

## تصميم خوارزمية معتمدة على الشبكة العصبونية الالتفافية (CNN) للكشف عن وجود الكتل السرطانية في صور الأشعة السينية للصدر

د.م محمد ملحم\*

م. مضر حماد\*\*

(تاريخ الإيداع 5 / 12 / 2021 . قُبِلَ للنشر في 28 / 2 / 2022)

### □ ملخص □

تستخدم صور الصدر الشعاعية (بالأشعة السينية) في تقييم الأمراض المختلفة ، ويُعد تحليل واختبار هذه الصور من الإجراءات الطبية الشائعة ، نظراً لتكلفتها المنخفضة وانتشارها الواسع. يمكن أن يساهم وجود طرق آلية تعتمد على الذكاء الاصطناعي لتحليل هذه الصور في تحسين الكفاءة وتقليل احتمالية حدوث أخطاء في التشخيص. يتناول هذا البحث تصميم خوارزمية معتمدة على الشبكة العصبونية الالتفافية والمعالجة المسبقة للصورة للكشف عن وجود كتل سرطانية في الرئة في صور الأشعة السينية للصدر. تم اقتراح وتجربة 4 منهجيات للخوارزمية تتضمن معالجة مسبقة للصورة. أظهرت النتائج أن النموذج المتضمن تطبيق مرشح CLAHE ومعيار JPEG لحقق دقة أعلى مقارنة بباقي منهجيات الخوارزمية المقترحة، حيث بلغت دقة التحقق من الصحة للنموذج 92.41% و F1-Score بلغت 0.556 . من جهة أخرى، ساهم استخدام معيار JPEG للضغط الصور المحسنة باستخدام CLAHE بتقليل حجم مجموعة التدريب، مما خفض من مدة تدريب النموذج.

**الكلمات المفتاحية:** الشبكات العصبونية الالتفافية، صور الأشعة السينية للصدر، التعلم العميق، المعالجة المسبقة للصور.

\* مدرس في قسم هندسة النظم الحاسوبية والالكترونيات - كلية هندسة تكنولوجيا المعلومات والاتصالات - جامعة طرطوس- سورية

\*\* طالب ماجستير في قسم هندسة تكنولوجيا الالكترونيات - كلية هندسة تكنولوجيا المعلومات والاتصالات - جامعة طرطوس- سورية

**Dr. Eng. Mohammad Molhem\***  
**Eng. Modar Hammad\*\***

(Received 5/ 12/ 2021 . Accepted 28/ 2/ 2022)

□ **ABSTRACT** □

Chest radiographs (X-rays) are used to assess different pathologies. Analysis and testing of these images is a common medical procedure, due to its low cost and widespread use. Having automated AI-based methods for analyzing these images can improve efficiency and reduce the possibility of misdiagnosis. This paper deals with the design of an algorithm based on convolutional neural network and image preprocessing to detect the presence of lung cancerous masses in chest x-ray images. 4 algorithm methodologies involving image preprocessing are proposed and tested. The results showed that the model that included applying the CLAHE filter and the JPEG standard achieved a higher accuracy compared to the rest of the proposed algorithm methodologies, where the validation accuracy of the model was 92.41% and the F1-Score was 0.556. On the other hand, the use of JPEG standard to compress images optimized with CLAHE reduced the size of the training set, which reduced the training time of the model.

**Keywords:** Convolutional neural networks, Chest X-Ray images, Deep learning, Image preprocessing.

---

Teacher, Computer and Electronic Systems Engineering Department, Information and Communication Technology Engineering, Tartous University, Syria.

\*\* Master student, Electronic Technology Engineering Department, Information and Communication Technology Engineering, Tartous University, Syria.

## 1. مقدمة:

يعد السرطان السبب الرئيس الثاني للوفاة في العالم ، بالمقابل، تتحسن معدلات البقاء على قيد الحياة لأنواع كثيرة من السرطان بفضل التحسينات التي تشهدها طرق الكشف عن السرطان وعلاجه والوقاية منه. يُعد سرطان الرئة نوع من السرطانات التي تبدأ في الرئتين ، وسبباً رئيساً لحالات الوفاة بالسرطان حول العالم. [1] لا تظهر عادة أعراض سرطان الرئة حتى يصل المرض إلى مرحلة متقدمة ، وحتى عندما يتسبب سرطان الرئة في ظهور أعراض، قد يخطئ الكثير من الأطباء في تفسيرها على أنها مشاكل أخرى مثل عدوى ميكروبية أو أنها ناتجة من آثار التدخين على المدى الطويل، وهذا قد يتسبب في تأخير التشخيص مما يستوجب إيجاد حل آلي سريع ودقيق للتشخيص.

