيفية resnet50 في MATLAB.
  5. تطبيق عملية معالجة أولية لصور قاعدة بيانات البحث من خلال تحويل الصورة لتدرج الرمادي من خلال تحويل الصورة لتدرج الرمادي gray ثم إعادة بناء حجم الصورة للأبعاد 224 x 224 x 3 لمجموعات التدريب والاختبار.
  6. اختيار مُحسِن آدم (Adam optimize) ضمن خيارات التدريب لأننا اخترنا مجموعة تدريب بحجم صغير بسبب حجم الذاكرة المحدود في وحدة معالجة الرسومات GPU.
  7. استخدام خيار تعزيز البيانات (Data Augmentation) حيث تقوم عملية تعزيز بيانات الصورة بالعديد من خيارات المعالجة المسبقة لزيادة بيانات الصورة كتغيير الحجم والتدوير والانعكاس وهذا يضمن عملية لتصنيف أفضل على أي نوع من صور الصدر بالأشعة السينية.
  8. تغيير أبعاد الصور في الصنفين المدروسين في الشبكة العصبية إلى أبعاد [224 224] للتناسب والهيكليّة المعمارية لشبكات resnet.
  9. استخدام تابع التدريب للشبكة العصبية التلافيفية بعد تحديد معاملاته الثلاثة في الفقرات السابقة وهي بيانات الصورة وطبقات الشبكة العصبية وخيارات التدريب.
  10. يظهر الشكل (10) تدريب مجموعة التدريب الأخيرة على الشبكة العصبية ونلاحظ الدقة وهي تقريباً 100 بالمائة لمدة 30 فترة، والضياح إلى الصفر.
  11. بناء مصفوفة الارتباب أو الخطأ كما في الشكل (11) وهي ملخص لتوصيف أداء عملية التصنيف على مجموعة بيانات الاختبار ومعرفة البيانات الصحيحة التي تم تحديدها في عملية التصنيف ويعطي فكرة جيدة ليس فقط عن الأخطاء التي ترتبها عملية التصنيف إنما أنواع الأخطاء التي يتم ارتكابها.
- تسمح لنا مصفوفة الارتباب الحصول على الدقة الناتجة عن عملية التصنيف وذلك عن طريق تحديد ما يلي:
- (TP) عدد حالات التشخيص الإيجابية الصحيحة.
  - (TN) عدد حالات التشخيص السلبية الصحيحة.
  - (FP) عدد حالات التشخيص الإيجابي الخاطئ.
  - (FN) عدد حالات التشخيص السلبية الخاطئة.
  - ACC الدقة و تعطى بالعلاقة
- $$ACC = \frac{TP + TN}{TP + TN + FP + FN} \dots \dots (1)$$
- (err) معدل الخطأ وهو النسبة المئوية لعدد الحالات التي تم تشخيصها بشكل خاطئ
  - الحساسية (Sensitivity) وهي احتمال أن تكون نتيجة الاختبار إيجابية عند وجود المرض (معدل إيجابي حقيقي معبر عنه كنسبة مئوية) وتكتسب قيمة مثالية كلما انخفض عدد الحالات السلبية الخاطئة وتعطى بالعلاقة
- $$Sensitivity = \frac{TP}{TP + FN} \dots \dots (2)$$
- الخصوصية (Specificity): وهي احتمال أن تكون نتيجة الاختبار سلبية عندما لا يكون المرض موجوداً (المعدل السلبي الحقيقي معبراً عنه كنسبة مئوية) وتعطى بالعلاقة

$$Specificity = \frac{TN}{TN + FP} \dots \dots (3)$$

○ القيمة التنبؤية الإيجابية (Positive predictive value): وهي النسبة المئوية لاحتمال وجود المرض عندما يكون الاختبار إيجابياً.

$$PPV = \frac{TP}{TP + FP} \dots \dots (4)$$

كلما كان عدد الحالات الإيجابية الخاطئة صغيراً كلما كانت عملية التصنيف ممتازة ودقة التصنيف مثالية، أما ارتفاع الحساسية وانخفاض الدقة فتشير إلى أن أغلب الحالات الإيجابية تم تصنيفها لكن مع العديد من الحالات الإيجابية الخاطئة ( قيمة قليلة من FN و كبيرة من FP )، أما قيمة حساسية منخفضة ودقة مرتفعة فتشير إلى فقدان تصنيف العديد من الحالات الإيجابية ( قيمة عالية FN و قيمة صغيرة FP ) [29].

