

تصنيف صور (Chest X-Ray) باستخدام CNN للكشف عن COVID-19 والالتهاب الرئوي

أحمد عبدالله امحمد أبوراس

قسم الهندسة الكهربائية والحاسوب، كلية الهندسة، جامعة المرقب، الخمس، ليبيا

* البريد الإلكتروني للمؤلف: amaburas@elmergib.edu.ly

ملخص البحث

في السنوات القليلة الماضية وتحديدا في أواخر 2019 انتشر فيروس خطير في جمهورية الصين يسمى (SARS-CoV2) وهو المسبب لمرض كورونا المستجد (COVID-19)، أصبح هذا المرض في تزايد وانتشار سريع جدا حتى انتشر في العالم أجمع مما أدى لوفاة الآلاف من الأشخاص، قبل اكتشاف اللقاحات المناسبة كانت الخطوات الأساسية لمحاربة هذا المرض هي الكشف والتشخيص المبكر ثم العزل التام للمرضى وللمخالطين لهم وذلك للحد من انتشاره السريع وهذا ما أوصت منظمة الصحة العالمية. تعتبر صور الأشعة السينية (X-Ray) للصدر من أهم الطرق التشخيصية لهذا المرض، لكن هذه الصور تحتاج الى أطباء ذو مهارة وكفاءة لتشخيصها وخاصة في وجود التشابه الكبير بين الالتهاب الرئوي Pneumonia الفيروسي أو البكتيري مع الالتهاب الذي يسببه COVID-19. في هذه الورقة تم بناء نموذج باستخدام الذكاء الاصطناعي والتعلم العميق لتصنيف صور الأشعة السينية للصدر وذلك لتسهيل ومساعدة الكوادر الطبية في التشخيص السريع والسليم، حيث يقوم هذا النموذج المصمم باستخدام الشبكات العصبية الالتفافية بتصنيف هذه الصور إلى ثلاثة تصنيفات وهي صور (طبيعية - مصابة بالتهاب رئوي Pneumonia - مصابة COVID-19). تم تدريب النموذج المقترح باستخدام 6432 صورة حيث يتميز هذا النموذج ببساطة تصميمه بالإضافة الى الأداء والكفاءة العالية في التصنيف مقارنة ببعض النماذج الأخرى وتبلغ دقته 95%.

الكلمات المفتاحية: التعلم العميق، الشبكات العصبية الالتفافية، COVID-19، التهاب رئوي.

Classification of Chest X-Ray Images using CNN for Detection of COVID-19 and Pneumonia

Ahmed Abdualah Emhemmad Aburas *

Department of Electrical and Computer Engineering, Faculty of Engineering, Elmergib University, Alkhoms, Libya

*Corresponding Author, Email Address: amaburas@elmergib.edu.ly

Abstract- In the past few years, specifically after late 2019, a dangerous virus spread in the Republic of China called (SARS-CoV2), which caused the emerging of the corona disease (COVID-19). Before the discovery of appropriate vaccines, the basic steps to combat this disease, as recommended by the World Health Organization, were early detection and diagnosis, then complete isolation of patients and their contacts, in order to limit its rapid spread. X-Ray images of the chest are considered one of the most important diagnostic methods for this disease, but these images need skilled and efficient doctors to diagnose them efficiently, especially in the presence of great similarity between viral or bacterial pneumonia with the infection caused by the COVID-19. In this paper, a model is built using artificial intelligence and deep learning to classify chest X-ray images to facilitate and assist medical personnel in fast and correct diagnosis of the disease. This model, is designed using convolutional neural networks, classifies these images into three classes, which are (Normal - Pneumonia - COVID-19). The

proposed model is trained using 6432 images, it is distinguished by its simple design, in addition to performance and high efficiency in classification compared to some other models, as its accuracy reaches 95%.

Keywords – Deep learning, Convolution Neural Network, COVID-19, Pneumonia.