المعيار الأفضل حالياً لفحص العقد الرئوية هو أخذ خزعة تحت توجيه الأشعة المقطعية. توفر هذه الطريقة عينة للمساعدة في دقة التشخيص ولكن يمكن أن تؤدي إلى مضاعفات كبيرة مثل استرواح الصدر. لذلك يفضل الكشف عن السرطان من خلال تقنيات التصوير الطبي لتجنب هذه المضاعفات وتوفير الوقت والجهد[2].

توجد العديد من تقنيات التصوير الطبي لتشخيص سرطان الرئة مثل الأشعة السينية، ومسح التصوير المقطعي المحوسب (CT)، والتصوير المقطعي بالإصدار البوزيتروني، والموجات فوق الصوتية، والتصوير بالرنين المغناطيسي. ومع ذلك، يركز هذا المشروع على الأشعة السينية نظراً لتكلفتها المنخفضة وتوافرها بشكل كبير.

الأشعة السينية هي صور ذات تدرج رمادي لجزء معين من الجسم، تكون مظلمة في مناطق ذات كثافة إشعاعية منخفضة (مثل الرئتين) وساطعة في مناطق ذات كثافة إشعاعية عالية (مثل العظام). حيث تظهر الرئتين مظلمتين في الأشعة السينية، بينما الكتل، وهي عبارة عن أنسجة رخوة ذات كثافة إشعاعية أعلى بكثير، تظهر على هيئة كتل بيضاء رمادية.

## 2. الدراسات المرجعية:

يحظى تحليل الصور الطبية باستخدام التعلم العميق باهتمام كبير لدى الباحثين. وتعد تقنية التعلم العميق نسخة متقدمة من الشبكات العصبية الاصطناعية، حيث تحتوي على طبقات متعددة لاستخراج ميزات الصورة والقيام بمهام التصنيف. وقد أثبتت الشبكات العصبونية الانتقافية (CNN) قدرتها على التقاط التفاصيل التي قد يواجه الخبراء البشريون صعوبة في تمييزها بالتالي يمكن أن تقدم نتائج واعدة في تحليل الصور الطبية. بناءً على ذلك ، تم اقتراح العديد من شبكات CNN لتشخيص الأمراض في صور الأشعة السينية للصدر مثل السرطان والالتهاب الرئوي وكورونا وتضخم الجنب.

قام الباحثون في [3] بتطوير شبكة عصبونية اصطناعية (ANN) لاكتشاف سرطان الرئة في جسم الإنسان. تم استخدام الأعراض لتشخيص سرطان الرئة مثل اصفرار الأصابع والقلق والأمراض المزمنة والتعب والحساسية والصفير والسعال وضيق التنفس وصعوبة البلع وألم الصدر. وتبين أن نموذج ANN قادر على اكتشاف وجود أو غياب سرطان الرئة بدقة 96.67%. لكن أعراض سرطان الرئة لا تظهر حتى يصل المرض

لمراحل متقدمة كما يمكن أن تتداخل مع أعراض أمراض أخرى لذلك يفضل استخدام صور الأشعة السينية كخيار مبكر و أفضل للتشخيص.

قدم الباحثون في [4] شبكة عصبونية عميقة (DNN) لتصنيف صور الرئة بالأشعة السينية على أنها طبيعية أم لا، وحققت 87% في دقة التصنيف، إلا أنها استخدمت مجموعة بيانات محدودة، وآلية بسيطة في تصنيف الصور. اقترح الباحثون في [5] نهجاً لتصنيف صور الأشعة السينية للصدر إلى مرضية أو عادية بناءً على نموذج (Faster Regional-CNN). وعلى الرغم من أن النهج المقترح يقلل من وقت الحساب إلا أنه حقق دقة منخفضة نسبياً 62%.

قام الباحثون في [6] بتطبيق التعلم العميق على مجموعة البيانات (NeRDD) التي تحتوي على صور مصنفة على أنها إما طبيعية أو غير طبيعية أو شديدة الخطورة، حيث قاموا باختبار ثلاث بنى للشبكات العصبية. وقد حققت شبكة GoogLeNet دقة 80% فقط، إلا أنهم استخدموا تقنيات بسيطة لمعالجة الصورة مثل معادلة الهيستوغرام (HE).

قدم الباحثون في [7] شبكة تعلم عميق لتصنيف العقيدات الرئوية وتضخم القلب، حيث تحتوي الشبكة المقترحة على AUC عالي (0.91) لتصنيف تضخم القلب، و AUC معتدل (0.73) لتصنيف العقيدات، إلا أنهم لم يستخدموا تقنيات المعالجة المسبقة للصور.

