

استخدام نموذج VGG16 لاكتشاف مرض كوفيد-19 من صور أشعة الصدر السينية

* ليلى اصميدة ، ايمان خليفة ، ريمافرحات

كلية تقنية المعلومات ، الجامعة الأسمرية الإسلامية ، زليتن - ليبيا
* لمراسلة المؤلف: la.esmeda@asmarya.edu.ly

المخلص (ABSTRACT)

جائحة كورونا (كوفيد-19) هي جائحة عالمية ظهرت أواخر شهر ديسمبر 2019 في مدينة وهران بجمهورية الصين، وأصبح هذا المرض يتزايد يوميا في جميع أنحاء العالم فتزايد عدد المصابين والوفيات وفقا لتقارير منظمة الصحة العالمية.

وبسبب تزايد هذا المرض وقلة الامكانيات والمعدات المتاحة للكشف عن هذا المرض خصوصا في مراحله الأولى، وكذلك بسبب نقص الأطباء المتخصصين في القرى النائية تم القيام ببناء نموذج في التعلم العميق لتصنيف 8000 صورة باستخدام الشبكات العصبية الالتفافية (Convolutional Neural Networks) وكانت الدقة 0.51، كذلك تم استخدام نموذج VGG16 للتنبؤ بوجود المرض من عدمه لنفس الصور، وقد تم الوصول الى دقة 0.93. كما اثبت نموذج VGG16 كفاءته في هذه الدراسة مقارنة بنموذج الشبكة العصبية (CNNs).

الكلمات المفتاحية: الشبكات العصبية الالتفافية (CNNs) - أشعة الصدر السينية (Chest X-ray) - كوفيد-19 - نموذج VGG16

1. المقدمة (INTRODUCTION)

مما لا شك فيه أن للأمراض وانتشارها عواقب وخيمة على كافة مجالات الحياة، فهي تهدد وتؤثر على الصحة العامة واقتصاد الدولة والأمن القومي؛ وبالتالي يجب إعطاء الأمراض بمختلف أنواعها الأهمية القصوى لتجنب مخاطرها على مختلف الأصعدة. كما أنه يوجد الكثير من الأمراض التي تستوجب أن تكون في مقدمة الأمراض التي تعنى بالبحث والدراسة لفهم مسبباتها وتشخيصها ومن ثم الوصول إلى سبل علاجها ومكافحتها والوقاية منها، ومن بين تلك الأمراض مرض كوفيد-19 الذي سيتم التركيز عليه في هذه الدراسة.

إن مرض (كوفيد-19) هو مرض معدي يصيب الرئة وقد سبب في وفاة العديد من الأشخاص، بالإضافة إلى مشاكل في مختلف جوانب الحياة مثل التعليم والاقتصاد. كما أن الأعراض التي يسببها مرض كوفيد-19 وفقا لتقرير منظمة الصحة العالمية هي الحمى بنسبة (83-99%) والسعال بنسبة (59-82%)، التعب العام بنسبة (44-70%) وفقدان الشهية بنسبة (40-84%) وضيق التنفس بنسبة

(31-40%) والألم العضلي بنسبة (11-35%) ، وهناك أعراض أخرى مثل التهاب الحلق والقيء والإسهال، كذلك قد يتسبب في إصابة الجهاز العصبي [2]، [1].

وقد تم الإجماع من قبل منظمة الصحة العالمية على أن جهاز RT-PCR هو الجهاز الذي يمكنه الكشف عن وجود المرض، وبسبب تكلفته العالية قد لا يتوفر في جميع المستشفيات وفي كل الأوقات، كما أنه يحتاج لساعات حتى يبين نتيجة الإصابة بالمرض؛ ومن هذا المنطلق تم العزم على تقديم هذه الورقة لإيجاد وسيلة أخرى تساعد في تشخيص الإصابة بالمرض.

وقد تم في هذه الورقة القيام بجمع عينة مكونة من 8000 صورة تتضمن صور أشخاص مصابين وغير مصابين بكوفيد-19، كما تم تقسيم هذه الصور إلى 6000 صورة لتدريب النموذج (Train set) و 2000 صورة للاختبار (Test set)، تم تدريب هذه الصور على الشبكة العصبية الالتفافية كذلك تم التدريب على الشبكة العصبية الالتفافية VGG16، ثم قمنا بتحليل النتائج وأداء النموذج.

