

## Designing a Multiclassification Convolutional Neural Networks Model for the Diagnosis of Lung Cancer and Covid-19

Dr. Ghada Saad\*  
Aous Mohamad Mohammad\*\*

(Received 18 / 5 / 2022. Accepted 14 / 12 / 2022)

### □ ABSTRACT □

In this research, a multi-classification system was designed to automatically detect Covid-19 disease and lung cancer based on convolutional neural networks, through two data sets, the first is computed tomography images of both infected and uninfected people, and the second is x-ray images, and we divided these data into two groups. (Test - Training), and then we built and trained the model and compared the performance of the system between the use of the first group (computed tomography images), which gave an accuracy of 98%, and the second group (X-ray images), which gave an accuracy of 86%, and therefore the use of computed tomography images gives better results. In diagnosing the disease, the results of our designed system also show better accuracy than the results of previous reference studies that used Alex Net, VGG19, Res Net, Google Net, Squeeze Net, which give the following accuracy, respectively, when they are used for X-ray images (58.62, 67.74, 84.48, 75.86, 70.68) and gives the following resolution when used for CT images (89.1, 93.10, 93.10, 89.65, 82.75).

**Keywords:** convolutional neural networks , X-ray images, CT images, Cancer, covid19.

---

\* Assistant Professor- Biomedical Engineering – Tishreen University – Lattakia - Syria.

\*\* Master - Industrial Automation Engineering – Tartus University – Tartus - Syria.

## تصميم نموذج عصبوني التفاضلي متعدد التصنيفات لتشخيص الإصابة بمرض سرطان الرئة و Covid-19

د. غادة محي الدين سعد \*

أوس محمد محمد \*\*

تاريخ الإيداع 18 / 5 / 2022. قُبِلَ للنشر في 14 / 12 / 2022

### □ ملخص □

تم في هذا البحث تصميم نظام متعدد التصنيفات لكشف الإصابة بمرض Covid-19 وسرطان الرئة تلقائياً اعتماداً على الشبكات العصبونية التفاضلية، وذلك من خلال مجموعتين من البيانات الأولى صور مقطعية محوسبة لكل من الأشخاص المصابين وغير المصابين والثانية صور الأشعة السينية، وقمنا بتقسيم هذه البيانات إلى مجموعتين (اختبار - تدريب)، ومن ثم قمنا ببناء النموذج وتدريبه ومقارنة أداء النظام بين استخدام المجموعة الأولى (صور مقطعية محوسبة) حيث أعطت دقة 98% والمجموعة الثانية (صور أشعة سينية) حيث أعطت دقة 86% وبالتالي إن استخدام الصور مقطعية المحوسبة تعطي نتائج أفضل في تشخيص المرض، كما تظهر نتائج نظامنا المصمم دقة أفضل من نتائج الدراسات المرجعية السابقة التي استخدمت كل من الشبكات Alex Net, VGG19, Res Net, Google Net, Squeeze Net والتي تعطي الدقة التالية على الترتيب عند استخدامها لصور الأشعة السينية (58.62, 67.74, 70.68, 75.86, 84.48, 89.1, 93.10, 93.10, 82.75, 89.65).

الكلمات المفتاحية: الشبكات العصبونية التفاضلية - الأشعة السينية - صور مقطعية محوسبة - سرطان الرئة - Covid19.

\*مدرس - قسم الهندسة الطبية - كلية الهندسة الميكانيكية والكهربائية - جامعة تشرين - اللاذقية - سورية.  
\*\* ماجستير - قسم هندسة الأتمتة الصناعية - كلية الهندسة التقنية - جامعة طرطوس - سورية.

**مقدمة:**

بدأ مرض فيروس كورونا في الصين في ديسمبر 2019. وتم الإبلاغ عن أكثر من 29.5 مليون حالة في أكثر من 188 دولة، وقد تم الإعلان عن مليون حالة وفاة [1]. حيث يسبب هذا الفيروس متلازمة تنفسية حادة وخيمة ويمكن أن يكون شديداً في المرضى الذين يعانون من أمراض مصاحبة ويبلغ معدل الوفيات 2٪ [2]. وقد كان لابد من اتخاذ خطوة فعالة لاحتواء COVID-19 من خلال إجراء اختبارات حتى يتمكن الشخص المصاب من تلقي رعاية فورية مع علاج أكثر تحديداً ويمكن ضمان الحجر الصحي للمريض للحد من انتشار الفيروس. ويعتبر استخدام الذكاء الاصطناعي في المجال الصحي أمر جديد نسبياً، حيث يساعد في عملية التشخيص، ويساهم في تحسين الخطط العلاجية وتطوير الأدوية ومراقبة المريض ورعايته، ويمكن أيضاً استخدام خوارزميات الذكاء الاصطناعي لتحليل كميات كبيرة من البيانات بالاعتماد على السجلات الصحية الإلكترونية للوقاية من الأمراض وتشخيصها.

**أهمية البحث وأهدافه:**

تطوير نموذج ذكاء اصطناعي معتمد على الشبكات العصبونية التفاضلية متعددة التصنيفات لتشخيص الإصابة بمرض سرطان الرئة و Covid-19

**طرائق البحث ومواده:**

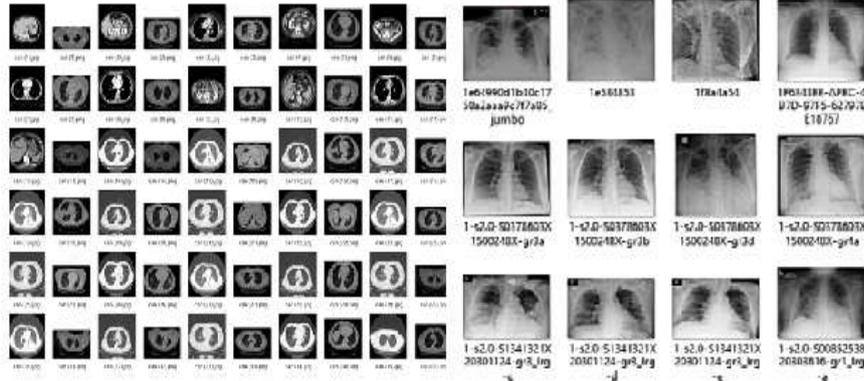
تم استخدام برنامج python في هذا البحث لبناء نموذج الشبكة.

