

الكشف عن سرطان الجلد باستخدام التعلم العميق

د. سحر العلي* م. أوس محمد محمد**

(الإيداع: 22 تشرين الأول 2023، القبول: 13 كانون الأول 2023)

الملخص:

يعد سرطان الجلد واحد من أكثر سرطانات الجلد شيوعاً والكشف المبكر عنه يساعد في تقليل من نسبة انتشار المرض والتقليل من نسبة الوفيات، ولكن يؤدي الاكتشاف المبكر أحياناً إلى التشخيص الخاطئ بسبب أخطاء بشرية ناجمة عن التعب البصري، ويكون التشخيص الخاطئ مكلف ومجهد للمريض نفسياً، لذلك كان لابد من وضع منهجية عمل لتشخيص سرطان الجلد بشكل آلي باستخدام خوارزمية تعتمد على معالجة الصورة، حيث تم جمع قاعدة البيانات لصور سرطان الجلد تعود لأشخاص مختلفي العمر والجنس واللون، كما تم الأخذ بالحسبان اختلاف الخلفية والبعد عن الكاميرا وموضع الشامة، ومن ثم تم تطبيق بعض تقنيات معالجة الصورة من معالجة أولية وتجزئة الصور، المورفولوجي وبالاستناد إلى الدراسات المرجعية السابقة تم بناء خوارزمية تعتمد على الشبكات العصبونية الالتفافية لكشف سرطان الجلد وتصنيفه إلى حالات خبيثة أو حميدة حيث حققت دقة تصل إلى 96%.

الكلمات المفتاحية: سرطان الجلد ، الشبكات العصبونية الالتفافية ، تجزئة الصورة، المورفولوجي.

* مدرس في قسم هندسة الأتمتة الصناعية- كلية الهندسة التقنية – جامعة طرطوس

** حاصل على درجة الماجستير – قسم هندسة الأتمتة الصناعية – كلية الهندسة التقنية – جامعة طرطوس

Diagnosis of skin cancer using convolution neural network

**Eng. Aous Mohammad *Dr. Sahar AL Ali

(Received: 22 October 2023,Accepted: 13 December 2023)

Abstract:

Skin cancer is one of the most common skin cancers, and its early detection helps reduce the spread of the disease and reduce the death rate, but visual detection sometimes leads to misdiagnosis due to human errors resulting from visual fatigue, and the wrong diagnosis is costly and stressful for the patient psychologically.

Therefore, it was necessary to develop a working methodology to diagnose skin cancer automatically using an algorithm based on image processing, where a database of skin cancer images belonging to people of different age, gender and color was collected, and the difference in background, distance from the camera and the location of the mole was taken into account, and then the application was applied. Some image processing techniques from primary processing and image segmentation. Based on previous reference studies, we will build an algorithm based on convolutional neural networks to detect skin cancer and classify it into malignant or benign conditions, It achieved an accuracy of up to 96%.

Key words: Skin cancer, convolution neural network, image segmentation, morphology

* Teacher– Industrial Automation Engineering Department – Faculty of Technical Engineering – Tartous university

** Get a master's degree – Industrial Automation Engineering Department – Faculty of Technical Engineering – Tartous university

1. المقدمة:

يعد سرطان الجلد أحد أنواع أمراض السرطان شيوعاً حيث تمثل نسبة حالات الإصابة به نحو ثلث إجمالي حالات السرطان على اختلاف أنواعها، وتشير الإحصائيات المتوافرة حالياً إل أن هناك 2-3 مليون حالة إصابة بسرطان الجلد غير الميلانيني، و132 ألف حالة إصابة بسرطان الخلايا الصبغية (الميلانوما) تسجل سنوياً في كافة أنحاء العالم [1]. كما يحتل هذا النوع من السرطان المرتبة التاسعة لجهة معدلات انتشاره بين الرجال والنساء على حدٍ سواء [2]، وتحتل استراليا المرتبة الأولى في العالم من حيث الإصابة بسرطان الجلد [3]. لذلك فإن الكشف المبكر عن سرطان الجلد يساعد في التقليل من نسبة انتشار المرض والتقليل من نسبة الوفيات ويبين الجدول (1) عدد الحالات الجديدة لكافة أنواع السرطانات حول العالم بالمقارنة مع سرطان الجلد عام 2023.

الجدول (1): عدد الحالات الجديدة لكافة أنواع السرطانات حول العالم بالمقارنة مع سرطان الجلد.

الرجال	النساء	الحالات الكلية	عدد الحالات
7.4 million	6.7 million	14.1 million	كافة أنواع السرطان حول العالم [4]
121 thousands	111 thousands	232 thousands	سرطان الجلد حول العالم [4]

ومع تطور تقنيات التصوير الطبية نتيجة التطورات الحاصلة في المجالات الحاسوبية المختلفة ظهرت فجوة بين ما تقدمه هذه التقنيات من بيانات طبية تحتوي على معلومات دقيقة ومهمة وبين قدرات العناصر البشرية المحدودة على تحليل هذه المعلومات الأمر الذي دفع باتجاه البحث عن حلول حاسوبية مساعدة في عملية التشخيص تقدم رأياً ثانياً مساعداً لهذه العناصر البشرية.