○ F-Measure: قياس يمثل كل من الحساسية ودقة التصنيف ويستخدم الوسط التوافقي بدلا من الوسط الحسابي وسيكون هذا القياس أقرب للقيمة الأصغر ويعطى بالعلاقة

$$F - Measure = \frac{2 * Sensitivity * PPV}{Sensitivity + PPV} \dots \dots (4)$$

○ (BAC) الدقة المتوازنة وتعطى بالعلاقة

$$BAC = \frac{(Sensitivity + Specificity)}{2} \dots \dots (5)$$

○ (PLR) نسبة الاحتمالية الإيجابية (Positive likelihood ratio): وهي النسبة بين احتمالية نتيجة اختبار إيجابية بالنظر إلى وجود المرض واحتمال نتيجة اختبار إيجابية بالنظر إلى غياب المرض وتعطى بالعلاقة:

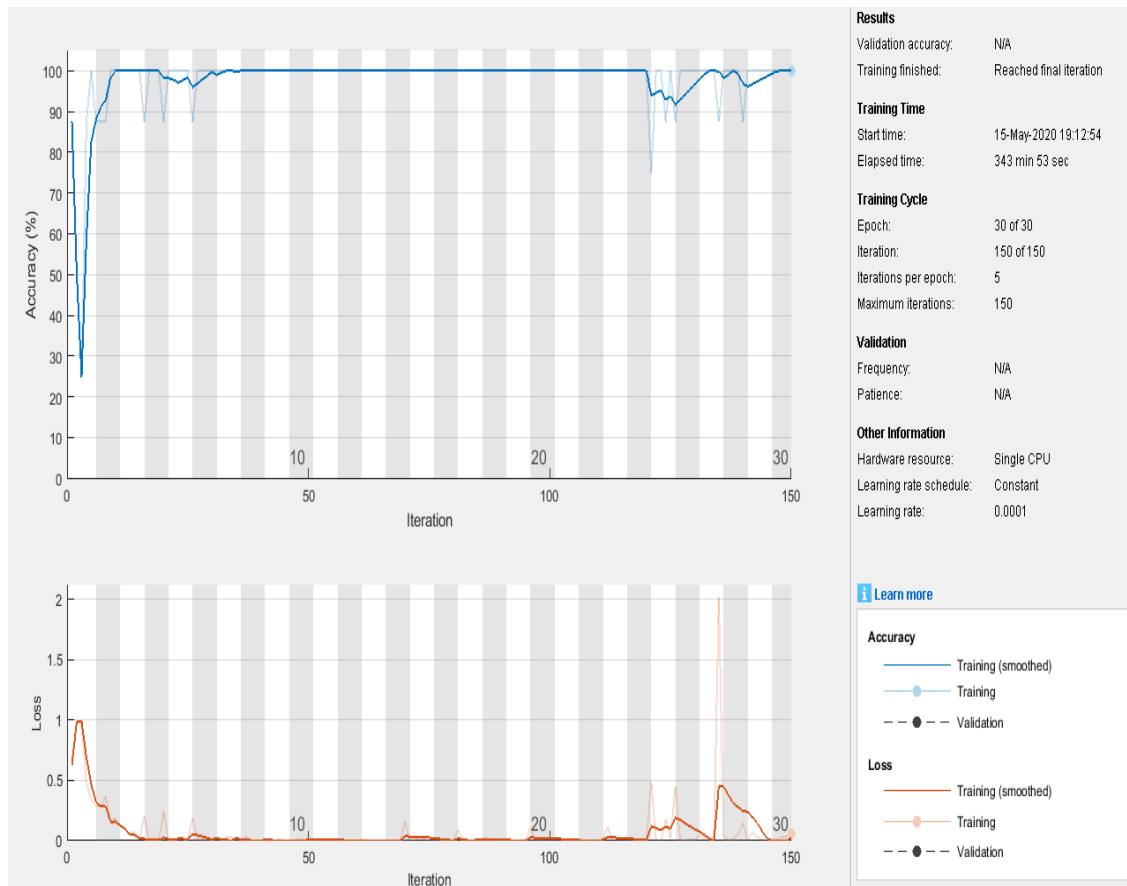
$$PLR = \frac{Sensitivity}{(1 - Specificity)} \dots \dots (6)$$