**الدراسات المرجعية:**

أظهر التعلم العميق زيادة كبيرة في التطبيقات الطبية بشكل عام وخاصة في التشخيص الطبي القائم على الصور، حيث تم اختبار أداء نماذج التعلم العميق بشكل بارز في مشاكل رؤية الكمبيوتر المتعلقة بتحليل الصور الطبية، تفوقت شبكات ANN على النماذج والطرق التقليدية الأخرى لتحليل الصور [3-4]، نظراً للنتائج الواعدة جداً التي قدمتها شبكات CNN في تحليل الصور الطبية وتصنيفها، فإنها تعتبر معياراً واقعياً في هذا المجال [5-6]. تم استخدام CNN في مجموعة متنوعة من مهام التصنيف المتعلقة بالتشخيص الطبي مثل أمراض الرئة [10]، واكتشاف طفيلي الملاريا في صور مسحة الدم الرقيقة [7]، واكتشاف سرطان الثدي [8]، وصور التنظير اللاسلكي [9]، مرض الرئة الخلالي [1]، التشخيص المستند إلى CAD في التصوير الشعاعي للصدر [15]، وتشخيص سرطان الجلد حسب التصنيف [2]. منذ ظهور COVID-19 في ديسمبر 2019، يشارك العديد من الباحثين في أنشطة التجريب والبحث المتعلقة بتشخيص وعلاج وإدارة COVID-19، حيث استخدموا مائة صورة من تصوير مقطعي محوسب لمصدر لمرضى الكورونا COVID-19 لبناء واختبار مصنف Bayes Naïve Gaussian لتميز النسيج الطبيعية من النسيج غير الطبيعية. قسمت المناطق المصابة في هذه الصور يدوياً بواسطة أخصائي أشعة خبير. أجريت عملية استخراج قيمة البكسل الرمادية والانتروبيا المحلية وقيم الهستوغرام للتدرجات الموجهة HOG كميزات لتصنيف صور الأنسجة. استناداً إلى تجارب تصنيف ذات خمس طيات، وصلت درجة دقة المصنف إلى حوالي 79.94%. كان التصنيف أكثر دقة (85%) في التعرف على الأنسجة الطبيعية من الأنسجة غير الطبيعية (63%). كانت أيضاً الفعالية في تحديد المناطق أكثر وضوحاً في الأنسجة الطبيعية من الأنسجة غير الطبيعية [11].

## 1- تحضير البيانات:

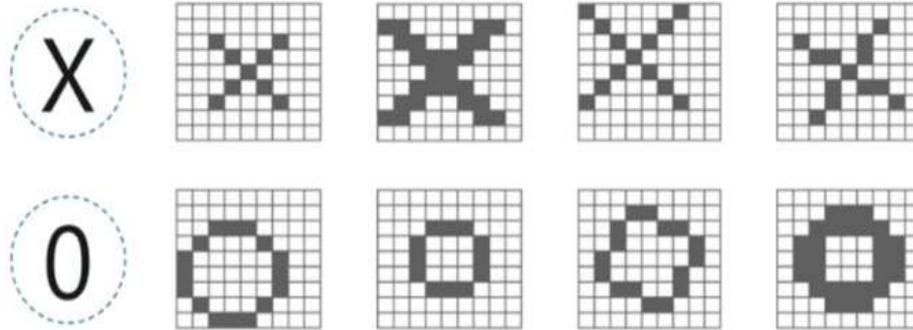
قمنا بتجهيز مجموعة البيانات، ثم درينا الشبكة على 80% من البيانات (كوفيد - سرطان رئة - سليم) ، ثم قمنا باختبار الشبكة على 20% من البيانات (كوفيد - سرطان رئة - سليم) وبيين الشكل (1) قاعدة البيانات المستخدمة.



الشكل (1): قاعدة البيانات المستخدمة.

## 2- بناء نموذج الشبكة:

تتكون الشبكة العصبية الالتفافية من 4 طبقات أساسية وهي طبقة الدخل، طبقة التسطح، الطبقة كاملة الاتصال وطبقة الخرج، ولفهم آلية عمل الشبكة العصبونية الالتفافية سنأخذ المثال العملي التالي والذي يهدف إلى التمييز بين صورة الرمز X وصورة الرمز O ويوضح الشكل (2) صورة لكلا الرمزين مع بعض الصور التي يمكن اعتبارها تابعة لإحدى الرمزين.

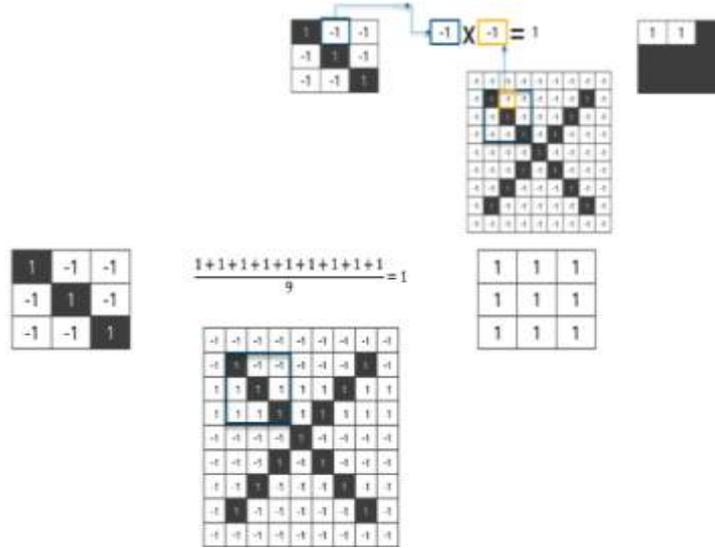


الشكل (2): عدة أشكال لمصفوفة الدخل لكل من الرمزين X,O.

### 1- المرحلة الأولى (الطبقة الالتفافية):

يمثل خرج كل مرشح يتم استخدامه في هذه الطبقة مجموعة ميزات مهمة للتعرف على الصورة (كل تطبيق للمرشح على جزء من الصورة يعتبر ميزة)، وتقوم خوارزمية التعلم في الشبكة العصبونية العميقة باختيار الميزات الأكثر مناسبة للصورة المرجعية.