2. مشكلة البحث:

إن كثرة الصور المراد تشخيصها وخلال زمن قصير قد يقع الطبيب في تشخيص خاطئ والتي يمكن للحاسب أن يتدارك هذه الأخطاء ويخفف هذا العبء عن الطبيب ويدعم رأيه، تتركز مشكلة البحث الرئيسية في بناء نموذج حاسوبي مساعد للطبيب يقوم بتشخيص مرض سرطان الجلد آلياً وذلك بتحليل صور الجلد المشكوك بإصابته ويعطي تصنيفاً دقيقاً عما إذا كان وربما حميداً أم خبيثاً وذلك بالاعتماد على الشبكات العصبونية الالتفافية.


3. أهمية وأهداف البحث:

إن استخدام الأنظمة الحاسوبية في هذا المجال أصبح أمراً في غاية الأهمية نظراً لأنه سيعطي نتائج أكثر دقة تساعد العنصر البشري في تحسين النتائج وتخفيض معدل الخطأ، والذي من الممكن أن يساعد في إنقاذ أرواح بشرية. يهدف البحث إلى اقتراح خوارزمية للكشف عن سرطان الجلد باستخدام تقنيات التعلم العميق والذي يمكن أن يحل محل طرق الفحص البصرية الحالية من قبل الطبيب ويساهم في تخفيض عدد الخزعات الجراحية غير الضرورية وزيادة الموثوقية وذلك بالمساعدة على التشخيص الصحيح.

4. طرائق البحث وموارده:

تم تنفيذ هذا البحث باستخدام لغة البرمجة python ضمن بيئة العمل Visual Studio Code على جهاز حاسوب شخصي يمتلك المواصفات وحدة معالجة مركزية intel Core i5-8250u بسرعة 1.80 GHz وذاكرة نظام 8GB.

يتضمن البحث عدة مراحل بدءاً من الحصول على الصورة وصولاً إلى مرحلة التشخيص من خلال بناء نموذج التعلم العميق الذي يعتمد على شبكات CNN مع الاستعانة بمكتبات Keras و Tansorflow من أجل بناء النموذج وبيّن الشكل (1) المخطط الصندوقي لأهم مراحل العمل خلال هذا البحث.



الشكل(1): المخطط الصندوقي لمراحل العمل.

5. الدراسات المرجعية:

- في عام 2014 قام [5] Arati P. Chavan و D. K. Kamat و Dr. P. M. Patil بتقديم تصنيف لصور سرطان الجلد باستخدام الشبكات العصبونية، حيث تم تصنيف الخرج إلى ثلاثة أنواع سرطان الخلايا القاعدية BCC ، وسرطان حرشفي الخلايا SCC والآفات الجلدية غير المؤذية Harmless Skin lesions ، كما تم استخدام خوارزمية تحليل الموجة للحصول على قيم المعاملات اللازمة لعملية التصنيف.
- في عام 2015 قام [6] Ramandeep Kaur Gurmeen Kaur باستخدام قاعدة بيانات من مستشفى BLK، وقد احتوت على أكثر من 100 صورة، حيث تم استخراج عدة سمات عن طريق عدة خوارزميات وتم استعمال خوارزمية GLCM وخوارزمية LBP كما تم ايجاد سمات تتعلق باللون والحجم حيث ساعدت هذه السمات في تصنيف الخرج إلى BCC و SCC والسرطان الميلانومي، كما أعطت هذه الدراسة نتائج مرضية جداً حيث وصل معدل دقة التصنيف إلى 94%.
- في عام 2021 قام [7] J. Höhn, E. Krieghoff–Henning, T. B.Jutzi, C. Kalle, J. S.Utikal and F. Meier بدراسة ما إذا كان الدمج بين تحليل صورة الشرائح الكاملة النسيجية (WSI) اعتماداً على الشبكات العصبية الالتقافية CNN وبيانات المريض المتاحة العمر والجنس والموقع التشريحي للآفة لتشخيص سرطان الجلد يمكن أن يحسن الأداء مقارنة بـ CNNs (شبكة عصبونية ترشيحية) وحدها، حيث تم استخدام 400 صورة WSI من مختبرين مختلفين (LABOR 28 AG - NORDAIR SYSTEMS GMBH.)، وتخمين أداء المصنفات التي استخدمت الصورة أو بيانات المريض بشكل فردي أو ثلاث تقنيات دمج شائعة، علاوة على ذلك، اختبار مزيجاً بسيطاً من بيانات المريض ومصنف صور: بالنسبة للحالات التي تم تفسيرها على أنها غير مؤكدة، حققت CNN بمفردها أداء أفضل مع AUROC بنسبة 92%.
- في عام 2020 قام [8] N. Rezaoana, M. S. Hossain and K. Andersson باستخدام تقنية آلية لتصنيف سرطان الجلد، وقد تم تصنيف 9 أنواع من سرطان الجلد وملاحظة أداء وقدرة الشبكات العصبونية الالتقافية حيث تم استخدام مجموعة بيانات من Kaggle's تحتوي على تسعة أنواع سريرية من سرطان الجلد منها (التقرن السفغي،

وسرطان الخلايا القاعدية، والتقران المئي الحميد، والورم الليفي الجلدي، والورم الميلانيني، والوحمات، والتقران الدهني، وسرطان الخلايا الحرشفية، وآفات الأوعية الدموية) وكان الهدف بناء شبكة عصبونية التقافية تقوم بتصنيف سرطان الجلد إلى فئات مختلفة وحقق النموذج دقة 79.4%.