### 3. هدف البحث:

سنقوم في هذا البحث بتصميم خوارزمية معتمدة على الشبكة العصبونية الالتفافية (CNN) لتصنيف صور الأشعة السينية للصدر إلى فئتين (إما تحتوي على كتل في الرئة أو لا تحتوي على كتل في الرئة). حيث سنقوم بتصميم شبكة CNN لهذا العمل.

سنطبق أيضاً المعالجة المسبقة للصور من خلال مرشح معادلة الهيستوغرام التكيفي المحدود التباين (CLAHE) [13] لتحسين التباين المحلي للصورة، ثم ضغط الصور باستخدام معيار (JPEG) المعتمد على تحويل جيب التمام المتقطع (DCT) [10] لتقليل حجم الصور، وبالتالي تسريع انجاز الحسابات وتخفيض زمن تدريب الشبكة العصبونية.

ومن ثم نقوم بمقارنة أداء CNN قبل وبعد تطبيق المعالجة المسبقة للصور (CLAHE-JPEG). أيضاً تم استخدام لغة البرمجة بايثون وموقع "Google Colab" في التصميم والاختبار.

## 4. طرائق البحث ومواده:

### 4.1 الشبكات العصبونية الالتفافية:


تعد الشبكات العصبونية الالتفافية (CNN) نوع من بنى التعلم العميق لمعالجة البيانات الضخمة، ويتم تطبيقها على نطاق واسع لمعالجة تحديات تحليل التصوير الطبي. [15]

تتميز شبكات CNN على طرق التعلم الآلي الأخرى بأنها لا تتطلب استخراج يدوي للميزات، كما لا تتطلب بنيتها بالضرورة تقسيماً معيناً بواسطة خبراء بشريين. يظهر نموذج CNN العام كما في الشكل (1).

تحتوي CNN على العديد من الطبقات، وهي طبقة الإدخال، والطبقات المخفية التي تحتوي على الالتفاف مع طبقة (ReLU) وطبقة التجميع، والطبقة المتصلة بالكامل، وطبقة الإخراج.

طبقة الإدخال هي مرحلة تحميل بيانات الدخل مثل ملف الصورة. أما الطبقة الالتفافية تحتوي على عملية الالتفاف لاستخراج الميزات وذلك عن طريق أخذ بيانات الإدخال وتصنيفها باستخدام أنواع مختلفة من مرشحات الالتفاف لاستخلاص مجموعة من خرائط الميزات. بعد ذلك، يتم تنفيذ طبقة ReLU التي تستخدم دالة تنشيط خطية، حيث تعين قيم الإدخال السلبية إلى الصفر.

بمجرد الانتهاء، يتم إجراء طبقة التجميع لتنفيذ عملية أخذ العينات على خرائط الميزات الناتجة. سيتم عمل طبقة الالتفاف وطبقة التجميع في دورات قليلة، حيث تكون نتيجة كل دورة من طبقة التجميع هي مصفوفة أحادية البعد. يصبح هذا المتجه المدخل لتكوين الطبقة المتصلة بالكامل، حيث تبدأ عملية التعلم بتحديد العلاقة بين الميزات. نتيجة عملية التعلم هي تحديد فئة أو تسمية معينة، كجزء من طبقة المخرجات. [5]



الشكل (1): نموذج شبكة CNN

### 2.4 تصميم شبكة CNN المقترحة:

سنقوم بتصميم شبكة CNN تحتوي على 14 طبقة على النحو الآتي:

1. طبقة الإدخال.
2. طبقات الالتفافية (وعددها 5 طبقات).
3. طبقات التجميع Pooling (وعددها 5 طبقات).
4. طبقة التسطيح Flatten.
5. طبقة التكتيف Dense.
6. طبقة الإخراج.


دخل الشبكة هو صور ذات تدرج رمادي بأبعاد  $3 \times 512 \times 512$ ، لذلك سنقوم بتغيير أبعاد جميع الصور إلى  $3 \times 512 \times 512$ .

استخدمنا في الـ CNN المقترحة تقنية "Same Padding". كما اعتمدنا استخدام دالة تنشيط "RELU" فهي أقل تكلفة من الناحية الحسابية وتتعلم بشكل أسرع من دوال التنشيط الأخرى وتحقق المعادلة  $A(x) = \max(0, x)$ . كما استخدمنا التجميع الأقصى (Max Pooling) في طبقة التجميع لإرجاع القيمة القصوى لجزء الصورة الذي تغطيه النواة (Kernel)، وهذا يقلل من الضجيج في الصورة.

أيضاً قمنا باستخدام طبقة Dense بـ 64 عقدة، وكون التصنيف هنا هو تصنيف ثنائي فستكون طبقة الخرج هي Dense بعقدتين فقط حيث تستخدم دالة السيجمويد "Sigmoid" والتي لها المعادلة الآتية:

$$F(x) = \frac{1}{1 + e^{-x}}$$

يوضح الشكل (2) بنية CNN المقترحة، ويبين الجدول (1) ترتيب طبقات شبكة CNN المقترحة مع أبعاد الخرج في كل طبقة وعدد البارامترات القابلة للتدريب، حيث تحتوي الشبكة المقترحة على 2,394,434 بارامتر جميعها قابلة للتدريب.