نقوم بتمرير كل مرشح على صورة الدخل، حيث يجري في البداية جداء عناصر المصفوفة الموافقة لأبعاد المرشح (في مثالنا 3\*3). بعد الحصول على نتيجة الجداء، يجري قسمة الناتج على عدد عناصر المرشح عندها نكون قد حصلنا على أول قيمة خرج للمرشح (الميزة الأولى) ويوضح الشكل (3) هذه العملية.



الشكل (3): الطبقة الالتفافية.

بنكرار العملية السابقة مع إزاحة المرشح على كامل مصفوفة الدخل، نحصل على الخرج النهائي لهذا المرشح والشكل (4) يوضح ذلك.

0.77	-0.11	0.11	0.33	0.55	-0.11	0.33
-0.11	1.0	-0.11	0.33	-0.11	0.11	-0.11
0.11	-0.11	1.0	-0.33	0.11	-0.11	0.55
0.33	0.33	-0.33	0.55	-0.33	0.33	0.33
0.55	-0.11	0.11	-0.33	1.00	-0.11	0.11
-0.11	0.11	-0.11	0.33	-0.11	1.00	-0.11
0.33	-0.11	0.55	0.33	0.11	-0.11	0.77

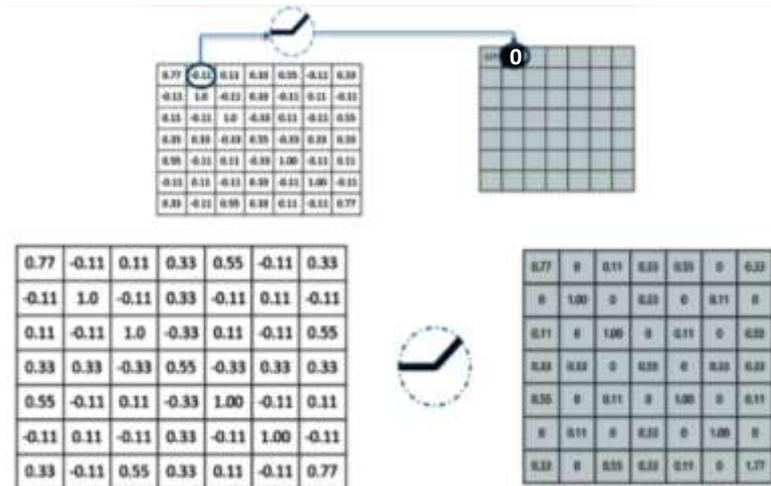
الشكل (4): نتيجة مرور مصفوفة الدخل بالطبقة الالتفافية.

2- المرحلة الثانية طبقة التنغيع:

سنختار تابع التنغيع RELU والذي تعطي علاقته [6] كما يلي:

$$f(x) = \begin{cases} x, & \text{if } x \geq 0 \\ 0, & \text{if } x < 0 \end{cases}$$

حيث يحافظ على القيم الموجبة كما هي، ويقوم بجعل القيم السالبة مساوية للصفر، ويوضح الشكل (5) نتيجة تطبيق تابع التنغيع على كل عنصر من عناصر مصفوفة الدخل.



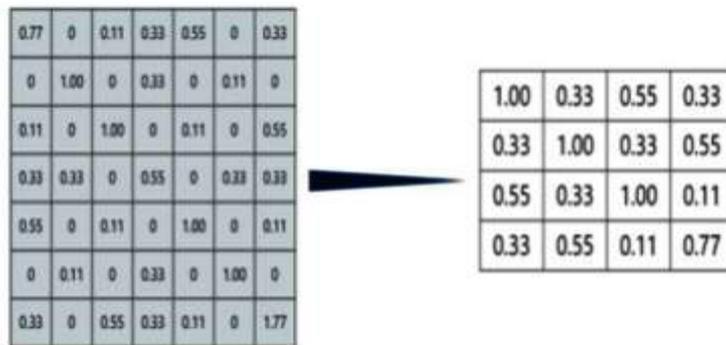
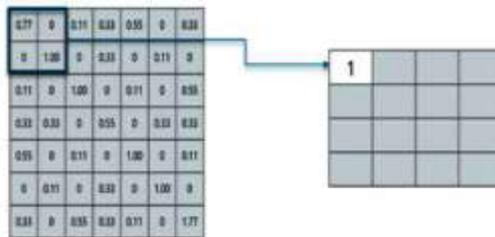
الشكل (5): تطبيق طبقة التفعيل على خرج الطبقة الالتفافية.

3- طبقة التجميع:

تقوم باختزال خرج الطبقة السابقة وذلك باستخدام تابع ما (max, average,...) يعبر عن القيم المختزلة. لتنفيذ عملية التجميع نقوم بالخطوات التالية:

- 1- نختار مصفوفة التجميع (عادة ما يستخدم مصفوفة بأبعاد  $2 \times 2$  أو  $3 \times 3$ ).
- 2- نختار طول خطوة إزاحة المصفوفة (في الغالب نختارها مساوية لـ 2).
- 3- نمرر المصفوفة على كامل الدخل مع تطبيق تابع معين (في مثالنا سنستخدم تابع يعيد أكبر قيمة موجودة ضمن المصفوفة).

ويبين الشكل (6) مصفوفة  $2 \times 2$  ونتيجة تطبيق التجميع على كامل الدخل.



الشكل (6): تطبيق طبقة التجميع على خرج طبقة التفعيل.

عادة ما تكون الصور ملونة بمعنى لها ثلاث مركبات (ثلاث مصفوفات تعبر عن RGB) ويبين الشكل (7) خرج الطبقات السابقة على المصفوفات الثلاث.