6. قاعدة البيانات المستخدمة:

تم الحصول على صور سرطان الجلد من عدة مواقع قواعد بيانات [9،10،11،12،13] مثل المعهد العالمي للسرطان، وجمعية السرطان الأميركية، وجمعية الأمراض الجلدية الكندية وغيرهم، وهي صور حالات مخصصة للباحثين، حيث تحتوي قاعدة البيانات هذه على 2637 صورة ذات صيغة jpg موضحة بالشكل (2) ومقسمة بالترتيب على النحو التالي:

✓ 1318 صورة لسرطان جلد حميد

✓ 1319 صورة لسرطان جلد خبيث



الشكل(2): صور من قاعدة البيانات المستخدمة.

تتميز قاعدة البيانات المتوفرة بالصفات التالية:

- ✓ اختلاف أماكن توضع الشامات.
- ✓ اختلاف أحجام الشامات.
- ✓ وجود أكثر من شامة في بعض الصور.
- ✓ اختلاف أحجام الصور.
- ✓ اختلاف مسافة البعد عن الكاميرا.


- ✓ اختلاف الخلفيات في الصور.
- ✓ اختلاف لون البشرة.
- ✓ وجود شعر في أغلب الصور.

7.7 المعالجة الأولية للصور (Preprocessing of images):

قبل البدء بعملية المعالجة الأولية يجب التنويه إلى أننا قمنا بأخذ صورة من قاعدة البيانات وطبقنا عليها مراحل المعالجة كمثال وبنفس الطريقة والأسلوب تم التطبيق على قاعدة البيانات بالكامل. تم تنفيذ عدة خطوات لمعالجة الصورة الأولية للصور وتقادي أي مشكلة قد تؤدي لتجزئ غير دقيق وهذه التغيرات قد لا تبدو واضحة ولكنها للحذر والوقاية من أي صورة مستحصلة بشكل غير دقيق، وهذه المراحل هي:

7.1 تحويل الصورة (Image conversion):


تحويل الصورة إلى التدرج الرمادي لأن معالجة الصورة الرمادية أسهل من معالجتها كصورة ملونة كما هو موضح بالشكل (3).



الشكل (3): الصورة الرمادية الهستوغرامية للصورة التي تمت قراءتها من قاعدة البيانات.

7.2 تسوية الهستوغرام (Histogram equalization):

تطبيق عملية تسوية الهستوغرام على الصورة لزيادة تباينها ولجعل منطقة الورم تختلف أكثر فأكثر عن مجاوراتها لتسهيل فصل الورم عن الخلفية ويبين الشكل (4) ناتج تطبيق تسوية الهستوغرام على الصورة.



الشكل (4): الصورة التي تمت قراءتها من قاعدة البيانات بعد تسوية الهستوغرام والهستوغرام الموافق لها.


8. تجزئ الصورة (Image segmentation):

8.1 تعتیب الصورة (Threshold):

تحويل الصورة الرمادية إلى صورة ثنائية بعتبة تمثل انزياح عن القيمة المتوسطة بمقدار 100 وتم استخدام القيمة المتوسطة للصورة لجعل اختيار العتبة يتم بشكل يعتمد على الصورة وبالتالي تتغير قيمة العتبة حسب الصورة المدروسة وعموماً تعطى علاقة التعتیب التي استخدمناها لتعتیب الصور كمايلي [14]:

$$f(x, y) = \begin{cases} 1, & f(x, y) < \left(\frac{1}{m * n} \sum_{i=1}^m \sum_{j=1}^n f(x, y) \right) - 100 \\ 0, & \text{otherwise} \end{cases} \quad (1)$$


أي أن بكسلات الصورة التي تقل قيمتها عن القيمة المتوسطة للصورة مطروحاً منها القيمة 100 ستصبح (1) في الصورة الثنائية، بكسلات الصورة التي تزيد قيمتها عن القيمة المتوسطة للصورة مطروحاً منها القيمة 100 ستصبح (0) في الصورة الثنائية، كنتيجة لذلك سنحصل على الصورة المبينة بالشكل (5)



الشكل (5): الصورة بعد عملية التعتیب.

8.2 المورفولوجي (morphology):


نحتاج في بعض الصور إلى تصحيح خرج الصورة الناتجة عن عملية التعتیب من خلال إنجاز عملية فتح مورفولوجي على الصورة الناتجة من عملية التعتیب، وذلك من أجل إزالة النتوءات التي قد تظهر في الصورة حيث تم تطبيق قناع دائري نصف قطره 5، كما هو موضح بالشكل (6).



الشكل (6): الصورة بعد تطبيق عملية الفتح.