1. المقدمة

يعتبر مرض COVID-19 من أسرع الأمراض انتشاراً، وقد انتشر مؤخرًا في دول العالم أجمع وقد عجزت بعض الدول على محاربهه والحد منه في بداية ظهوره. وقبل اكتشاف اللقاحات فرضت هذه الدول الحظر الشامل والتباعد مما أدى الى توقف جميع أشكال الحياه في كبرى الدول وهذا ما سبب انهيار وافلاس العديد من الشركات الكبرى وقد تأثر الاقتصاد العالمي كثيرا بهذه الجائحة.

في ذلك الوقت، كانت هناك ضرورة ملحة لاتخاذ إجراءات سريعة لمواجهة تفشي هذا المرض، كان التشخيص الصحيح والمبكر والعزل التام للمريض بالإضافة للأشخاص المخالطين له من بين أهم الاجراءات الأساسية في تقارير وتوصيات منظمة الصحة العالمية، كذلك التباعد ولبس الكمامات إلى آخره من الاحترازاات الوقائية، وقد تعددت واختلقت أعراض هذا المرض من السعال والحمى والتعب والارهاق العام وفقدان الشهية وضيق التنفس وألم في الصدر والتهاب الحلق واحمرار العينين والاسهال والقي والطفح الجلدي [1] [2].

تم تشخيص هذا المرض بطرق مختلفة منها التحاليل الطبية والصور المقطعية والأشعة السينية للصدر، حيث كان التشخيص بهذه الطرق فعال جدا ودقيق لكنه يحتاج لأطباء ذو مهارة خاصة لتشخيص الصور، حيث تتشابه أعراض الالتهاب الرئوي مع أعراض مرض COVID-19. أيضا تتشابه صور الأشعة السينية للصدر لمرض COVID-19 مع مرض الالتهاب الرئوي الفيروسي أو البكتيري، والذي للخلط بين المرضين والخطأ في تشخيص هذه الصور خاصة من الكوادر الطبية الحديثة قليلة الخبرة [3] [4].

يقدم الذكاء الاصطناعي والتعلم العميق حولا واعدة في تشخيص هذا المرض حيث يساعد كثيرا في سرعة ودقة تشخيص صور الأشعة السينية للصدر. كان للذكاء الاصطناعي تاريخ قديم في المجال الطبي من اكتشاف الأورام المختلفة واكتشاف الكسور والعديد من الأمراض مثل الملاريا وأمراض العيون وأمراض القلب والرئة، حيث توالى الأبحاث والدراسات في السنوات الماضية في هذا المجال وقامت بعض المؤسسات بتصميم وتطوير العديد من النماذج المستخدمة في الرؤية الحاسوبية والتعلم العميق مثل النموذج ResNet المطور من قبل الباحثين من شركة Microsoft [5] والنموذج VGG لتصنيف الصور والمصمم من قبل باحثين من جامعة Oxford [6] والنموذج CheXNet المخصص للكشف عن الأمراض الرئوية والمطور من قبل باحثين من جامعة Stanford للذكاء الاصطناعي [7].

بناء على ما سبق، في هذه الورقة تم بناء نموذج لتصنيف صور الأشعة السينية للصدر، حيث تم تصنيف هذه الصور إلى ثلاثة تصنيفات أو فئات وهي صور (طبيعية Normal - مصابة بالتهاب رئوي Pneumonia - مصابة COVID-19)، تم تدريب واختبار النموذج باستخدام 6432 صورة، حيث قسمت هذه الصور إلى مجموعتين الأولى للتدريب والثانية للاختبار وتم تحليل ومناقشة النتائج وأداء النموذج ومقارنته بالنتائج السابقة.

2. الدراسات السابقة

هناك الكثير من الدراسات السابقة للذكاء الاصطناعي وتعلم الآلة والتعلم العميق في المجال الطبي بشكل عام من (تشخيص وتصنيف وتوقع وتعرف وتنبؤ) للعديد من الأمراض المختلفة والشائعة، ومؤخرًا في أواخر 2019 وبداية 2020 توالى وتعددت الدراسات في تشخيص واكتشاف COVID-19 ونذكر بعض منها في ما يلي:

استخدم الباحث Ilyas وآخرون [8] نماذج الشبكات العصبية الالتفافية InceptionV3 , VGG19 , ResNET , ResNet50 لتصنيف 100 صورة للأشعة السينية لحالات مصابة وغير مصابة بمرض COVID-19، ووصلت دقة هذه النماذج إلى 95% و96% و98% و96% على التوالي.