الشكل (2): بنية شبكة CNN المقترحة

الجدول (1): ترتيب طبقات CNN المقترحة مع أبعاد الصورة في كل طبقة وعدد البارامترات القابلة للتدريب

Layer (type)	Output Shape	Parameters #
img_input(InputLayer)	[(None, 512, 512, 3)]	0
layer_1 (Conv2D)	(None, 512, 512, 64)	1792
layer_2(MaxPooling2D)	(None, 256, 256, 64)	0
dropout (Dropout)	(None, 256, 256, 64)	0
layer_3 (Conv2D)	(None, 256, 256, 64)	36928
layer_4 (MaxPooling2D)	(None, 128, 128, 64)	0
dropout_1 (Dropout)	(None, 128, 128, 64)	0
layer_5 (Conv2D)	(None, 128, 128, 64)	36928
layer_6 (MaxPooling2D)	(None, 64, 64, 64)	0
dropout_2 (Dropout)	(None, 64, 64, 64)	0
layer_7 (Conv2D)	(None, 64, 64, 128)	73856
layer_8 (MaxPooling2D)	(None, 32, 32, 128)	0
dropout_3 (Dropout)	(None, 32, 32, 128)	0
layer_9 (Conv2D)	(None, 32, 32, 128)	147584
layer_10(MaxPooling2D)	(None, 16, 16, 128)	0
dropout_4 (Dropout)	(None, 16, 16, 128)	0
flatten (Flatten)	(None, 32768)	0
layer_11 (Dense)	(None, 64)	2097216
dropout_5 (Dropout)	(None, 64)	0
output_layer (Dense)	(None, 2)	130
Total params: 2,394,434		
Trainable params : 2,394,434		
Non-trainable params: 0		

### 3.4 وصف مجموعة البيانات:

تعد مجموعة البيانات (ChestX-ray14) من أكبر مجموعات البيانات لصور الصدر بالأشعة السينية المتاحة على الإنترنت، والتي تحتوي على 112,120 صورة بالأشعة السينية لـ 30,805 مريض، حيث تكون جميع الصور بحجم  $1024 \times 1024$  بكسل. [8]

تحتوي ChestX-ray14 على 15 صنفاً (14 مرضاً وصنف واحد باسم لا توجد نتائج "No-Finding"). يمكن تصنيف الصور على أنها "لا توجد نتائج" أو إلى تصنيف واحد أو أكثر من فئات الأمراض: (انخماص، دمج، تسرب، استرواح الصدر، الوذمة، انتفاخ الرئة، تليف رئوي، الانصباب، التهاب رئوي، سماكة الجنب، تضخم القلب، كتل، عقيدات، فتق).

فيما يتعلق بهذا البحث، قررنا اختيار 1628 صورة أشعة سينية للصدر من ChestX-ray14، حيث تنتمي 814 صورة منها إلى الصنف الذي يحتوي على كتل في الرئة (سنشير له بـ "Mass")، و814 صورة تنتمي إلى


الصف (لا توجد نتائج) أي لا يحتوي على كتل (سنشير له بـ "No Mass")، حيث تكون جميع الصور بالاتجاه الأمامي الخلفي (PA)، وبصيغة .png.

قمنا بتقسيم مجموعة البيانات بنسبة 70% للتدريب و15% للتحقق من الصحة و15% للاختبار، ويوضح الجدول (2) عدد صور التدريب والتحقق من الصحة والاختبار المستخدمة في هذا البحث.

الجدول (2) عدد صور التدريب والتحقق من الصحة والاختبار

الاختبار	التحقق من الصحة	التدريب	صنف الصور
122	122	570	Mass
122	122	570	No Mass

يبين الشكل (3) صورتي أشعة سينية للصدر مأخوذتين من مجموعة البيانات ChestX-ray14، حيث (a) تحتوي على كتل في الرئة (Mass) و (b) لا تحتوي على كتل (No Mass).



(b)

(a)

الشكل (3): صورتي أشعة سينية للصدر مأخوذتين من مجموعة البيانات ChestX-ray14

#### 4.4 المعالجة المسبقة للصور:

يعد تحسين الصورة أسلوباً مهماً لمعالجة الصور، حيث يسלט الضوء على المعلومات الأساسية في الصورة ويقلل أو يزيل معلومات ثانوية معينة لتحسين جودة النتائج. الهدف هو جعل الصور ملائمة أكثر لتطبيق معين من الصور الأصلية. استخدمنا في هذا البحث تقنيتين هما مرشح (CLAHE) ومعيار الضغط (JPEG).