8.3 استعادة الصورة الأصلية (Image recovery):

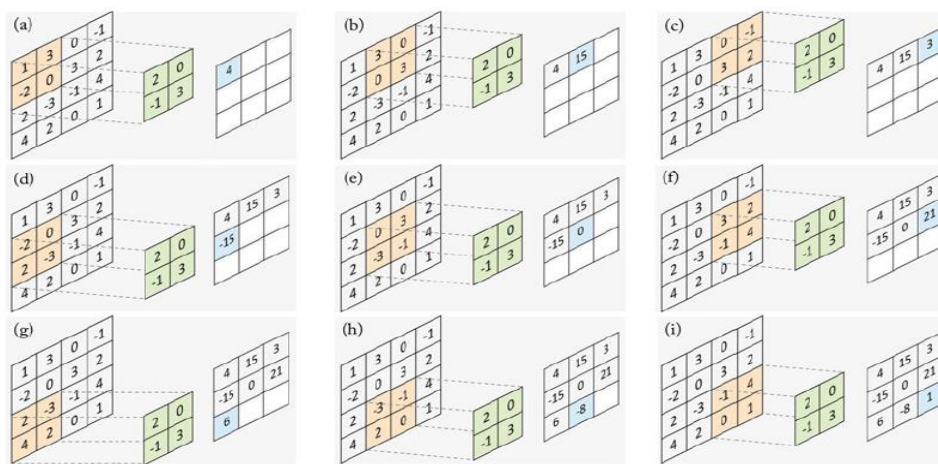
يجب أن نظهر منطقة الورم على الصورة الأصلية الملونة، حيث تمثل آخر صورة وصلنا إليها صورة الماسك أو صورة القناع التي يجب أخذ ما يماثلها من الصورة الملونة كما هو موضح في الشكل (7).



الشكل (7): صورة الورم بعد اقتطاعها من الصورة الأصلية.

9. الشبكات العصبونية الالتفافية (Convolutional neural networks):

تتكون الشبكة العصبونية الالتفافية من 4 طبقات أساسية [15]: الطبقة الالتفافية Convolutional layer يُطبَّق في طبقة التلافيف مُرَشَّح Filter ويُعرف أيضاً بـ kernal من شأنه تحديد وجود سمات أو أنماط مُعينة في الصورة الأصلية (الدخل)، كما يمكن استخدام عدة مرشحات بغية استخراج سمات مختلفة. يكون المُرَشَّح نو حجم صغير ليمسح الصورة كاملةً ويطبق العمليات الحسابية المناسبة بين قيم المُرَشَّح والنقاط اللونية (Pixels) بغية استخراج السمات Features، وعادةً ما تكون الجداء الداخلي فيما بينها. يُعاد ضبط قيم المُرَشَّح خلال عملية التدريب الدورية وعند تدريب الشبكة لعدد مُعين من التكرارات (epochs)، وكل تدريب يعني إدخال كل أمثلة التدريب مرة واحدة، تسرع هذه المُرَشَّحات البحث عن سمات مُتميزة في الصورة. يتم توظيف الطبقات المخفية الأولى في استخراج السمات البسيطة والواضحة، مثل الحواف في الاتجاهات المُختلفة وما إلى ذلك، ومع التعمق أكثر في الطبقات المخفية في الشبكة، تزداد درجة تعقيد السمات التي يجب تحديدها واستخراجها، والشكل (8) يعبر عن الطبقة الالتفافية.

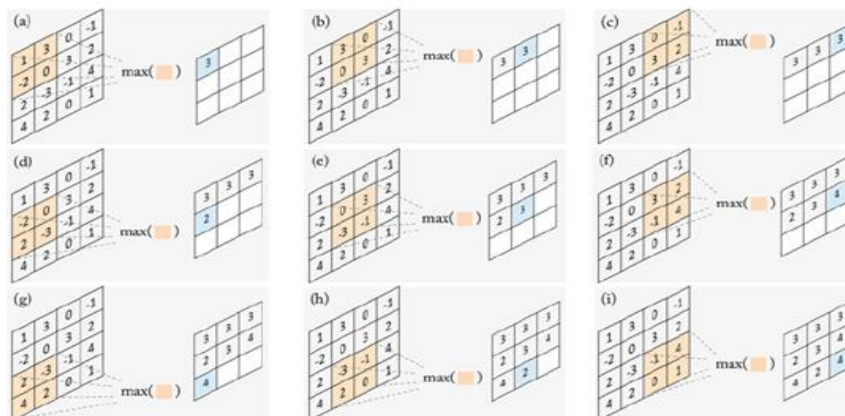


الشكل (8): الطبقة الالتفافية

1- طبقة التجميع Pooling Layer

في هذه الطبقة، ننتقل إلى خريطة المعالم لاكتشاف السمات الأكثر دقة. هناك نوعان من التجميع: الحد الأقصى والمتوسط.

يعني Max pooling أننا نختار أكبر قيمة من الخريطة المميزة في كل خطوة، بينما يعني متوسط التجميع average pooling أننا نضيف القيم التي نكتشفها من الخريطة ونقسمها على عددها [20].



الشكل (9) max pooling layer

2- طبقة تسطيح المدخلات flatten layer

تقوم هذه الطبقة بتحويل المصفوفة إلى متجه لأن دخل الطبقة المتصلة بالكامل FC يجب أن يكون متجهًا.