وقام HaghaniFar وآخرون [9] بإعداد نموذج نقل التعلم CheXNet مكون من 121 طبقة واستخدموا 1326 صورة وأنجزوا دقة وصلت إلى 96%.

استخدم Sekeroglu وآخرون [10] عدة نماذج للتعلم العميق وتعلم الآلة وقاموا باستخدام صوراً للأشعة السينية (Chest X-ray) من مدينة كوهين بعدد 6100 صورة قسمت إلى 1583 صورة لأشخاص غير مصابين (سليمين) و4292 لديهم التهاب رئوي و225 مصابين بـ COVID-19، حيث قام الباحث بإجراء 38 تجربة باستخدام الشبكات العصبية الالتفافية، و10 تجارب باستخدام خمسة نماذج للتعلم الآلي، وتم إجراء 14 تجربة باستخدام أحدث الشبكات المدربة مسبقاً لنقل التعلم، وكانت أفضل دقة لهذه النماذج والتجارب 98.5%.

قام Pandit وآخرون [11] باستخدام بيانات تحتوي على 1428 صورة شعاعية للصدر، درب عليها نموذج VGG16 لغرض التصنيف، تم استخدام التعلم بالنقل مع الضبط الدقيق في هذه الدراسة لتدريب الشبكة على صور شعاعية للصدر، أظهرت التجارب أن النموذج حقق نتائج جيدة ويمكن استخدامه بشكل فعال لتسريع اكتشاف COVID-19 بدقة وصلت 96% و92.5% في التصنيف الثنائي و المتعدد على التوالي.

قدم Gaur وآخرون [12] نموذج لتصنيف صور الأشعة السينية للصدر حيث يصنف هذا النموذج هذه الصور إلى ثلاثة تصنيفات وهي الطبيعية ومصابة بـ COVID-19 ومصابة بالتهاب رئوي Pneumonia، حيث استخدمت آلية نقل التعلم في هذه الدراسة مع CNN، حيث تم تدريب النموذج باستخدام 3106 صورة وقد بلغت دقته 92.93%.

بالاستناد على مما سبق، ولتحقيق الهدف الأساسي من هذا البحث وهو اكتشاف الإصابة بالالتهاب الرئوي Pneumonia أو مرض COVID-19، تم تصميم نموذج باستخدام الشبكات العصبية الالتفافية ("CNN") لتشخيص المرضين.

3. الشبكات العصبية الالتفافية CNN

تعتبر CNN أحد الطرق المستخدمة في التعلم العميق لغرض (التصنيف أو التحليل أو التعرف أو التنبؤ) في الصور والفيديو. تكمن فكرة الشبكات العصبية الاصطناعية في أنها مستوحاة من الخلايا العصبية لدى الإنسان، حيث يحتوي جسم الإنسان على الملايين من الخلايا العصبية المرتبطة مع بعضها والتي تشكل جزءاً من الجهاز العصبي الذي يتحكم بالوظائف الحيوية المختلفة في جسم الإنسان.