○ (NLR) نسبة الاحتمالية السلبية (Negative likelihood ratio): وهي النسبة بين احتمالية نتيجة اختبار سلبية نظراً لوجود المرض واحتمال نتيجة اختبار سلبية نظراً لغياب المرض وتعطى بالعلاقة

$$NLR = \frac{(1 - Sensitivity)}{Specificity} \dots \dots (7)$$

○ (NPV) القيمة التنبؤية السلبية (Negative predictive value) وهي النسبة المئوية لاحتمالية عدم وجود المرض عندما يكون الاختبار سلبياً و تعطى بالعلاقة

$$NPV = \frac{TN}{TN + FN} \dots \dots (8)$$



الشكل (10): مجموعة التدريب الأخيرة للشبكة العصبية ResNet.

**Confusion Matrix For(ResNet)**

	Covid	Normal	
Output Class	Covid	25 50.0%	1 2.0%
	Normal	0 0.0%	24 48.0%
		96.2% 3.8%	100% 0.0%
		100% 0.0%	96.0% 4.0%
		98.0% 2.0%	
		Covid	Normal
		Target Class	

الشكل (11): مصفوفة الارتباب للشبكة العصبية ResNet.


12. سنقوم الآن بإنشاء منحنى خاصة تشغيل المستلم (ROC) كما في الشكل (12) وهو رسم بياني يوضح القدرة التشخيصية لنظام التصنيف الثنائي مع اختلاف عتبة التمييز الخاصة به وهذا الرسم البياني هو علاقة يرسم المعدل الإيجابي الحقيقي (TPR) أو ما يسمى الحساسية كناتج للمعدل الإيجابي الكاذب (FPR) أو احتمالية الإنذار الكاذب و هو (1-specificity) في إعدادات العتبة المختلفة و كلما كان المنحنى أقرب للزاوية اليسرى العليا كلما زادت الدقة الإجمالية لعملية التصنيف.

13. حساب AUC وهو المساحة تحت منحنى ROC تعطي انطباع عن مدى جودة عملية التصنيف و كلما كانت قيمة المساحة أكبر كلما كانت دقة التصنيف أفضل و قيمة AUC في البحث لدينا