##### 4.4.1 مرشح CLAHE:

تهدف تقنية معادلة الهستوغرام (HE) إلى توزيع المستويات الرمادية داخل الصورة، حيث يغير HE سطوع وتباين الصور المظلمة وذات التباين المنخفض لتحسين جودة الصورة. [12]

يسمى HE المحسن بمعادلة الهستوغرام التكيفي (AHE)، حيث يطبق HE على مناطق صغيرة في الصورة، وبالتالي يعزز تباين كل منطقة على حدة. وهذا يمكن أن يزيد من تضخيم مكون الضجيج في الصورة. [9][12]

عند تطبيق HE على صور الأشعة السينية، لوحظ أنها تشبع مناطق معينة. لمعالجة هذه المشكلة، يستخدم CLAHE نفس النهج مثل AHE ولكن مقدار تحسين التباين الذي يمكن إنتاجه داخل المنطقة المحددة

محدود بمعامل عتبة. بالتالي تبدو الصور المحسنة باستخدام CLAHE أكثر طبيعية في المظهر من تلك التي ينتجها HE.

لتطبيق CLAHE يتم أولاً تحويل الصورة الأصلية من مساحة الألوان RGB إلى مساحة الألوان HSV (تدرج اللون والتشبع والقيمة). ثانياً، تتم معالجة قيمة HSV بواسطة CLAHE دون التأثير على تدرج اللون والتشبع. ثم يتم اقتصاص الهستوغرام الأولي وإعادة توزيع كل مستوى رمادي على وحدات البيكسل التي تم اقتصاصها. ويتم تقليل قيمة كل بيكسل إلى حد يختاره المستخدم. أخيراً، يتم إعادة تحويل الصورة المعالجة HSV إلى مساحة الألوان RGB [9][13].

يبين الشكل (4) صورة الأشعة السينية الأصلية والمحسنة باستخدام تقنيتي HE و CLAHE مع مخطط الهستوغرام المقابل لكل صورة.






الصورة المحسنة باستخدام

الصورة المحسنة باستخدام HE

الصورة الأصلية

CLAHE



مخطط الهستوغرام للصورة المحسنة

مخطط الهستوغرام للصورة

مخطط الهستوغرام للصورة الأصلية

بإستخدام CLAHE

المحسنة باستخدام HE

الشكل (4): صورة الأشعة السينية الأصلية والمحسنة باستخدام تقنيتي HE و CLAHE مع مخطط الهستوغرام المقابل لكل صورة.

4.4.2 معيار الضغط JPEG:

بعد ضغط الصور من بين العديد من التقنيات المستخدمة في معالجة الصور، وله العديد من التطبيقات فهو يلعب دوراً مهماً في نقل الصور وتخزينها بكفاءة يهدف ضغط الصور إلى تقليل عدد البتات المطلوبة لتمثيل المعلومات في صورة ما عن طريق إزالة التكرار الموجود فيها، حيث يوجد ثلاثة أنواع من التكرار:

1. التكرار المكاني، والذي يرجع إلى الارتباط أو الاعتماد بين قيم البيكسل المجاورة.
2. التكرار الطيفي، والذي يرجع إلى الارتباط بين مستويات الألوان المختلفة أو النطاقات الطيفية.
3. التكرار النفسي البصري، ويعود إلى حقيقة أن العين البشرية غير حساسة لبعض الترددات المكانية.

يعد (JPEG (Joint Photographic Experts Group) نظام ضغط مع خسارة ، وقد تم تصميمه

$$F(u, v) = \frac{C(u) C(v)}{4} \sum_{i=0}^7 \sum_{j=0}^7 \cos \frac{(2i+1)u\pi}{16} \cos \frac{(2j+1)v\pi}{16} f(i, j)$$

خصيصاً  
لتجاهل  
المعلوما

ت التي لا تستطيع العين البشرية رؤيتها بسهولة ، فالتغيرات الطفيفة في اللون لا تدركها العين البشرية بشكل

$$\tilde{f}(i, j) = \sum_{u=0}^7 \sum_{v=0}^7 \frac{C(u) C(v)}{4} \cos \frac{(2i+1)u\pi}{16} \cos \frac{(2j+1)v\pi}{16} F(u, v)$$

جيد ، بينما تدرك التغييرات الطفيفة في الشدة.