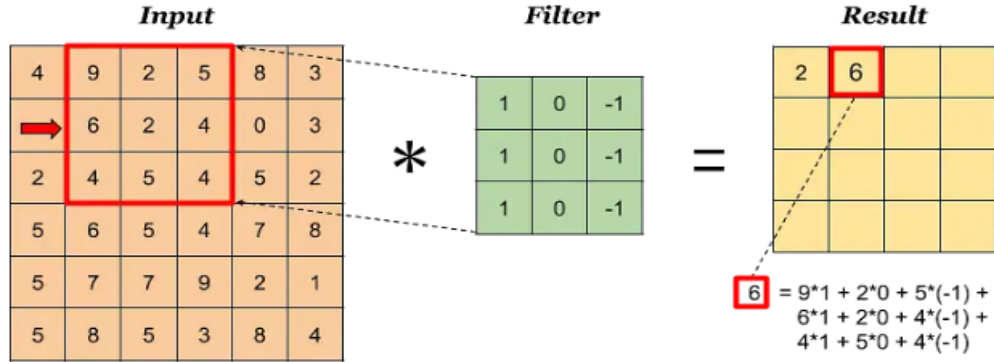
تطورت الشبكات العصبية الاصطناعية على مدى السنوات الماضية حتى ظهور ما يعرف بالشبكات العصبية الالتفافية CNN المندرجة تحت التعلم العميق، تعتمد فكرة عمل CNN على استخلاص المعلومات أو السمات المميزة للصور والتعرف على الأنماط والخصائص المميزة التي تميز الصور المختلفة باستخدام عملية الالتفاف (Convolution). يتم تدريب هذه الشبكات باستخدام مجموعة كبيرة من الصور الموثوقة والمصنفة سابقاً كـ "بيانات التدريب". بعد التدريب، يمكن للنموذج أن يستخدم لتصنيف الصور الجديدة التي لم يرها مسبقاً، ولهذه التقنية تطبيقات عديدة مثل التعرف على الكائنات والأنماط في الصور والتشخيص الطبي.

4. بنية الشبكات العصبية الالتفافية

تتكون الشبكات العصبية الالتفافية من عدة طبقات مختلفة تختلف باختلاف التطبيق والغرض المستخدم، ومن أهم هذه الطبقات ما يلي

أ- طبقة الالتفاف (Convolution Layer)


يستخدم الالتفاف في إيجاد الخصائص أو السمات المميزة للصور الرقمية، ويتم رياضياً بضرب الفلتر التفافياً في مصفوفة الصورة كما هو موضح بالشكل (1)، حيث يمرر هذا الفلتر على كامل الصورة.



الشكل (1) يوضح عملية الالتفاف Convolution

ب- طبقة التجميع وأخذ العينات (Pooling & Sampling Layer)

في هذه الطبقة يتم تقليل أبعاد الصورة وذلك بعد عملية الالتفاف مع المحافظة على السمات المهمة في الصورة، هذه العملية تساعد في تسريع المعالجة وذلك بتقليل عدد البكسل الكلي للصورة وبالتالي تقليل عدد العمليات الحسابية، يوجد العديد من الدوال المستخدمة في هذه الطبقة منها (Max – Min – Average – Median)، في هذا البحث تم استخدام Max-Pooling والشكل (2) يوضح فكرة عمل هذه الطبقة [14] [13]




الشكل (2) يوضح الية التجميع واخذ العينات Pooling & Sampling

ت- التصنيف Classification

هي العملية التي تحدد صنف أو فئة الصورة، مثلا صورة مصابة بمرض أو صورة طبيعية، تسمى الطبقة الأساسية في عملية التصنيف بالطبقة المتصلة Fully Connector Layer أو Dense وتوجد عدة دوال تفعيل Activation functions تستخدم في هذه الطبقة ومنها Sigmoid المستخدمة في هذا البحث والموضحة بالمعادلة (1) والشكل (2)، حيث يمثل x دخل الدالة و $f(x)$ تمثل خرج الدالة والتي تتراوح قيمتها ما بين الصفر والواحد [13] [14].