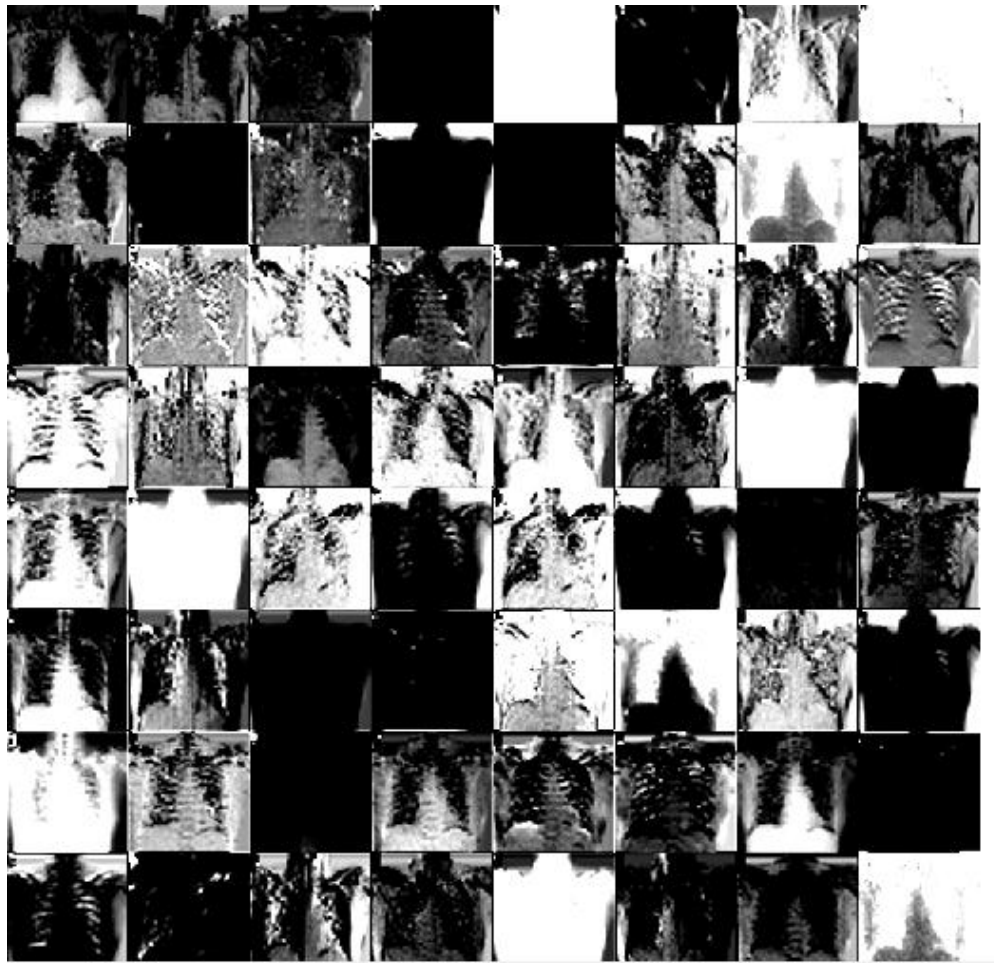
$$AUC = 0.9984$$

14. تم التحقق من فعالية الكتلة الثانية (activation\_2\_relu) في تحديد السمات التي ستقوم الشبكة العصبية باستخراجها من خلال اختبار الصورة السابعة من قاعدة بيانات البحث كما في الشكل (13) حيث يظهر اللون الداكن الميزات الأقل تواترا بينما يظهر اللون الفاتح الميزات الأكثر تواترا.


15. يتم التحقق من الميزات المستخرجة من إحدى طبقات الشبكة بواسطة التابع deepDreamImage وبيين الشكل (14) الميزات المستخرجة من الطبقة bn\_conv1.



الشكل (12): منحنى ROC وقيمة AUC



الشكل (13): السمات التي سيتم استخراجها من الصورة السابعة من قاعدة بيانات البحث



الشكل (14): التحقق من الميزات المستخرجة من الطبقة bn\_conv1.

## النتائج والمناقشة:

يمكن اعتبار النتائج التي تم التوصل إليها في البحث كما في الجدول (1) وهو نتائج مصفوفة الارتياح الخاصة بالشبكة والموضحة بالشكل (11) كما يلي:

الجدول (1): نتائج مصفوفة الارتياح للشبكة العصبية الصناعية ResNet

Covid	Normal	TP	TN	FP	FN	Specificity
25	25	25/25	24/25	1/25	0/25	0.962
Average(ACC)		Average(err)	Sensitivity	PPV	F-measure	BAC
98.1%		1.9%	1	0.962	0.981	0.98

تمت مقارنة نتائج البحث مع نتائج أبحاث أخرى تمت حول نفس الفكرة وباستخدام بنى شبكات عصبية صناعية مختلفة لنفس تابع التصنيف ونفس قاعدة البيانات مصدر بيانات بالبحث فكان الجدول (2)