3- الطبقة المتصلة بالكامل Fully connected layer

إنها الطبقة الأخيرة في نموذج CNN، وهي عبارة عن شبكة عصبونية متعددة الطبقات، حيث أن طبقة الخرج فيها تدل على التصنيفات المكتشفة.

10. بناء الشبكة العصبونية الالتفافية وضبط ثوابتها:

10.1 عدد طبقات الالتفاف والتجميع:

تمثل هذه الطبقات النواة الأساسية في الشبكة العصبونية الالتفافية، وتعتبر هذه الطبقات عن مرحلة استخلاص السمات من طبقة الدخل، وقمنا بتجريب تغيير عدد الطبقات وتأثيره على الدقة على قاعدة بياناتنا، ويوضح الشكل (10) تغيير عدد الطبقات وتأثيره على دقة التصنيف.



الشكل (10): تغيير عدد الطبقات وتأثيره على دقة التصنيف.


نلاحظ من الشكل (10) أنه كلما زدنا عدد الطبقات لا تتحسن الدقة، وذلك لأن زيادة عدد الطبقات تحتاج إلى زيادة في معطيات التدريب، بالإضافة لذلك فإن استخدام طبقات التجميع بشكل كبير قد يعمل على التأثير على السمات وحتى حذفها. لذلك سنعيد التجربة هذه على نفس قاعدة البيانات ولكن مع جعل عدد طبقات الالتفاف أكبر من عدد طبقات التجميع ويوضح ذلك الجدول (2).

الجدول (2): نتيجة تغير عدد الطبقات الالتفافية وطبقة التجميع على الدقة

الدقة	عدد طبقات التجميع	نوع الالتفاف	عدد طبقات الالتفاف
%57.47	1	Same, stride=1	2
%54.51	1	Same, stride=1	3
%54.51	2	Same, stride=1	3
%54.51	2	Same, stride=1	4
%54.63	3	Same, stride=1	4
%60.23	3	Same, stride=1	5
%54.36	4	Same, stride=1	5
%60.04	4	Same, stride=1	6
%54.40	5	Same, stride=1	6

10.2 عدد المرشحات في كل طبقة:

في كل طبقة النفاذ نحتاج إلى تعريف عدد المرشحات اللازمة للقيام بعملية استخلاص السمات من مصفوفة الدخل. يعتبر عدد المرشحات أحد ثوابت الشبكة، بينما تعتبر قيم المرشح هي المتحولات التي يتم ضبطها أثناء عملية التدريب والشكل (11) يبين دراسة لتغير عدد المرشحات في كل طبقة مع الدقة.



الشكل (11): نتيجة تغير عدد المرشحات في كل طبقة التفاضلية على الدقة

نلاحظ أنّ الخيار (32,64,64,128,128) هو الخيار الأفضل في حالتنا. تمثل زيادة عدد المرشحات في الطبقة زيادة كبيرة موافقة في حجم المعطيات الواجب التعامل معها أثناء تدريب الشبكة، وهذا يؤثر على سرعة التدريب.

10.3 شكل طبقة التجميع:


يتوجب ضبط عاملين في طبقة التجميع، شكل نواة التجميع وتابع التجميع. ويوضح الجدول (3) دراسة تغير تابع التجميع مع الدقة.

الجدول (3): نتيجة تغير متحوّلات طبقة التجميع على الدقة

الدقة	تابع التجميع	نواة التجميع	عدد طبقات التجميع	عدد طبقات الالتفاف
60.00%	Max	2*2	3	5
56.70%	Average	2*2	3	5

10.4 طبقة كاملة الاتصال:

تحتوي هذه الطبقة عدة طبقات عصبونية (طبقة الدخل وطبقات مخفية وطبقة الخرج)، تحوي هذه الطبقة ثابتين يجب ضبطهما، الأول هو عدد الطبقات العصبونية المخفية، والثاني يمثل عدد العصبونات في كل طبقة مخفية ويبين الشكل (12) نتائج تغيير عدد الطبقات المخفية وعدد العصبونات في كل منها مع الدقة.



الشكل (12): نتيجة تغير عدد الطبقات المخفية وعدد العصبونات في كل منها على الدقة

لا تعني زيادة عدد الطبقات أو العصبونات الحصول على دقة أعلى، وخاصة إذا لم تحصل زيادة وتتنوع كبير في المعطيات، وذلك لأن النموذج سيميل بشكل واضح لملائمة معطيات التدريب (over fitting)، وبالمقابل هذا سيؤدي إلى زيادة متحوّلات الشبكة وبطء في عملية التعليم.