يستخدم JPEG "تحويل الترميز" والذي يقوم بتحويل الصورة من تمثيل المجال المكاني إلى نوع مختلف من التمثيل باستخدام بعض التحويلات المعروفة ثم ترميز القيم المحولة (المعاملات). توفر هذه الطريقة ضغطاً أكبر للبيانات مقارنة بالطرق التنبئية وتعتمد بشكل أساسي على تحويل جيب التمام المتقطع [10] DCT والذي له العلاقة (1) الآتية [14]:

(1)

ويعبر عن تحويل جيب التمام المتقطع IDCT العكسي بالعلاقة (2) الآتية [14]:


(2)

يقوم تحويل جيب التمام المتقطع "DCT" بفصل الصور إلى أجزاء من الترددات المختلفة ، حيث يتم تجاهل الترددات الأقل أهمية من خلال التكميم ، بينما تستخدم الترددات المهمة لاسترداد الصورة أثناء فك الضغط. بالمقارنة مع المحولات الأخرى المعتمدة على المدخلات ، تتمتع DCT بالعديد من المزايا كالقدرة على تجميع معظم المعلومات في أقل عدد من المعاملات ، بالإضافة إلى تنفيذها في دارة متكاملة "IC" واحدة.

خطوات الضغط باستخدام معيار JPEG المعتمد على [11] DCT:

1. تقسم الصورة الأصلية إلى بلوكات (Blocks) كل منها بحجم  $8 \times 8$ .

2. قيم البيكسل لنطاق الصورة بالأبيض و الأسود من 0-255 ولكن تم تصميم DCT للعمل على قيم بكسل تتراوح من -128 إلى 127، لذلك يتم تعديل كل بلوك للعمل في النطاق المذكور.
  3. حساب مصفوفة DCT.
  4. تطبيق DCT على كل بلوك.
  5. ثم يتم ضغط كل بلوك من خلال التكميم.
  6. ثم يتم ترميز الانتروبيا من خلال مصفوفة التكميم.
  7. يتم إعادة بناء الصورة المضغوطة من خلال عملية عكسية.
  8. يستخدم DCT العكسي لفك الضغط.
- يبين الشكل (5) مثال لصورة أشعة سينية قبل وبعد ضغطها باستخدام JPEG، والصورة بعد تطبيق "DCT"  $8 \times 8$ ، كما يبين بلوك بحجم  $8 \times 8$  مأخوذ من الصورة قبل وبعد تطبيق DCT.



الشكل (5): (a) الصورة الأصلية (b) الصورة بعد ضغطها بـ JPEG (c) الصورة بعد DCT  $8 \times 8$  (d) بلوك  $8 \times 8$  مأخوذ من الصورة الأصلية (e) البلوك بعد DCT  $8 \times 8$ .


#### 4.5 خوارزمية العمل المقترحة:

نصمم في هذا البحث خوارزمية لتصنيف صور الأشعة السينية للصدر، حيث سنقوم بتدريب واختبار شبكة CNN المقترحة وفقرابعة منهجياتكالتالي:

1. المنهجية الأولى: تدريب واختبار CNN على مجموعة البيانات بدون أي معالجة مسبقة للصور.
2. المنهجية الثانية: تدريب واختبار CNN على مجموعة البيانات بعد تطبيق JPEG فقط.
3. المنهجية الثالثة: تدريب واختبار CNN على مجموعة البيانات بعد تطبيق CLAHE فقط.

4. المنهجية الرابعة: تدريب واختبار CNN على مجموعة البيانات بعد تطبيق CLAHE ثم JPEG.

يبين الشكل (6) مخطط الخوارزمية لكل منهجية من منهجيات الخوارزمية المقترحة:



الشكل (6): مخطط الخوارزمية لكل منهجية من المنهجيات المقترحة

## 5. النتائج والمناقشة:

تم تدريب شبكة الـ CNN باستخدام محسن "Adam" لـ 100 تكرار (epoch) مع حجم دفعة (batch size) يساوي 32.

كما تم استخدام تقنية التوقف المبكر (early stopping) [16] لإيقاف تدريب النموذج في حالة عدم تحسن دقة التحقق (validation accuracy) خلال 20 تكرار، وذلك لتجنب التلاؤم المفرط (overfitting). يوضح الجدول (3) النتائج التي حصلنا عليها والمقابلة لأفضل دقة تحقق.

تتيح المقاييس الموجودة في مجموعة التدريب (accuracy) معرفة مدى تقدم النموذج فيما يتعلق بالتدريب، فيما تتيح لنا المقاييس الموجودة في مجموعة التحقق من الصحة (Val-accuracy) الحصول على مقياس لجودة النموذج، وإلى أي مدى يمكنه إجراء تنبؤات جديدة استناداً إلى بيانات لم يرها من قبل.