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

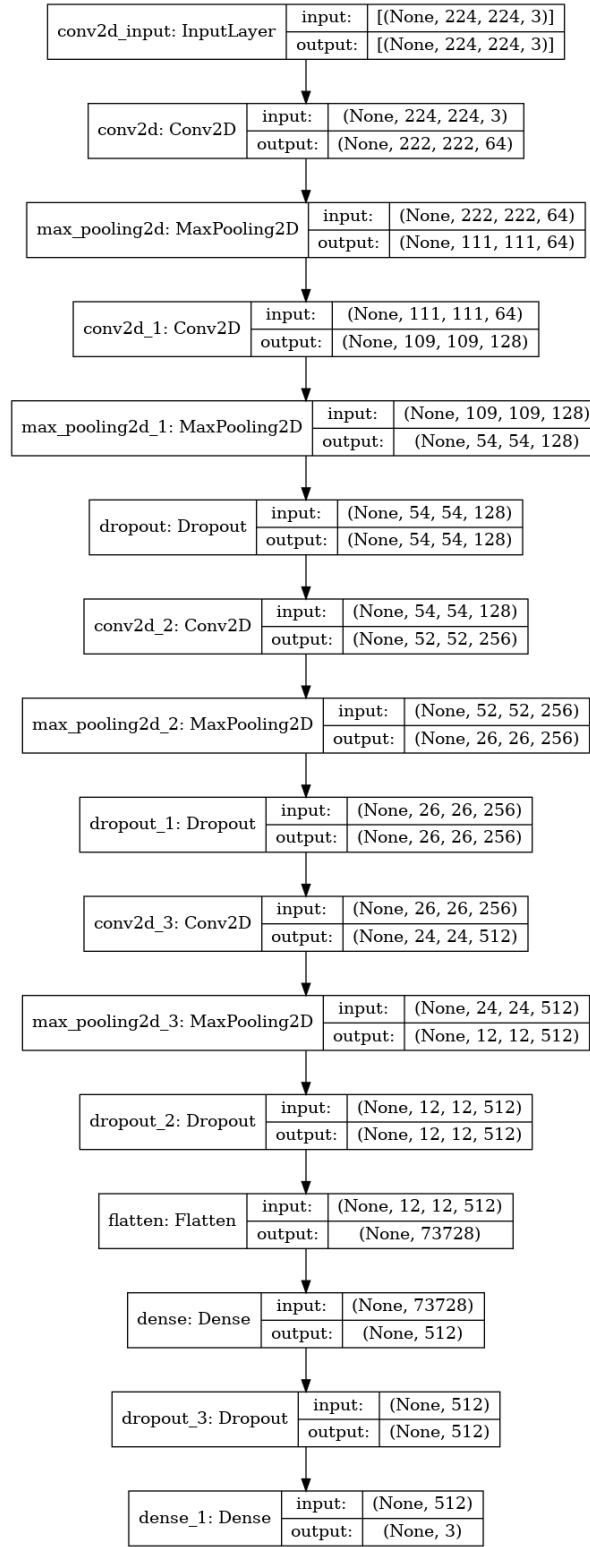


الشكل (3) شكل دالة Sigmoid [14]

5. النموذج المقترح

يتكون النموذج المقترح والموضح بالشكل (3) من أربع طبقات التفاف Convolution، أربع طبقات أخذ العينات Max Pooling، ثلاثة طبقات Dense للتصنيف وطبقة واحدة Flatten. تم استخدام ثلاثة طبقات Dropout لتحسين عملية التعلم وتقليل الملائمة الزائدة (Overfitting) وتحسين أداء النموذج النهائي.

تكون أبعاد الصورة المدخلة (3,224,224)، ويتكون النموذج من طبقة التفاف تحتوي على 64 قناة بفلتر حجمه 3*3 تليها طبقة Pooling، ثم طبقة التفاف تحتوي على 128 قناة بفلتر 3*3 تليها طبقة Pooling وطبقة Dropout، ثم طبقة التفاف بعدد 256 قناة بفلتر 3*3 تليها طبقة Pooling وطبقة Dropout، ثم طبقة التفاف بعدد 512 قناة بفلتر 3*3 تليها طبقة Padding وطبقة Dropout، ثم طبقة التفاف بعدد 512 قناة بفلتر 3*3 تليها طبقة Padding وطبقة Dropout، ثم طبقة Flatten ثم ثلاث طبقات Dense الأخيرة منها بعدد 3 قنوات والتي تمثل خرج النموذج المتكون من التصنيفات الثلاثة وهي صورة (طبيعية - التهاب رئوي - COVID-19).