الجدول (2): مقارنة نتائج البحث مع نماذج شبكات CNN في أبحاث أخرى

نماذج الشبكة العصبية CNN	نتائج مصفوفة الارتياح والأداء			
	ACC	Sensitivity	Specificity	PPV
Inception V3	97	94	100	100
ResNet 50	98.1	100	96.2	96.2
Inception- ResNetV2	87	84	90	91
NCOVnet (VGG-16)	97.62	97.62	78.57	78
DenseNet121	90.61	90.80	89.76	89
AlexNet	97	87	94	94
ResNet-18	95.18	96	70.65	71

لقد تبين نتائج البحث مع الوصول إلى نسبة دقة تشخيص 98.1% أنه من الممكن أن تساعد تقنيات التعلم العميق الأطباء في تشخيص الحالات المرضية موضوع البحث بالتالي تصنيف تقنيات التعلم العميق مفهوماً جديداً عملياً في عملية التصنيف والرؤية الحاسوبية، وفي بحثنا كان تشخيص الإصابة بفيروس كورونا الجدي من خلال الأشعة السينية للصدر وذلك من خلال تدريب شبكة عصبية عميقة CNN.

## الاستنتاجات والتوصيات:

تم في هذا البحث تحقيق تشخيص ذكي لكشف الإصابة بفيروس كورونا الجدي من خلال أشعة الصدر السينية وذلك بواسطة شبكة عصبية التلافيفية CNN إحدى تقنيات التعلم العميق وهو أحد مجالات الذكاء الصناعي قد تم استخدام النظام المقترح على صور أشعة سينية للصدر مأخوذة من مصابين بالفايروس وغير مصابين به. تضمنت خطوات العمل المقترحة تدريب شبكة عصبية صناعية التلافيفية CNN على خمسين صورة أشعة سينية مأخوذة من قاعدة بيانات متوفرة على الشبكة العنكبوتية للأبحاث وبشكل مجاني تم تجميع هذه الصورة بقاعدة بيانات خاصة بالبحث تحت قسمين الأول Normal لصور الأشخاص الغير مصابين بالفايروس يتضمن 25 صورة و Covid لصور

الأشخاص المصابين يتضمن 25 صورة، ثم تم تحميل القاعدة إلى برنامج MATLAB وتقسيم البيانات وفق خوارزمية التقسيم المتشابه إلى عشر مجموعات فرعية تسعة للتدريب والعاشر للاختبار. تم تدريب الشبكة واختبار أدائها ثم تقييم النتائج من خلال بعض المؤشرات كالقيمة التنبؤية الإيجابية (PPV) والحساسية، الخصوصية والدقة، وكذلك من خلال منحنى ROC وقيمة AUC وقد أظهرت النتائج أن الخطوات العملية المقترحة تعتمد بشكل أساسي على نوع الشبكة العصبية الاصطناعية والآلية المتبعة في تدريب الشبكة وأدائها في النهاية وأنه لن يعمل بشكل جيد في حال فشلت الشبكة في استخلاص النتائج وتصنيف الصور المدخلة إليها. حصلت بنية الشبكة العصبية الاصطناعية CNN المقترحة وهي ResNet50 أعلى معدل للدقة بين بعض النماذج الأخرى التي تم مقارنة النتائج بها في المقالة.