1.00	0.33	0.55	0.33
0.33	1.00	0.33	0.55
0.55	0.33	1.00	0.11
0.33	0.55	0.11	0.77

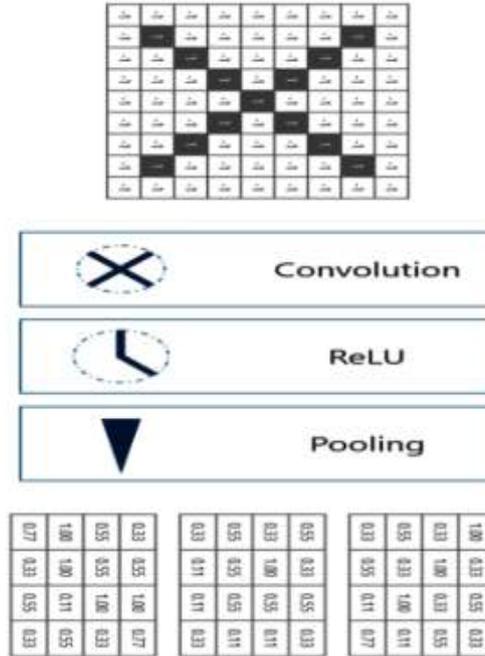
0.55	0.33	0.55	0.33
0.33	1.00	0.55	0.11
0.55	0.55	0.55	0.11
0.33	0.11	0.11	0.33

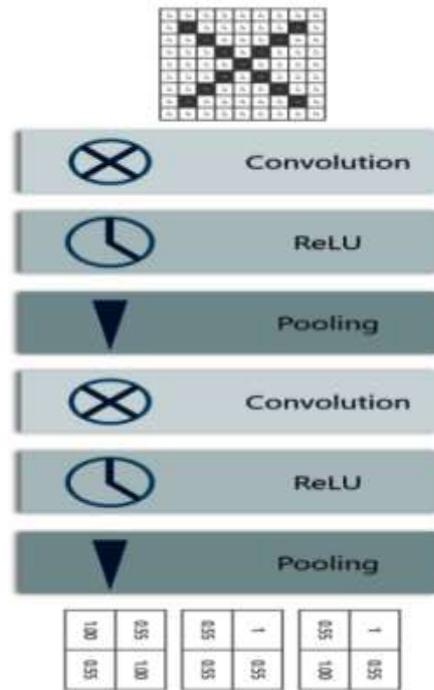
0.33	0.55	1.00	0.77
0.55	0.55	1.00	0.33
1.00	1.00	0.11	0.55
0.77	0.33	0.55	0.33

الشكل (7): نتيجة تطبيق كل من الطبقات الالتفافية والتفعيل والتجميع على صورة دخل RGB

تمثل الطبقات السابقة المرحلة الأولى في الشبكة العصبونية الالتفافية ويبين ذلك الشكل (8) وعادة ما نقوم بتكرار هذه المرحلة عدة مرات (مع اختلاف بالمتحولات الخاصة بكل مرحلة) ويوضح الشكل (9) نتيجة تطبيق مرحلتين من الطبقات على الدخل.



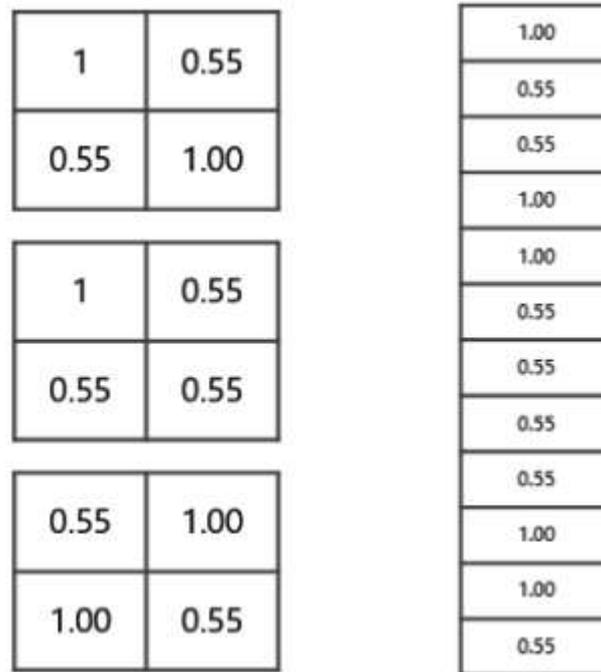
الشكل (8): نتيجة تطبيق المرحلة الأولى من تطبيق الشبكة العصبونية الالتفافية على الدخل.



الشكل (9): نتيجة تطبيق مرحلتين من المراحل الأساسية للشبكة العصبونية الانتقافية على الدخل.

#### 4- مرحلة التسطح (التسوية):

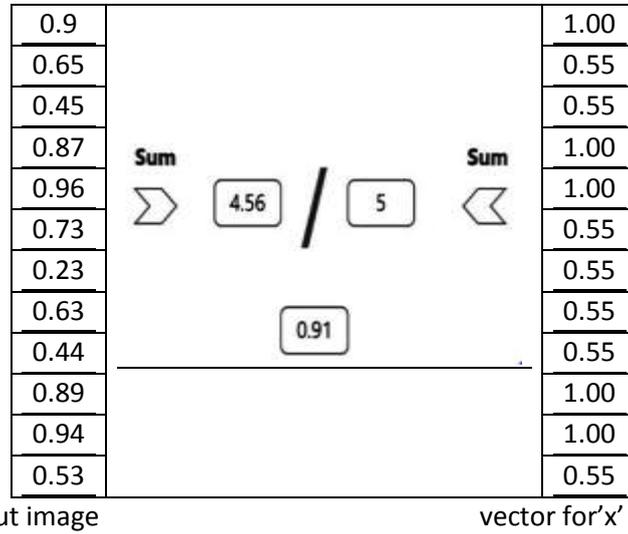
عند الانتهاء من تطبيق المراحل الأساسية، نكون قد حصلنا على ثلاث مصفوفات مختزلة تعبر عن أهم ميزات الدخل. بعد ذلك يجري تطبيق طبقة التسوية والتي تحول الخرج المصفوفاتي إلى شعاع وحيد ويبين ذلك الشكل (10).



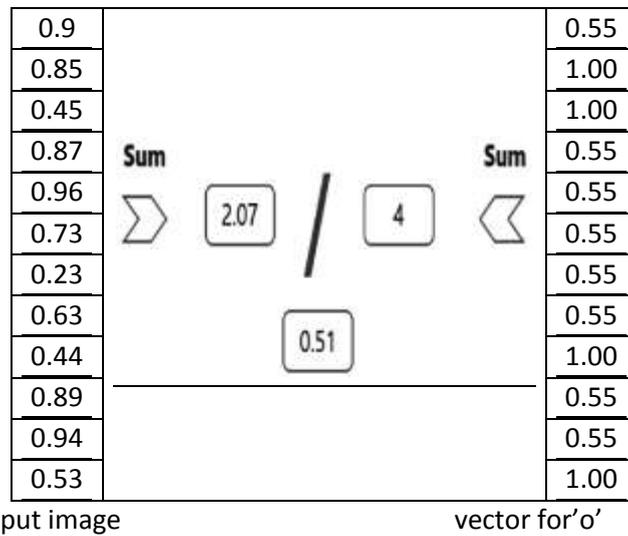
الشكل (10): خرج طبقة التسوية.