2. الدراسات السابقة (LITERATURE REVIEW)

هناك العديد من الأبحاث والدراسات التي تناولت أساليب وطرق الكشف عن الإصابة بمرض كوفيد-19 من خلال أشعة الصدر السينية (Chest X-ray) باستخدام الشبكات العصبية الالتفافية، ونذكر من هذه الدراسات مايلي:

استخدم Ilyas وآخرون [3] تدريب الشبكات الالتفافية وهي ResNET و VGG19 و ResNet50 و InceptionV3 في تصنيف صور مرض كوفيد-19 لعدد 100 صورة لحالات مصابة وغير مصابة بالمرض، وقد وصلوا لدقة (accuracy) 0.98 ، 0.95، 0.96 على التوالي.

بينما قام HaghaniFar [4] بإنشاء نموذج نقل التعلم اسماء CheXNet مكون من 431 طبقة مستخدماً عدد من الصور وقدره 1326 صورة وأنجز دقة (accuracy) وصلت إلى 0.96.

كما قام عباس وآخرون [5] ببناء نموذج اسمه (DeTraC) Transfer, and Compose model لاكتشاف مرض كوفيد-19، حيث تم إنشاء (new layer) طبقة جديدة إلى النموذج المذكور وذلك لغرض تقسيم كل فئة (Class) ضمن الصور إلى فئات عديدة (sub-classes) وتخصيص تسمية جديدة لهذه الفئات، حيث كل مجموعة جزئية مرتبطة كفئة مستقلة، ثم قام بتجميع هذه الفئات الفرعية مرة أخرى لتقوم بإيجاد التنبؤ النهائي، وقد وصل إلى دقة (accuracy) بلغت 0.93.

كذلك قام Sekeroglu وآخرون [6] باستخدام عدة تجارب عن طريق نماذج التعلم العميق وتعلم الآلة واستخدموا صور الأشعة السينية (Chest X-ray) من مدينة كوهين بلغت 6100 صورة قسمت كالتالي : 1583 صورة لأشخاص غير مصابين بمرض كوفيد-19 و 4292 لديهم التهاب رئوي و 225 مصابين بالكوفيد-19 استخدموا خوارزمية CNNs باستخدام نماذج التعلم الآلي وأنجزوا النموذج بدقة (accuracy) بلغت 0.98.

3. المنهجية (METHODOLOGY)


إن الهدف الأساسي من هذا البحث هو تحديد واكتشاف الإصابة بمرض كوفيد-19، حيث تم استخدام الشبكات الالتفافية (Convolutional Neural Networks) ونموذج VGG16. وفيما يلي توضيح لمفهومها وعناصرها الأساسية.

1.3 الشبكات العصبية الالتفافية CNNs

تعد الشبكات العصبية الالتفافية نوع من أنواع الشبكات العصبية التي تستخدم في مجال التعلم العميق لتصنيف الصور، فهي محاكاة لدماغ الإنسان تستمد عملها من العمليات البيولوجية الموجودة في القسم البصري في دماغ الإنسان، فالدماغ عبارة عن مليارات الخلايا المرتبطة مع بعضها البعض، والعين تعكس ما تراه إلى الدماغ ويبدأ الدماغ في تحليل هذه الصورة وإيجاد النمط المعين لهذه الصورة وتمييزها، والوظيفة الرئيسية للشبكات العصبية الالتفافية هي إيجاد الميزات (Features) الموجودة في الصورة. وقد أثبتت هذه الشبكات فعاليتها في مجالات عدة مثل التعرف على الصور وتصنيفها والتعرف على الوجوه (Face Recognition) والأشياء (Objects) وإشارات المرور (Traffic lights) والسيارات ذاتية القيادة (self-driving cars) [7].

1.1.3 معمارية الشبكات العصبية الالتفافية CNN

هناك أربعة مكونات في شبكات CNNs [8] كما هو مبين في الشكل التالي:




شكل 1. تصنيف الشبكات العصبية الالتفافية لصور كوفيد-19

حيث تعد هذه المكونات من الخطوات الرئيسية التي يجب اتباعها عند استخدام الشبكات العصبية الالتفافية في مختلف عمليات تصنيف الصور، وفيما يلي شرح مبسط لتوضيح فهم هذه العمليات الأساسية في الشبكات العصبية الالتفافية CNNs.