## References:

- [1] P. Huang et al., "Use of Chest CT in Combination with Negative RT-PCR Assay for the 2019 Novel Coronavirus but High Clinical Suspicion," *Radiology*, vol. 295, no. 1, pp. 22-23, 2020.
- [2] M.-Y. Ng et al., "Imaging Profile of the COVID-19 Infection: Radiologic Findings and Literature Review," *Radiology: Cardiothoracic Imaging*, vol. 2, no. 1, p. e200034, 2020.
- [3] C. I. Paules, H. D. Marston, and A. S. Fauci, "Coronavirus Infections—More Than Just the Common Cold," *JAMA*, vol. 323, no. 8, pp. 707-708, 2020.
- [4] Y. Chen, Q. Liu, and D. Guo, "Emerging coronaviruses: Genome structure, replication, and pathogenesis," *Journal of Medical Virology*, vol. 92, no. 4, pp. 418-423, 2020.
- [5] C. Sohrabi et al., "World Health Organization declares global emergency: A review of the 2019 novel coronavirus (COVID-19)," *International Journal of Surgery*, vol. 76, pp. 71-76, 2020/04/01/ 2020
- [6] H. Liu, F. Liu, J. Li, T. Zhang, D. Wang, and W. Lan, "Clinical and CT imaging features of the COVID19 pneumonia: Focus on pregnant women and children," *Journal of Infection*, 2020/03/21/ 2020.
- [7] L. J. M. Kroft, L. van der Velden, I. H. Girón, J. J. H. Roelofs, A. de Roos, and J. Geleijns, "Added Value of Ultra-low-dose Computed Tomography, Dose Equivalent to Chest X-Ray Radiography, for Diagnosing Chest Pathology," *Journal of Thoracic Imaging*, vol. 34, no. 3, pp. 179-186, 2019
- [8] M. Chung et al., "CT Imaging Features of 2019 Novel Coronavirus (2019-nCoV)," *Radiology*, vol. 295, no. 1, pp. 202-207, 2020.
- [9] N. Chen et al., "Epidemiological and clinical characteristics of 99 cases of 2019 novel coronavirus pneumonia in Wuhan, China: a descriptive study," *Lancet*, vol. 395, no. 10223, pp. 507-513, Feb 15 2020.
- [10] M. E. Karar, D. R. Merk, V. Falk, and O. Burgert, "A simple and accurate method for computer-aided transapical aortic valve replacement," *Computerized Medical Imaging and Graphics*, vol. 50, pp. 31-41, 2016
- [11] M. Messerli et al., "Computer-aided detection (CAD) of solid pulmonary nodules in chest x-ray equivalent ultralow dose chest CT - first in-vivo results at dose levels of 0.13mSv," *European Journal of Radiology*, vol. 85, no. 12, pp. 2217-2224, 2016/12/01/ 2016.
- [12] X. Tian et al., "Medical imaging and diagnosis of subpatellar vertebrae based on improved Laplacian image enhancement algorithm," *Computer Methods and Programs in Biomedicine*, vol. 187, p. 105082, 2020/04/01/ 2020.



- [13] Md Zahangir Alom et al., "A State-of-the-Art Survey on Deep Learning Theory and Architectures," *electronics*-08-00292-v3, pp. 1-12, 2019/3/5.
- [14] Jaiswal AK, Tiwari P, Kumar S, Gupta D, Khanna A, Rodrigues JJ (2019) Identifying pneumonia in chest X-rays: a deep learning approach. *Measurement* 145:511–518
- [15] Antin B, Kravitz J, Martayan E (2017) Detecting pneumonia in chest X-rays with supervised learning.
- [16] Narayan Das N, Kumar N, Kaur M, Kumar V, Singh D (2020) Automated deep transfer learning-based approach for detection of COVID-19 infection in chest X-rays. *IRBM*.
- [17] Ayan E, Ünver HM (2019) Diagnosis of pneumonia from chest X-ray images using deep learning. In: Scientific meeting on electrical-electronics and biomedical engineering and computer science (EBBT), Istanbul, Turkey, pp 1–5.
- [18] Tahir H., Iftikhar A. and Mumraiz M., "Forecasting COVID-19 via Registration Slips of Patients using ResNet-101 and Performance Analysis and Comparison of Prediction for COVID-19 using Faster R-CNN, Mask R-CNN, and ResNet-50," 2021 International Conference on Advances in Electrical, Computing, Communication and Sustainable Technologies (ICAECT), 2021, pp. 1-6, doi: 10.1109/ICAECT49130.2021.9392487.