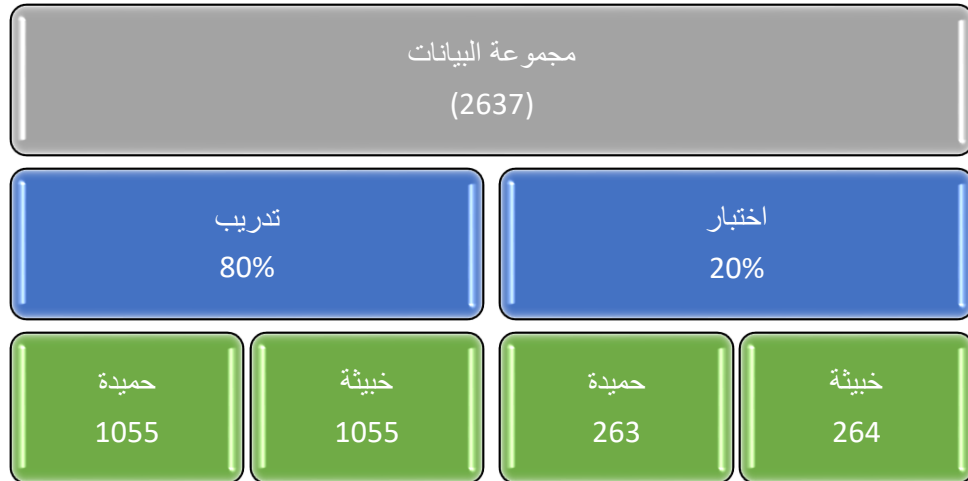
10.5 بنية الشبكة الالتفافية:

بعد الانتهاء من التجارب السابقة واختيار المتحوّلات ومعرفة الأثر التقريبي لكل منها على دقة التصنيف، نعرض في الجدول (4) البنية النهائية للشبكة العصبونية الالتفافية.

الجدول (4): البنية النهائية للشبكة العصبونية الالتفافية المستخدمة

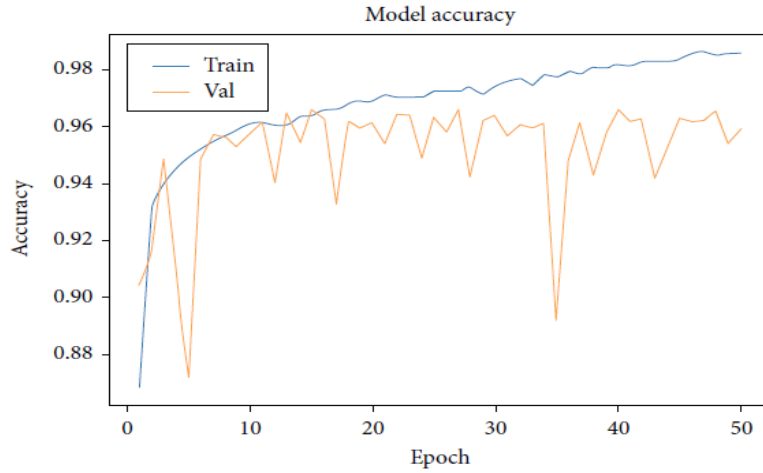
نوع الطبقة	تابع التفعيل	حجم الصورة المدخلة	الحجم الناتج بعد كل طبقة
Conv1	ReLu	150*150	148*148
Pool1		148*148	74*74
Conv2	ReLu	74*74	72*72
Conv3	ReLu	72*72	70*70
Pool2		70*70	35*35
Conv4	ReLu	35*35	33*33
Conv5	ReLu	33*33	31*31
Pool3		31*31	15*15
طبقة ال Flatten			30 عصبون
طبقة الدخل للشبكة العصبونية كاملة الاتصال	ReLu		عصبونات بطول طبقة ال Flatten
طبقة مخفية للشبكة العصبونية كاملة الاتصال	ReLu		256 عصبون
طبقة الخرج للشبكة العصبونية كاملة الاتصال	sigmoid		عصبون واحد

بعد الانتهاء من ضبط ثوابت الشبكة العصبونية الالتفافية، نقوم الآن بتدريب الشبكة على معطيات التدريب، حيث تم تقسيم البيانات إلى مجموعتين تدريب واختبار وبين الشكل (13) تقسيم البيانات.




الشكل (13): تقسيم البيانات

يظهر كل من الشكل (14) منحنى الدقة لكل من معطيات التدريب والاختبار بينما يظهر الشكل (15) منحنى الخسارة لكل من معطيات التدريب والاختبار.



الشكل (14): منحنى الدقة لكل من معطيات التدريب والاختبار



الشكل (15): منحنى الخسارة لكل من معطيات التدريب والاختبار

يعطي الشكلين السابقين مؤشر على سير عملية التدريب والاختبار، حيث ستقف عملية التدريب عند التكرار رقم 50 ونحفظ الأوزان والمتحولات الناتجة عن التدريب.

ونلاحظ وجود تقارب كبير بين منحنى التدريب والاختبار وهو مؤشر جيد لغياب Over-fitting وأن تدريب الشبكة العصبية تم بشكل سليم، حيث أعطت الشبكة دقة حوالي 99% لكل من مجموعات التدريب و96% لكل من مجموعات الاختبار وهذا يشير إلى أن النموذج كان قادرًا على تصنيف غالبية الصور في مجموعة البيانات بشكل فعال كما يوضح منحنى الخسارة أن خسارة النموذج انخفضت بشكل مطرد أثناء التدريب ، مما يشير إلى أن النموذج كان ناجحًا في تقليل الخطأ.