1- الالتفاف أو الالتواء Convolution

إن الهدف من عملية الالتفاف هو إيجاد الخصائص (Feature map or Convolved Feature) وذلك من خلال ضرب الفلتر Kernel على مصفوفة الصورة وحساب الناتج كما هو موضح في الشكل 2.




شكل 2. عملية الالتفاف

$$2*1 + 3*1 + 9*2 + 2*8 + 1*3 + 3*(-5) + 1*2 + 1*5 + 2*(4) = 42$$

ثم نكرر العمل على كل بكسل من بكسلات الصورة

2- التجميع أو أخذ عينات فردية Pooling or Sub Sampling

تقوم بتقليص الأبعاد للمصفوفة الناتجة من عملية الالتفاف مع الحفاظ على المعلومات المهمة في الصورة وهذا يساعد في تقليل حجم الصورة والذي بدوره يساعد في سرعة معالجة بيانات الصورة. وتوجد مجموعة من الدوال يمكن تطبيقها في عمليات التجميع المكاني مثل: دوال المتوسط (Average) أو دالة أعلى قيمة (Max) أو دالة أصغر قيمة (min) والشكل (3) يوضح هذه العملية.




شكل 3. يوضح التجميع وأخذ العينات

3- التصنيف (الطبقة الكاملة الاتصال) :Classification

المقصود بالطبقة الكاملة الاتصال أن كل طبقة من طبقات شبكة CNNs مرتبطة بالطبقة السابقة حتى تتكون الطبقة النهائية التي تستخدم دوال التنشيط (activation function) مثل دالة سيجمويد (Sigmoid)، ومهمة هذه الطبقة هو تصنيف الصور إلى فئات بناءً على الخصائص الناتجة من عملية التدريب السابقة [9].

الدالة اللاخطية السيجمويد (Non Linearity sigmoid)

تأخذ هذه الدالة قيم بين 0 و 1 كما في الشكل (4)، إذا كانت القيمة 1 أو قريبة من 1 تكون النتيجة إيجابية وإذا كانت القيمة 0 أو قريبة منها تكون النتيجة سالبة.



شكل 4. دالة سيجمويد (sigmoid function)

وتعطي بالعلاقة الآتية:


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

2-3 نموذج CNNs | VGG-16

إن نموذج CNNs | VGG-16 نوع من أنواع الشبكات العصبية الالتفافية (CNNs) وهو اختصار

للمصطلح Visual Geometry Group-16 (VGG-16) [10]


تم اقتراحه عن طريق الباحثان: كارين سيمونيان وأندرو زيسرمان في جامعة أكسفورد وقدماه سنة 2014 في مؤتمر ILSVRC ImageNet هذا النموذج يستخدم 16 طبقة تلافيفية و 3 طبقات متصلة بالكامل كما في الشكل (5):



شكل 5. شبكة VGG-16 المصدر: Researchgate.net

1-2-3 معمارية نموذج VGG-16

الصورة المدخلة إلى هذا النموذج عبارة عن صورة ذات أبعاد (224 ، 224 ، 3). الطبقة الأولى والثانية تحتوي على 64 قناة بفلتر حجمه 3×3 ثم طبقة pooling ثم طبقتان التفاف 128 قناة بفلتر 3×3 ثم تليها طبقة pooling، ثم 3 طبقات التفاف بقناة 256 بفلتر 3×3 ثم طبقة pooling وتليها 3 طبقات التفاف بعدد 512 قناة ومرشح 3×3 ثم padding، وبعدها 3 طبقات التفاف بعدد 512 قناة وأخيرا طبقة (dense layer) كما هو موضح بالشكل (6).



الشكل 6. معمارية VGG16

4. آلية العمل المقترح وبيئة العمل المستخدمة

تم تنفيذ العمل على بيئة أناكوندا (Anaconda) بلغة Python 3.9.12 وتم استخدام مكتبات tensorflow و keras بعد القيام بتنزيلها من الموقع وإضافتها إلى مكتبات لغة Python الأخرى. كما أنه وبعد توضيح المكونات الأساسية للشبكات العصبية الالتفافية وتوضيح نموذج VGG16 والمعمارية الخاصة به، فيما يلي سيتم توضيح الخطوات التي تم اتباعها في إنجاز هذا البحث كما يلي:

- 1- اختيار البيانات وتحضير البيانات
- 2- تقسيم البيانات

- 3- إنشاء النموذج
- 4- تدريب النموذج والتحقق منه
- 5- تقييم النموذج ومقارنة النتائج

1. اختيار و تحضير البيانات *Datasets select & Pre-processing*

تم القيام بجمع 8000 صورة أشعة سينية للصدر لمرضى COVID-19 من موقع kaggle، وتم إجراء عمليات data augmentation على الصور.