يدخل هذا الشعاع إلى شبكة عصبونية متصلة بشكل كامل، وذلك ليتم تهيئة الأوزان المناسبة (تدريب الشبكة)، لتقرير ما إذا كان هذا الشعاع ينتمي إلى الرمز X أو O. سنعتبر في حالتنا أن خرج الشبكة العصبونية يعبر عن مجموع

القيم (في الدخل) المقابلة لقيمة 1/ في الشعاع المثالي لـ X والشعاع المثالي لـ O. عند إدخال صورة جديدة، يتم إيجاد شعاع الدخل ومن ثم يتم حساب قيمة مجموع العناصر (المقابلة لقيمة 1/ في كل من X و O كل على حدى) في هذا الشعاع ومقارنتها مع القيم المثلى لكل من الرمزين X و O ويتم اختيار الرموز عن طريق القيمة الأقرب ويوضح كل من الشكل (11-a) شعاع الرمز X وشعاع الدخل والشكل (11-b) شعاع الرمز O وشعاع الدخل.

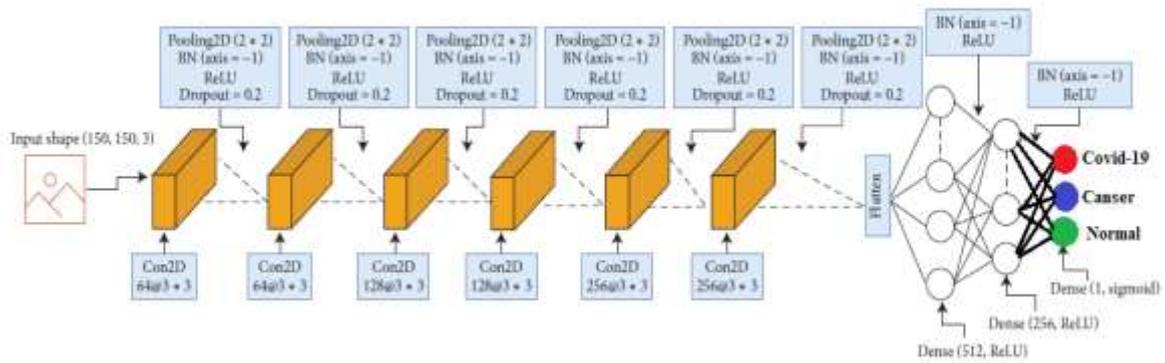


الشكل (11-a): طريقة حساب التصنيف النهائي من قبل الشبكة العصبونية ذات الاتصال الكامل.



الشكل (11-b): طريقة حساب التصنيف النهائي من قبل الشبكة العصبونية ذات الاتصال الكامل.

من الواضح أن شعاع الدخل أقرب إلى الرمز X ( $0.51 < 0.91$ ) وبالتالي الصورة تعبر عن الرمز X. قمنا بإنشاء 6 طبقات طّي، واخترنا أيضاً حجم مرشح الطي بأبعاد (3,3) وأبعاد طبقات تجميع-القيمة الكبرى ببعدين (2,2) ويبين الشكل (12) نموذج الشبكة المقترح.

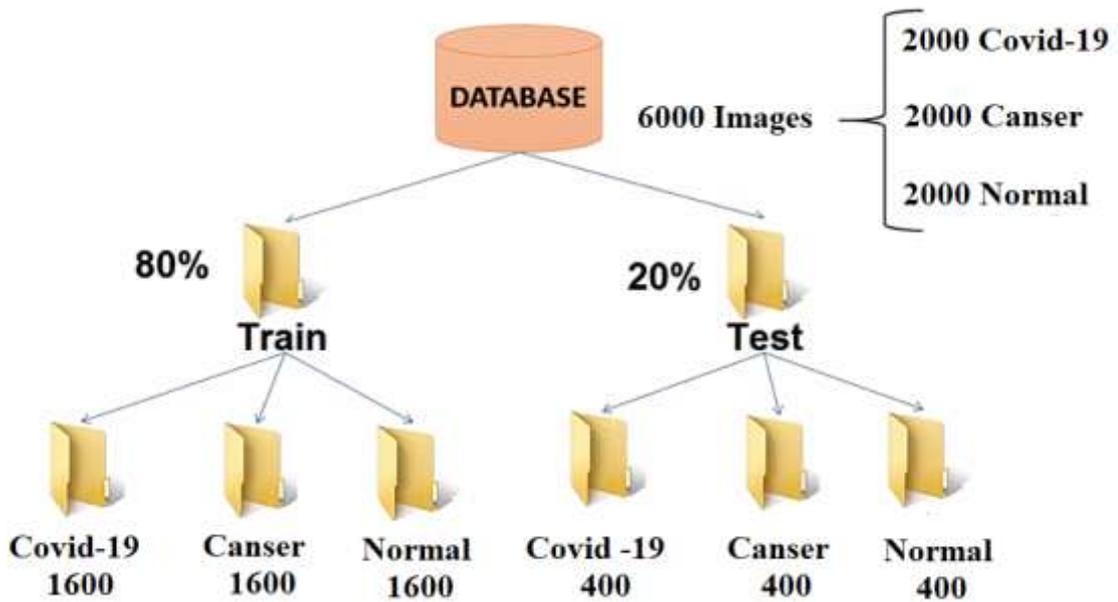


الشكل (12): نموذج الشبكة المقترح.

نلاحظ أن دخل الشبكة يأخذ التمثيل (150,150,3) وهذا يعني أن أبعاد الصور (150,150) وذات 3 قنوات chanels تعبر عن ألوان RGB ، يمكن لنموذجنا استيعاب التفاصيل الدقيقة والميزات الضرورية من الصورة من خلال طبقات الطي.