الجدول (3): نتائج التدريب لكل منهجية من منهجيات الخوارزمية المقترحة

المنهجية	الدقة (Accuracy)	دقة التحقق (Val-Accuracy)	الخسارة (Loss)	خسارة التحقق (Val-Loss)
الأولى	97.14 %	86.16 %	8.52 %	37.03 %
الثانية	93.95 %	90.18 %	16.60 %	32.39 %
الثالثة	98.10 %	91.92 %	5.96 %	42.62 %
الرابعة	97.29 %	92.41 %	7.81 %	37.56 %

تم اختبار كل نموذج مدرب من خلال مجموعة اختبار مكونة من 244 صورة، ثم حساب مصفوفة الارتباك (Confusion Matrix) والتي نحصل من خلالها على أربع قيم أساسية كالتالي:

$$AC = \frac{Tp+Tn}{Tp+Tn+Fp+Fn} : \text{الدقة (Accuracy)}$$

$$PR = \frac{Tp}{Tp+Fp} : \text{الضبط (Precision)}$$

$$SE = \frac{Tp}{Tp+Fn} : \text{الحساسية (Sensitivity)}$$

$$SP = \frac{Tn}{Tn+Fp} : \text{الخصوصية (Specificity)}$$

حيث يكون  $Tp$  الإيجابي الحقيقي،  $Fp$  الإيجابي الخاطئ،  $Tn$  السلبي الحقيقي، و  $Fn$  السلبي الخاطئ. يوضح الشكل (7) مصفوفة الارتباك لكل منهجية.

		التصنيف المتوقع	
		Mass	No Mass
التصنيف الحقيقي	Mass	53	69
	No Mass	51	71
		Mass	No Mass

المنهجية الثانية

		التصنيف المتوقع	
		Mass	No Mass
التصنيف الحقيقي	Mass	45	77
	No Mass	53	69
		Mass	No Mass

المنهجية الأولى

		التصنيف المتوقع	
		Mass	No Mass
التصنيف الحقيقي	Mass	66	56
	No Mass	49	73

		التصنيف المتوقع	
		Mass	No Mass
التصنيف الحقيقي	Mass	66	56
	No Mass	50	72

Mass No Mass


Mass No Mass

المنهجية الرابعة


المنهجية الثالثة

الشكل (7): مصفوفة الارتباك لكل منهجية من منهجيات الخوارزمية

يبين الشكل(8) مخطط بياني لحجم مجموعة التدريب والتحقق في كل منهجية، كما يبين الشكل (9) مخطط بياني للزمن الذي استغرقه النموذج في التدريب باستخدام Google Colab.



الشكل (8): المخطط البياني لحجم مجموعة التدريب والتحقق (بالـ MB)



الشكل (9): المخطط البياني لزمن تدريب النموذج (بالثانية)

تعتبر F1-score مقياساً لدقة النموذج في مجموعة البيانات. يتم استخدامه لتقييم أنظمة التصنيف الثنائية، والتي تصنف الأمثلة إلى "إيجابية" أو "سلبية". وهي طريقة للجمع بين "precision" و"sensitivity" للنموذج، وتحسب من العلاقة:

$$F1\text{-Score} = \frac{2 * (precision * sensitivity)}{(precision + sensitivity)}$$

يعرض الجدول (4) قيم precision و sensitivity و F1-Score لكل منهجية.

الجدول (4): قيم precision و sensitivity و F1-Score لكل منهجية

F1-Score	Sensitivity	Precision	المنهجية
0.408	0.368	0.459	الأولى
0.468	0.434	0.509	الثانية
0.553	0.540	0.568	الثالثة
0.556	0.540	0.573	الرابعة

تبين النتائج أن المنهجية الرابعة، وهي استخدام مرشح CLAHE ثم ضغط الصور باستخدام JPEG، أعطت أفضل نتيجة حيث بلغت دقة التحقق من الصحة أثناء التدريب 92.41% وذلك مقارنة بالمنهجيات الأخرى، كما أعطت أفضل النتائج من حيث Precision و Sensitivity و F1-Score والتي بلغت 0.573 و 0.540 و 0.556 على التوالي.

ويعود ذلك الى أن مرشح CLAHE يحسن تباين الصورة ويقلل الضجيج في المناطق المتجانسة الناتج عن AHE. كما أن استخدام JPEG خفض حجم الصور بشكل كبير عن طريق حذف المعلومات غير الضرورية من الصور مما ساهم بتحسين النتائج وتقليل مدة تدريب النموذج من 4751 ثانية إلى 2330 ثانية كما هو مبين بالشكل (8).

من جهة أخرى أعطت المنهجية الرابعة المعتمدة على CLAHE و JPEG عند الاختبار أفضل النتائج مقارنة بباقي المنهجيات المقترحة في هذا البحث حيث قامت بالتصنيف الصحيح لـ 73 صورة من أصل 122 صورة لا تحوي كتل في الرئة، بالمقابل تم التعرف بشكل صحيح على 66 صورة من أصل 122 صورة تحوي كتل في الرئة. يفسر انخفاض دقة الاختبار للمنهجية المذكورة سابقاً بسبب حدوث التلائم المفرط (overfitting)، والذي يمكن التغلب عليه عن طريق زيادة الصور في مجموعة البيانات أو استخدام التنظيم (Regularization) [16].