2. تقسيم البيانات *Split Dataset*

تم في هذه المرحلة تقسيم الصور التي تم جمعها إلى 80% صورة للتدريب و 20% صورة للاختبار.

3. إنشاء النموذج *Create Model*

في هذه الخطوة تم انشاء النموذجين، نموذج CNNs الذي يتكون من 8 طبقات، مجموع البارامترات (Total params 6,554,050)، ونموذج VGG16 من (Total pra ms: 40,931,650).

4. تدريب النموذج والتحقق منه *Training Model and validate it*

تم استخدام نموذج NNSS و VGG16 لتدريب بيانات الصور، وبعد الانتهاء من التدر يب تم استخدام 48 صورة جديدة للتحقق.

5. تقييم النموذج ومقارنة النتائج EVALUATION MODEL AND RESULT COMPARE

تم إيجاد دقة النموذج (accuracy) و الضبط (precision) والاستدعاء Recall ، F1-score ومصفوفة الإرباك (confusion matrix) ثم مقارنة نتائج النموذجين.


6. النتائج والمناقشة RESULTS & DISCUSSION

بعد انجاز هذه الدراسة أثبتت النتائج التي تم الحصول عليها أن دقة النتائج في حالة استخدام نموذج VGG16 أفضل من النتائج المتحصل عليها باستخدام نموذج CNNs، حيث بلغت دقتها 0.93 لمجموعة بيانات التدريب training set مع خسارة (Loss) 0.12 و في حالة اختبار البيانات testing accuracy بلغت الدقة 0.98 مع خسارة (Loss) 0.0368. كما تم إيجاد المقاييس لكل فئة class (مريض – غير مريض) وهذه المقاييس هي : الضبط precision ، والاستدعاء-F1 Score، والدقة (accuracy) للنموذج كما هو موضح في الجدول رقم 1.

جدول 1 تقرير التصنيف في حالة عينة الاختبار TESTING SET


النموذج The model	الفئة The class	الضبط Precision (%)	الاستدعاء Recall(%)	F1-score
الشبكة العصبية الالتفافية CNNS	0	0.50	0.49	50%
	1	0.50	0.51	0.50
نموذج VGG16	0	0.94	0.91	0.91
	1	0.89	0.92	0.92

في حالة استخدام نموذج CNNs تم الوصول إلى دقة (Accuracy) بلغت 0.50 بينما في حالة استخدام نموذج VGG 16 وصلت إلى 0.93 وكانت دالة الخسارة (loss) بين عينة التدريب والاختبار جيدة كما هي موضحة في شكل 7:




الشكل 7. دالة (loss function) بين عينة التدريب والاختبار في شبكة CNNS

بينما وصلت الدقة (Accuracy) بين عينة التدريب والاختبار باستخدام نموذج CNNs إلى 0.87 كما هو موضح في الشكل 8




الشكل 8. الدقة (Accuracy) لعينة التدريب والاختبار في شبكة CNNs

وقد تم إيجاد مصفوفة الإرباك confusion matrix في حالة الشبكات الالتفافية CNNs حيث تم تصنيف 501 حالة مصابة و 513 حالة غير مصابة بمرض كوفيد-19 بشكل صحيح، وأخطأ في تصنيف 499 حالة مصابة و 487 غير مصابة، كما هو موضح في الشكل 9.



شكل 9. مصفوفة الإرباك (confusion matrix) لنموذج (CNNs) في حالة بيانات الاختبار (testing set)

أما في حالة النموذج VGG16 فقد تم تصنيف 594 شخص غير مصاب بمرض كوفيد-19 و 700 شخص مصاب بصورة صحيحة وأخطأ في تصنيف 87 شخص غير مصاب و 36 شخص مصاب.




شكل 10. مصفوفة الإرباك (confusion matrix) للنموذج VGG16 في حالة بيانات الاختبار (testing set)

وفي حالة اختبار النموذج باستخدام صور جديدة فإن القياسات كانت كما هو موضح في الجدول رقم 2.