### 3- تدريب الشبكة المقترحة:

قمنا بتحميل مجموعة البيانات، وتقسيمها إلى مجموعتي تدريب واختبار كما هو موضح بالشكل (13)

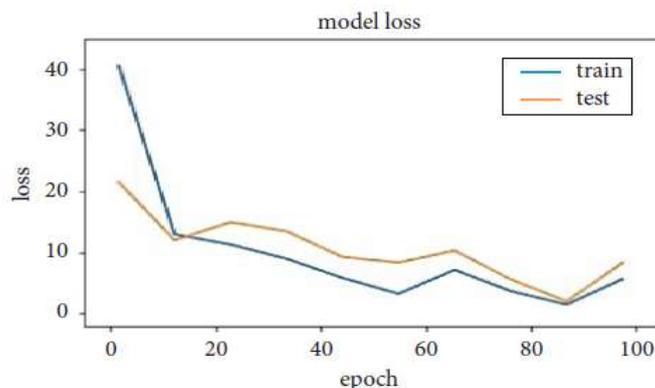


الشكل (13): تقسيم البيانات إلى مجموعتين تدريب واختبار.

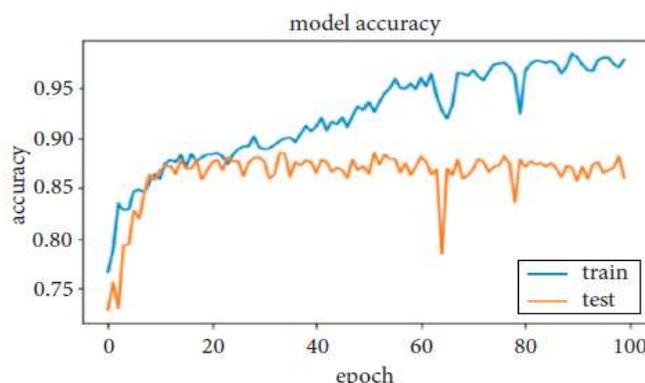
حيث استخدمنا 4800 صورة تدريب و1200 اختبار، ومن ثم قمنا بعملية تقييس للدخل، ولتحقيق ذلك قمنا بتحويل القيم اللونية للصور لتصبح ضمن المجال (0-1)، وبما أنّ الصور في مجموعة التدريب ضمن تدرجات اللون الرمادي (القيم اللونية ضمن المجال 0-255) نقسم القيم على القيمة العظمى (255).  
قمنا بإجراء تجربتين على نوعين من الصور (أشعة سينية - صور مقطعية محوسبة) من أجل اختيار الصور ذات الدقة الأفضل.

## 3-1- التجربة الأولى

قمنا باستخدام المجموعة الأولى من البيانات وهي عبارة عن صور الأشعة السينية للصدر وطبقنا خوارزمية (Adam) لتدريب الشبكة واختبارنا الشبكة المصممة وطبقنا 100 تكرار ويوضح الشكل (14) منحنى الخطأ لكل من معطيات التدريب والاختبار كما يبين الشكل (15) منحنى الدقة لكل من معطيات التدريب والاختبار.



الشكل (14): منحنى الخسارة لكل من مرحلة التدريب والاختبار



الشكل (15): منحنى الصحة لكل من مرحلة التدريب والاختبار

لتوضيح النتائج قمنا برسم مصفوفة الالتباس، حيث يتبين من خلالها نسبة الحالات التي توقع فيها النموذج بشكل صحيح وكذلك الحالات التي فشل النموذج فيها بتوقع الخرج الصحيح ويوضح الشكل (16) مصفوفة الالتباس وتم حساب كل ممايلي:

1- الدقة (accuracy): وهي عدد العينات التي تم توقعها بشكل صحيح على العدد الإجمالي للعينات وتعطى بالعلاقة [19]:

$$Acc = \frac{Tp + Tn}{Tp + Tn + Fp + Fn} \quad (1)$$

2- الحساسية (recall or sensitivity): وهي عدد العينات الصحيحة التي تم كشفها على عدد العينات الصحيحة الإجمالي، وتعطى بالعلاقة [19]:

$$SN = \frac{Tp}{Tp + Fn} \quad (2)$$

3- الخصوصية (Specificity): عدد العينات الخاطئة التي تم كشفها على العدد الإجمالي للعينات الخاطئة، وتعطى بالعلاقة [20]:

$$SP = \frac{Tn}{Tn + Fp} \quad (3)$$

4- مقياس القيمة المتوقعة الخاطئة (Negative Predicated Value): عدد العينات الخاطئة التي تم توقعها على العدد الإجمالي للعينات التي تم توقعها خاطئة، وتعطى بالعلاقة [20]:

$$NPV = \frac{Tn}{Tn + Fn} \quad (5)$$

5- المقياس (F1-score): ويعبر عن العلاقة التوافقية بين المقياسين (precision) و (recall)، ويعطى بالعلاقة [19]:

$$F1 - score = \frac{2 * Tp}{2 * Tp + Fn + Fp} \quad (6)$$

Confusion Matrix

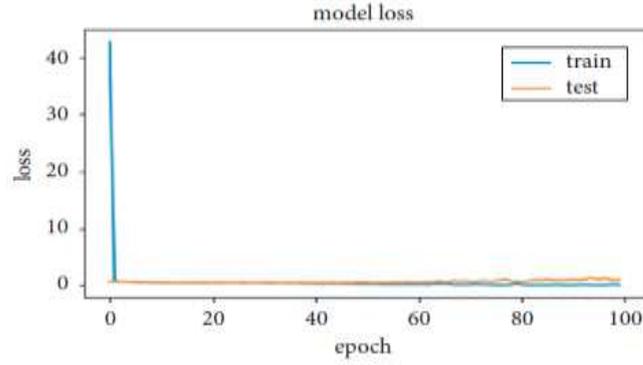
Predicted table	Covid-19	350	50	0
	Cancer	100	300	0
	Normal	10	0	390
	Actual table	Covid-19	Cancer	Normal