11. تقييم أداء النموذج:

لتوضيح النتائج قمنا برسم مصفوفة الارتباك، حيث يتبين من خلالها نسبة الحالات التي توقع فيها النموذج بشكل صحيح وكذلك الحالات التي فشل النموذج فيها بتوقع الخرج الصحيح وتم تقييم أداء النموذج من خلال حساب معايير التقييم (الدقة - الخصوصية - الحساسية - المقياس F1-score) ويوضح الشكل (16) مصفوفة الارتباك، كما يبين كل من الشكل (17) نتائج أداء النموذج، والجدول (5) مقارنة مع الدراسات المرجعية.

1. الدقة (*Accuracy*): هي مقياس لعدد التنبؤات الصحيحة التي قدمها النموذج لمجموعة بيانات الاختبار الكاملة، وهي مقياس أساسي جيد لقياس أداء النموذج، وتُعبّر عن مدى قرب القيمة المقاسة من القيمة الفعلية (الحقيقية)، وتصبح الدقة في مجموعات البيانات غير المتوازنة مقياساً ضعيفاً، وتعطى بالعلاقة التالية [16]:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

2. الاستدعاء (*Recall*): عدد الحالات الإيجابية الفعلية التي يتم التنبؤ بها بشكل صحيح باستخدام النموذج، ويعد الاستدعاء مقياساً مفيداً في الحالات التي تتفوق فيها السلبي الكاذب على الإيجابي الكاذب، وتعطى بالعلاقة التالية [16]:

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

3. الخصوصية (*precision*): عدد العينات الخاطئة التي تم كشفها على العدد الإجمالي للعينات الخاطئة، وتعطى بالعلاقة [16]:

$$SP = \frac{Tn}{Tn + Fp} \quad (4)$$

4. المقياس (*F1-score*): ويعبر عن العلاقة التوافقية بين المقياسين (*precision*) و(*recall*)، ويعطى بالعلاقة [16]:

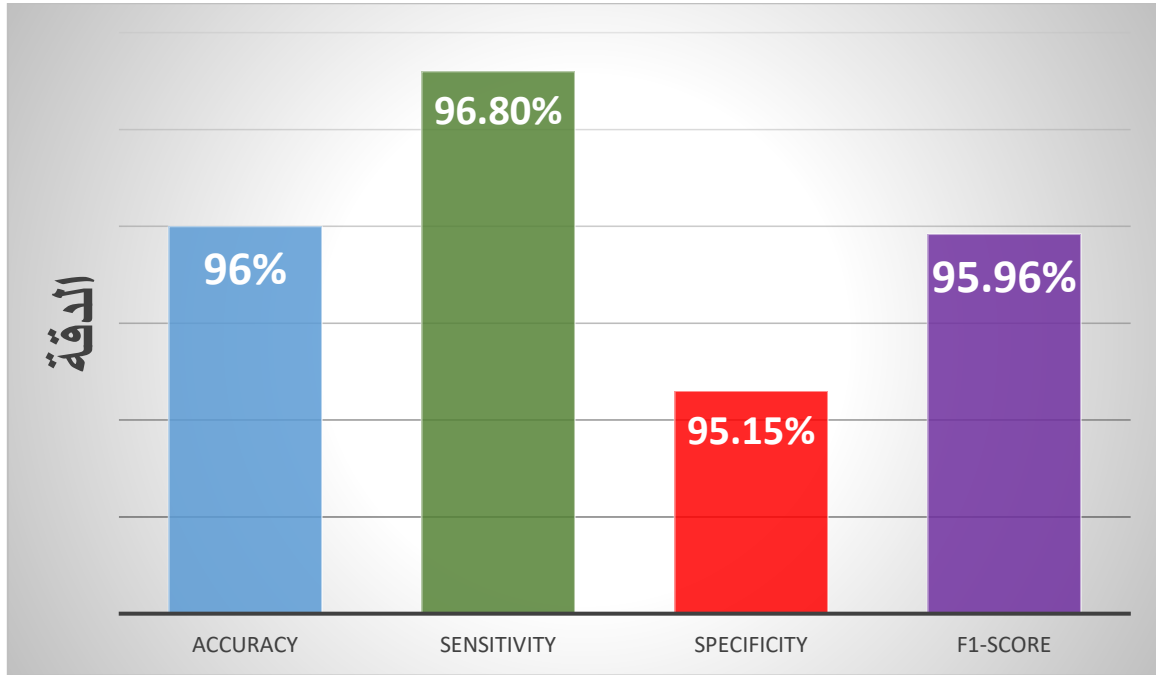
$$F1 - score = \frac{2 * Tp}{2 * Tp + Fn + Fp} \quad (5)$$

	benign	malignant
Actual	250	13
	benign	malignant
malignant	8	256
	benign	malignant
	Predicted	

الشكل (16): مصفوفة الارتباك

نلاحظ من مصفوفة الارتباك أنه من بين 263 مصاب بسرطان الجلد الحميد استطاع النموذج تصنيف 250 مصاب بسرطان الجلد بشكل صحيح وأخطأ بـ 13 حالة صنفها على أنها خبيث، ومن بين 264 مصاب بسرطان الجلد الخبيث

استطاع النموذج تصنيف 256 مصاب بشكل صحيح وأخطأ بتصنيف 8 مصابين حيث صنفهم على أساس أنه سرطان جلد حميد وهو خبيث.