جدول 2 تقرير التصنيف (CLASSIFICATION REPORT) في حالة بيانات التصديق (VALIDATION TEST)


النموذج The model	الفئة The class	الضبط Precision (%)	الاستدعاء Recall(%)	F1-score
الشبكة العصبية الالتفافية CNNs	0	0.59	0.54	0.57
	1	0.58	0.62	0.60
نموذج VGG16	0	0.96	100%	0.98
	1	100%	0.92	0.92

الدقة (Accuracy) لنموذج CNNs هي 0.58 بينما في نموذج VGG 16 هي 0.98 أما مصفوفة الإرباك (confusion matrix) في حالة CNNs كانت كما في الشكل رقم 11.



شكل 11. مصفوفة الإرباك (confusion matrix) لنموذج (CNN) في حالة بيانات التصديق (validation set)

وفي حالة استخدام نموذج VGG16 تم تصنيف كل الصور بشكل صحيح ما عدا صورة واحدة لشخص مصاب كما في الشكل 12.



شكل 12. مصفوفة الإرباك (confusion matrix) لنموذج (VGG16) في حالة بيانات التصديق (validation set)

7. الخلاصة CONCLUSION

في هذه الدراسة تم القيام بتصنيف صور مرضى الكوفيد-19 من خلال الشبكات العصبية الالتفافية ومن خلال نموذج VGG16 اتضح أن التصنيف استخدام نموذج VGG16 هو الأفضل حيث تم الوصول إلى دقة بلغت 0.93 وهذا يحل مشكلة قلة عدد الصور المتحصل عليها.

وعند استخدام هذا النموذج في تصنيف 48 صورة أخذت لمرضى كوفيد-19 في مستشفى زليتن تم تصنيفها بالكامل بشكل صحيح ماعدا صورة واحدة، وكانت دقة النموذج 99% في هذه الحالة. والجدير بالذكر أن هناك بعض الصعوبات التي تمت مواجهتها في إعداد هذه الدراسة أهمها الحصول على صورة جيدة، فقد كانت بعض الصور غير واضحة ورديئة على الرغم من معالجتها بتقنيات مختلفة ولكن النموذج أخفق في عملية التعرف عليها.

نوصي بتوفير مستودعات جيدة للصور للوصول إلى دقة أفضل من الدقة التي تم إنجازها وبمناذج أخرى للشبكات العصبية الالتفافية مثل VGG19.

المراجع REFERENCES

- [1] World Health Organization. (2022). WHO guidelines on the use of chest imaging in COVID-19.
- [2] World Health Organization. (2020). Use of chest imaging in COVID-19: a rapid advice guide, 11 June 2020 (No. WHO/2019-nCoV/Clinical/Radiology_imaging/2020.1). World Health Organization.)
- [3] Ilyas, M., Rehman, H., & Naït-Ali, A. (2020). Detection of covid-19 from chest x-ray images using artificial intelligence: An early review. arXiv preprint arXiv:2004.05436.
- [4] Haghanifar, A., Majdabadi, M. M., Choi, Y., Deivalakshmi, S., & Ko, S. (2022). Covid-cxnet: Detecting covid-19 in frontal chest x-ray images using deep learning. Multimedia Tools and Applications, 1-31.
- [5] Abbas, A., Abdelsamea, M. M., & Gaber, M. M. (2021). Classification of COVID-19 in chest X-ray images using DeTraC deep convolutional neural network. Applied Intelligence, 51(2), 854-864.
- [6] Sekeroglu, B., & Ozsahin, I. (2020). <? covid19?> Detection of COVID-19 from Chest X-Ray Images Using Convolutional Neural Networks. SLAS TECHNOLOGY: Translating Life Sciences Innovation, 25(6), 553-565.

- [7] Towards Data Science, M. (2020). Convolutional Neural Networks, Explained. towardsdatascience.com.
- [8] Hussain, M., Bird, J. J., & Faria, D. R. (2018, September). A study on cnn transfer learning for image classification. In *UK Workshop on computational Intelligence* (pp. 191-202). Springer, Cham.
- [9] Patel, K. (2019). Convolutional Neural Networks—A Beginner's Guide. Toward Data Science.
- [10] Masumoto, H., Tabuchi, H., Nakakura, S., Ohsugi, H., Enno, H., Ishitobi, N., ... & Mitamura, Y. (2019). Accuracy of a deep convolutional neural network in detection of retinitis pigmentosa on ultrawide-field images. *PeerJ*, 7, e6900.