الشكل (16): مصفوفة الالتباس للنموذج

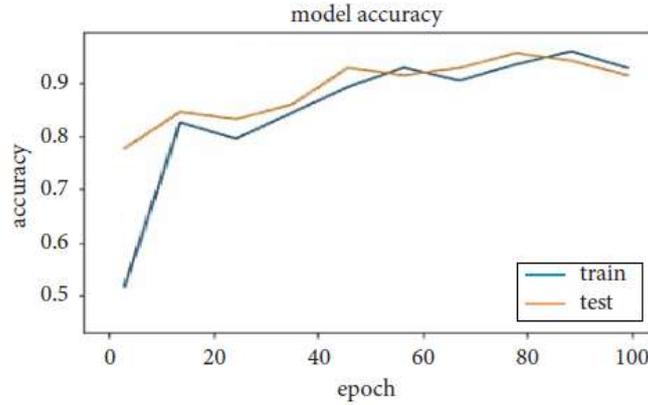
من الشكل (16) نلاحظ أنه من بين 400 مريض مصاب بالكوفيد، استطاع النموذج التنبؤ بشكل صحيح لـ 350 شخص مريض وكانت قيمة التصنيفات الخاطئة لمرضى الكوفيد تساوي 50 قام النموذج بتصنيفهم على أنهم مرضى سرطان، وقام النموذج بتصنيف 300 مريض سرطان بشكل صحيح، وأخطأ النموذج بتصنيف 100 مريض سرطان على أنهم مصابين بالكوفيد، وكما قام النموذج بتصنيف 390 شخص سليم بشكل صحيح وأخطأ بتصنيف 10 أشخاص على أنهم مصابين بالكوفيد، إذاً نتائج النموذج جيدة لكن لا بد من تحسينها.

### 3-2- التجربة الثانية

قمنا باستخدام المجموعة الثانية من البيانات وهي عبارة عن صور مقطعية محوسبة للصدر وطبقنا خوارزمية (Adam) لتدريب واختبارنا الشبكة المصممة وطبقنا 100 تكرار ووضح الشكل (17) منحني الخطأ لكل من معطيات التدريب والاختبار كما يبين الشكل (18) منحني الدقة لكل من معطيات التدريب والاختبار.



الشكل (17): منحنى الخسارة لكل من مرحلة التدريب والاختبار.



الشكل (18): منحنى الصحة لكل من مرحلة التدريب والاختبار

لتوضيح النتائج قمنا برسم مصفوفة الالتباس، حيث يتبين من خلالها نسبة الحالات التي توقع فيها النموذج بشكل صحيح وكذلك الحالات التي فشل النموذج فيها بتوقع الخرج الصحيح ويوضح الشكل (19) مصفوفة الالتباس.

		Confusion Matrix		
		Covid-19	Cancer	Normal
Predicted table	Covid-19	390	10	0
	Cancer	0	400	0
	Normal	0	5	395
		Actual table		
		Covid-19	Cancer	Normal

الشكل (19): مصفوفة الالتباس للنموذج

من الشكل (19) نلاحظ أنه من بين 400 مريض مصاب بالكوفيد، استطاع النموذج التنبؤ بشكل صحيح لـ 390 شخص مريض وكانت قيمة التصنيفات الخاطئة لمرضى الكوفيد تساوي 10 قام النموذج بتصنيفهم على أنهم مرضى سرطان، وقام النموذج بتصنيف 400 مريض سرطان بشكل صحيح، وكانت قيمة التصنيفات الخاطئة لمرضى السرطان معدومة، وكما قام النموذج بتصنيف 395 شخص سليم بشكل صحيح وأخطأ بتصنيف 5 أشخاص على أنهم مصابين بالسرطان، إذاً نتائج النموذج جيدة.

#### 4- مقارنة النتائج

قمنا بحساب كل من (الدقة - الحساسية - الخصوصية - مقياس القيمة المتوقعة الخاطئة - مقياس (F1-Sorce)) لكلا المجموعتين والجدول (1) يوضح ذلك.

الجدول(1): القيم المستخلصة من مصفوفة الالتباس

اسم الشبكة المدربة	ACC	SN	SP	NPV	F1-Sorce
CNN-Xray Images	0.86	0.98	0.72	0.97	0.89
CNN-CT Images	0.98	0.99	0.97	0.98	0.99

نلاحظ من الجدول (1) أن مجموعة البيانات التي تستخدم الصور المقطعية المحوسبة تعطي دقة أفضل في التصنيف من مجموعة البيانات التي تستخدم صور الأشعة السينية.

كما وقمنا بمقارنة النتائج التي حصلنا عليها بالدراسات المرجعية السابقة والجدول (2) يوضح ذلك.

الجدول(2): مقارنة النتائج مع الدراسات المرجعية السابقة

اسم الشبكة المدربة	Xray Images	CT Images
	ACC %	ACC %
CNN	86	98
AlexNet [20,21]	58.62	89.1
VGG19 [20,21]	67.74	93.10
ResNet [20,21]	84.48	93.10
GoogleNet [20,21]	75.86	89.65
SqueezeNet [20,21]	70.68	82.75

نلاحظ من الجدول (2) أن نموذجنا المصمم يعطي دقة أفضل بمقدار 86% للصور الأشعة السينية و 98% للصور المقطعية المحوسبة من النماذج المستخدمة في الدراسات السابقة.

## الاستنتاجات والتوصيات:

### الاستنتاجات:

1- تمكن النظام المقترح من خلال التجارب والنتائج التي تم إجراؤها على مجموعات البيانات التي تم جمعها من عدة مصادر والتي تحتوي على صور أشعة سينية للصدر وصور مقطعية ، تفوق نموذج CNN على النماذج الأخرى المقترحة في الدراسات المرجعية، حيث حقق نموذج CNN المصمم دقة 98 ٪ بناءً على صور المقطعية المحوسبة ودقة 86% بناءً على صور الأشعة السينية.

2- تمكن نموذج CNN المعتمد على مجموعة البيانات (الصور المقطعية المحوسبة) بإعطاء تصنيف أفضل من نموذج CNN المعتمد على مجموعة البيانات (صور الأشعة السينية)

3- استطاع النموذج المعتمد على صور الأشعة السينية التنبؤ بشكل صحيح لـ 350 شخص مريض وكانت قيمة التصنيفات الخاطئة لمرضى الكوفيد تساوي 50 قام النموذج بتصنيفهم على أنهم مرضى سرطان، وقام النموذج بتصنيف 300 مريض سرطان بشكل صحيح، وأخطأ النموذج بتصنيف 100 مريض سرطان على أنهم مصابين

بالكوفيد، وكما قام النموذج بتصنيف 390 شخص سليم بشكل صحيح وأخطأ بتصنيف 10 أشخاص على أنهم مصابين بالكوفيد.