### الاستنتاجات و التوصيات:

قمنا في هذا البحث بتصميم خوارزمية معتمدة على شبكة عصبونية التفافية CNN مؤلفة من 5 طبقات التفافية للكشف عن وجود الكتل في صور الأشعة السينية للصدر، حيث اقترحنا 4 منهجيات كالتالي (بدون معالجة مسبقة للصور، تطبيق JPEG، تطبيق CLAHE، تطبيق CLAHE ثم JPEG).

وبمقارنة نتائج التدريب والاختبار نلاحظ أن منهجية استخدام CNN مع معالجة مسبقة للصور (CLAHE ثم JPEG) أعطت أفضل النتائج حيث بلغت دقة التحقق من الصحة 92.41% و F1-Score بلغت 0.556. من جهة أخرى، ساهم استخدام معيار JPEG للضغط الصور المحسنة باستخدام CLAHE بتقليل حجم مجموعة التدريب من 2313 ميغابايت إلى 595 ميغابايت، مما خفض من مدة تدريب النموذج من 4751 ثانية إلى 2330 ثانية.

من الممكن استخدام اكثر من نوع للمرشحات و تحقيق دقة عالية في المستقبل من خلال استخدام المزيد من الصور في مجموعة البيانات، وتجزئة الرئتين باستخدام شبكة U-Net مع تطبيق تقنيات تحسين الصورة.

## المراجع

- [1]. <https://www.mayoclinic.org/ar/diseases-conditions/lung-cancer/diagnosis-treatment/drc-20374627> (2021)
- [2]. <https://www.rbhh-specialistcare.co.uk/news/lung-cancer-diagnostic-breakthrough-new-hope-for-high-risk-emphysema-patients-%28arabic%29> (2021)
- [3]. I. M. Nasser and S. S. Abu-naser, "Lung Cancer Detection Using Artificial Neural Network," no. March, 2019.
- [4]. I. O. P. C. Series and M. Science, "Automatic Classification and Accuracy by Deep Learning Using CNN Methods in Lung Chest X-Ray Images," pp. 0–6, 2021, doi: 10.1088/1757-899X/1055/1/012099.
- [5]. T. Rahmat, A. Ismail, and S. Aliman, "Chest X-ray Image Classification using Faster R-CNN CHEST X-RAY IMAGE CLASSIFICATION USING FASTER R-CNN," no. May, 2019.
- [6]. C. Tataru, D. Yi, A. Shenoyas, and A. Ma, "Deep Learning for abnormality detection in Chest X-Ray images," *IEEE Conf. Deep Learn.*, 2017, [Online]. Available: <http://cs231n.stanford.edu/reports/2017/pdfs/527.pdf>.
- [7]. M. Majdi, K. N. Salman, and J. J. Rodriguez, "Deep learning classification of chest x-ray images," no. May, 2020.
- [8]. <https://www.kaggle.com/nih-chest-xrays/data>
- [9]. T. Rahman *et al.*, "Exploring the effect of image enhancement techniques on COVID-19 detection using chest X-ray images," *Comput. Biol. Med.*, vol. 132, no. November 2020, p. 104319, 2021, doi: 10.1016/j.combiomed.2021.104319.
- [10]. A. M. Raid, W. M. Khedr, and W. Ahmed, "Jpeg Image Compression Using Discrete Cosine Transform - A Survey," vol. 5, no. 2, pp. 39–47, 2014.
- [11]. B. Gautam, "Image compression using discrete cosine transform & discrete wavelet transform," no. 10606053. Rourkela Deemed University. May, 2010
- [12]. H. Nguyen, "Tinku\_Acharya\_Ajoy\_K," Image Processing Principles and Applications vol. 16, no. 2, pp. 111-113, 2005.
- [13]. K. Zuiderveld: Contrast Limited Adaptive Histogram Equalization. In: P. Heckbert: *Graphics Gems IV*, Academic Press 1994.
- [14]. Z. Li and M. S. Drew, *Fundamentals of Multimedia*. no. 2, pp. 233 – 236. Springer, 2004.
- [15]. O. Stephen, M. Sain, U. J. Maduh, and D. U. Jeong, "An Efficient Deep Learning Approach to Pneumonia Classification in Healthcare," *J. Healthc. Eng.*, vol. 2019.
- [16]. حسن البستاني. الشبكات العصبونية. جامعة تشرين، 2016، 554–552