الشكل (17): نتائج أداء النموذج

نلاحظ من الشكل (17) أن نموذجنا المستخدم قادر على التصنيف بين العينات حيث حقق نسبة دقة 96% وهذه النسبة تثبت ان النظام صالح للاستخدام في التطبيقات العملية.

الجدول (5): مقارنة مع الدراسات المرجعية.

رقم الدراسة	قاعدة البيانات	عدد العينات	اسم الخوارزمية	الدقة
[6]	مستشفى BLK	100	GLCM+LB	94%
[7]	مختبرين (NORDAIR SYSTEMS – GMBH. LABOR 28 AG)	400	CNN	92%
[8]	Kaggel	لم تتكرر	CNN	79.40%
الدراسة الحالية	Kaggel	2637	CNN	96%

نلاحظ من الجدول (5) أن نموذجنا المستخدم أعطى أفضل دقة من النماذج المستخدمة في الدراسات السابقة وذلك لأن الدراسات (6,7,8) تعتمد على عدد قليل نسبياً من الصور، ولم تستخدم الدراسات قاعدة بيانات قياسية، ولم تقدم بعض الدراسات معلومات عن المصنف الذي استخدمته.

12. الخاتمة:

قمنا في هذا البحث بدراسة سرطان الجلد، واعتمدنا على استخدام التعلّم العميق، فانقلنا إلى دراسة التعلّم العميق، ووقع اختيارنا بناءً على النتائج والدراسات العلمية على الشبكة العصبونية الالتفافية، حيث تمتاز هذه الشبكة بأعلى نتائج تصنيف عند التعامل مع دخل مصفوفاتي، ومن خلال التجارب والنتائج التي تم إجراؤها على مجموعات البيانات التي تم جمعها، تفوق نموذج CNN على النماذج الأخرى المقترحة في الدراسات المرجعية، حيث حقق نموذج CNN دقة 96 %.

13. التوصيات:

1. من الممكن دمج أكثر من نوع من الشبكات العصبونية العميقة للحصول على أداء أفضل.
2. تدريب النموذج على مجموعة أكبر من البيانات.
3. توسيع تطبيق التعلّم العميق لتصبح منظومة كاملة يتم استخدامها في القطاع الصحي.

المراجع

1. <http://www.who.int/uv/faq/skincancer/en/index1.html>, downloaded at :5/4/2016
2. <https://www.kfshrc.edu.sa/ar/Home/HealthEncyclopedia/DiseasesConditions/1408>, downloaded at :31/3/2016
3. Alwunais, Khalid M., and Sohail Ahmad. "Pattern of skin cancer at Dammam Medical Complex in Dammam, Saudi Arabia." *Journal of Dermatology & Dermatologic Surgery*,2016,PP:51–54.
4. Siddiq Iqbal, Sophia.M, Divyashree.J.A, Mallikarjun Mundas, Vidya.R,," Implementation Of Supervised Learning For Melanoma Detection Using Image Processing", *International Journal of Research in Engineering and Technology*, Volume 4, Issue 6 , June 2023, PP: 325–329.
5. Arati P. Chavan, D. K. Kamat , Dr. P. M. Patil," Classification Of Skin Cancers Using Image Processing ", *International Journal of Advance Research in Electronics, Electrical & Computer Science Applications of Engineering & Technology* Volume 2, Issue 3, June 2014, PP: 378–384 .
6. Ramandeep Kaur, Gurmeen Kaur," Skin Cancer – Melanoma Detection in Skin Images Using Local Binary Pattern (LBP) and GLCM", *International Journal of Science and Research (IJSR)*, Volume 4, Issue 7, July 2015,PP: 134–139.
7. J. Höhn, E. Krieghoff–Henning, T. B.Jutzi, C. Kalle, J. S.Utikal and F. Meier, "Combining CNN–based histologic whole slide image analysis and patient data to improve skin cancer classification," *European Journal of Cancer*, pp. 94 – 101, 2021.
8. N. Rezaoana, M. S. Hossain and K. Andersson, "Detection and Classification of Skin Cancer by Using a Parallel CNN Model," *IEEE International Women in Engineering (WIE) Conference on Electrical and Computer*, 2020.

9. <http://www.cancer.gov>, downloaded at : 31/8/2014.
10. www.dermatology.ca, downloaded at : 2/2/2015.
11. www.skincancer.org, downloaded at : 3/1/2015.
12. www.skincancercare.com, downloaded at : 31/8/2014.
13. www.visualsonline.cancer.gov, downloaded at :31/7/2014.
14. Yu, S., Liu, L., Wang, Z., Dai, G., and Xie, Y.” Transferring deep neural networks for the differentiation of mammographic breast lesions.” Science China Technological. Sciences 62.3 (2019):441–447.
15. Dina M. I, Nada M. E., Amany M. S. Deep–chest: Multi–classification deep learning model for diagnosing COVID–19, pneumonia, and lung cancer chest diseases. Elsevier. 2021; 15(3):1–13.
16. Aous M., Ghada S. Designing a Multiclassification Convolutional Neural Networks Model for the Diagnosis of Lung Cancer and Covid–19. Tishreen University Journal for Research and Scientific Studies – Engineering Sciences Series. 2022; 44(6):185–20.