4- استطاع النموذج المعتمد على الصور المقطعية المحوسبة التنبؤ بشكل صحيح لـ 390 شخص مريض وكانت قيمة التصنيفات الخاطئة لمرضى الكوفيد تساوي 10 قام النموذج بتصنيفهم على أنهم مرضى سرطان، وقام النموذج بتصنيف 400 مريض سرطان بشكل صحيح، وكانت قيمة التصنيفات الخاطئة لمرضى السرطان معدومة، وكما قام النموذج بتصنيف 395 شخص سليم بشكل صحيح وأخطأ بتصنيف 5 أشخاص على أنهم مصابين بالسرطان.

#### التوصيات:

- 1- نوصي بدمج أكثر من نوع من الشبكات العصبونية العميقة للحصول على أداء أفضل.
- 2- نوصي بتصميم نموذج قادر على التصنيف بين جميع أمراض الرئة.
- 3- نوصي باستخدام تقنيات أخرى من الذكاء الصناعي مثل (المنطق الضبابي والخوارزمية الجينية و...) ومقارنة أدائها مع الشبكات العصبونية العميقة.

## References:

- [1] D. Cucinotta and M. Vanelli, "WHO declares COVID-19 a pandemic," *Acta Biomedica: Atenei Parmensis*, vol. 91, pp. 157–160, 2020.
- [2] F. Rustam, A. A. Reshi, A. Mehmood et al., "COVID-19 future forecasting using supervised machine learning models," *IEEE Access*, 2020.
- [3] D. J. Cennimo, "Coronavirus disease 2019 (COVID-19) clinical presentation," vol. 8, pp. 101489–101499, 2020, <https://emedicine.medscape.com/article/2500114-clinical#b2>, 2020. Online.
- [4] X-ray (Radiography)-Chest, 2020, <https://www.radiologyinfo.org/en/info.cfm?pg=chestrad#overview>.
- [5] J. P. Cohen, "Github Covid19 X-ray dataset," 2020, <https://github.com/iee8023/covid-chestxray-dataset>, 2020. Online.
- [6] Z. H. Chen, "Mask-RCNN detection of COVID-19 pneumonia symptoms by employing stacked autoencoders in deep unsupervised learning on low-dose high resolution CT," *IEEE Dataport*, 2020.
- [7] A. S. Lundervold and A. Lundervold, "An overview of deep learning in medical imaging focusing on MRI," *Zeitschrift für Medizinische Physik*, vol. 29, no. 2, pp. 102–127, 2019.
- [8] M. Ahmad, "Ground truth labeling and samples selection for hyperspectral image classification," *Optik*, vol. 230, Article ID 166267, 2021.
- [9] B. Kayalibay, G. Jensen, and P. van der Smagt, "CNN-based segmentation of medical imaging data," 2017, <http://arxiv.org/abs/1701.03056>.
- [10] Q. Li, W. Cai, X. Wang, Y. Zhou, D. D. Feng, and M. Chen, "Medical image classification with convolutional neural network," in *Proceedings of the 2014 13th International Conference on Control Automation Robotics & Vision (ICARCV)*, pp. 844–848, Singapore, December 2014.
- [11] M. Umer, S. Sadiq, M. Ahmad, S. Ullah, G. S. Choi, and A. Mehmood, "A novel stacked CNN for malarial parasite detection in blood smear images," *IEEE Access*, vol. 8, pp. 93782–93792, 2020.
- [12] R. Rouhi, M. Jafari, S. Kasaei, and P. Keshavarzian, "Benign and malignant breast tumors classification based on region growing and CNN segmentation," *Expert Systems with Applications*, vol. 42, no. 3, pp. 990–1002, 2015.
- [13] M. Sharif, M. Attique Khan, M. Rashid, M. Yasmin, F. Afza, and U. J. Tanik, "Deep CNN and geometric features-based gastrointestinal tract diseases detection and classification from wireless capsule endoscopy images," *Journal of Experimental & Theoretical Artificial Intelligence*, pp. 1–23, 2019.
- [14] N. Asada, K. Doi, H. MacMahon et al., "Potential usefulness of an artificial neural network for differential diagnosis of interstitial lung diseases: pilot study," *Radiology*, vol. 177, no. 3, pp. 857–860, 1990.
- [15] S. Katsuragawa and K. Doi, "Computer-aided diagnosis in chest radiography," *Computerized Medical Imaging and Graphics*, vol. 31, no. 4-5, pp. 212–223, 2007.
- [16] A. Esteva, B. Kuprel, R. A. Novoa et al., "Dermatologist-level classification of skin cancer with deep neural networks," *Nature*, vol. 542, no. 7639, pp. 115–118, 2017.
- [17] Y. Dong, Y. Pan, J. Zhang, and W. Xu, "Learning to read chest X-ray images from 16000+ examples using CNN," in *Proceedings of the 2017 IEEE/ACM International Conference on Connected Health: Applications, Systems and Engineering Technologies (CHASE)*, pp. 51–57, Philadelphia, PA, USA, July 2017.

- [18] D. Dong, Z. Tang, S. Wang et al., “The role of imaging in the detection and management of COVID-19: a review,” *IEEE Reviews Biomedical Engineering*, vol. 14, pp. 16–19, 2020.
- [19] Sneha Kugunavar, C. J. Prabhakar, “Convolutional neural networks for the diagnosis and prognosis of the coronavirus disease pandemic”, *Visual Computing for Industry, Biomedicine, and Art*, 2021.
- [20] Asmaa Abbas, Mohammed M. Abdelsamea· Mohamed Medhat Gaber, “Classification of COVID-19 in chest X-ray images using DeTraC deep convolutional neural network”, *springer*, (2021) 51:854–864.
- [21] Tao Yan, Pak Kin Wong, Hao Ren, Huaqiao Wang , Jiangtao Wang, Yang Li d, “Automatic distinction between COVID-19 and common pneumonia using multi-scale convolutional neural network on chest CT scans”, *Elsevier*, 2020.