الشكل (4) بنية النموذج المقترح

6. خطوات وآلية العمل

تم إنجاز هذا العمل بلغة Python واستخدام منصة Google Colab وتم تدريب النموذج باستخدام صور من موقع Kaggle وعددها 6432 صورة.

أ- إعداد وتجهيز البيانات

- تم استخدام بيانات من موقع kaggle عددها 6432 صورة، وهي صور أشعة سينية للصدر تحتوي على 1583 صور طبيعية (سليمة) و 4273 صورة مصابة بالتهاب رئوي Pneumonia و 576 صورة مصابة بمرض COVID-19 [15].
- تم إجراء Image augmentation على الصور، هذه العملية لزيادة عدد عينات الصور بأليات معينة منها قلب الصور أو إزاحتها. حيث تم زيادة عينات التدريب بنسبة 50%.
- تقسيم الصور (6432) الى 80% للتدريب و 20% للاختبار. الشكل (5) يوضح عينة من الصور المستخدمة في هذه الورقة وتحتوي على صور من الفئات الثلاثة.



الشكل (5) عينة من الصور المستخدمة [15]

ب- إعداد وتدريب النموذج المقترح

تم تدريب هذا النموذج باستخدام البيانات المجمعة وبتكرار Epochs=80 و Batch size=64 للحصول على الدقة المطلوبة، وتم تجميع النتائج وتقييمها ومناقشتها.

ت- تقييم النموذج

لتقييم النموذج في مرحلة الاختبار (Test) تم استخدام الدقة والضبط والاستدعاء أو الحساسية و F_1 score وفيما يلي المعادلات الرياضية لهذه المقاييس

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

$$\text{الضبط (Precision)} = \frac{TP}{TP + FP} \quad (3)$$

$$\text{الحساسية (Sensitivity or Recall)} = \frac{TP}{TP + FN} \quad (4)$$

$$F_1 \text{ score} = 2 TP / (TP + FP + FN) \quad (5)$$

ترمز TP: (True Positive) إيجابي صحيح وهذا يعني أن الصورة مصابة بالمرض وتصنيف النموذج صحيح.

TN: (True Negative) سلبي صحيح وهذا يعني أن الصورة غير مصابة أي طبيعية (سليمة) وتصنيف النموذج صحيح.


FP: (False Positive) إيجابي خاطئ ويعني أن توقع أو تصنيف النموذج خاطئ، أي أن الصورة طبيعية ولكن النموذج صنفها على أنها مصابة بالمرض.

FN: (False negative) سلبي خاطئ ويعني أن توقع أو تصنيف النموذج خاطئ، أي أن الصورة مصابة ولكن النموذج صنفها على أنها طبيعية، وهذا الخطأ هو الأسوأ والأخطر طبياً حيث يتم تصنيف الحالات المريضة على أنها سليمة [16] [17].


بالإضافة إلى المقاييس السابقة تم التقييم بمصفوفة الارتباك Confusion Matrix، وهو مصطلح يستخدم في مجال تقييم نماذج التعلم الآلي عن طريق قياس عدد الأخطاء التي يقوم بها النموذج في تصنيف الصور. ويتم ذلك بتصنيف عدد من العينات المعروفة مسبقاً ومقارنتها بالتصنيف الذي قام به النموذج على نفس العينات. حيث تعرض العلاقة بين عدد التصنيفات الصحيحة وعدد التصنيفات الخاطئة التي يؤديها النموذج، وبالتالي تتيح هذه المصفوفة تحليل أداء النموذج بشكل أكثر دقة وفهم أي نوع من الأخطاء التي يتم ارتكابها [17].

7. النتائج والمناقشة

في هذا الجانب سيتم مناقشة وعرض النتائج الخاصة بالنموذج المقترح والمتضمنة في منحنيات الدقة والفقد لعملية التدريب والاختبار بالإضافة إلى المقاييس ومصفوفة الارتباك الخاصة باختبار أداء النموذج، وسيتم مقارنة هذه النتائج ببعض الأبحاث السابقة.



الشكل (6) منحنيات الدقة لعملية تدريب واختبار النموذج



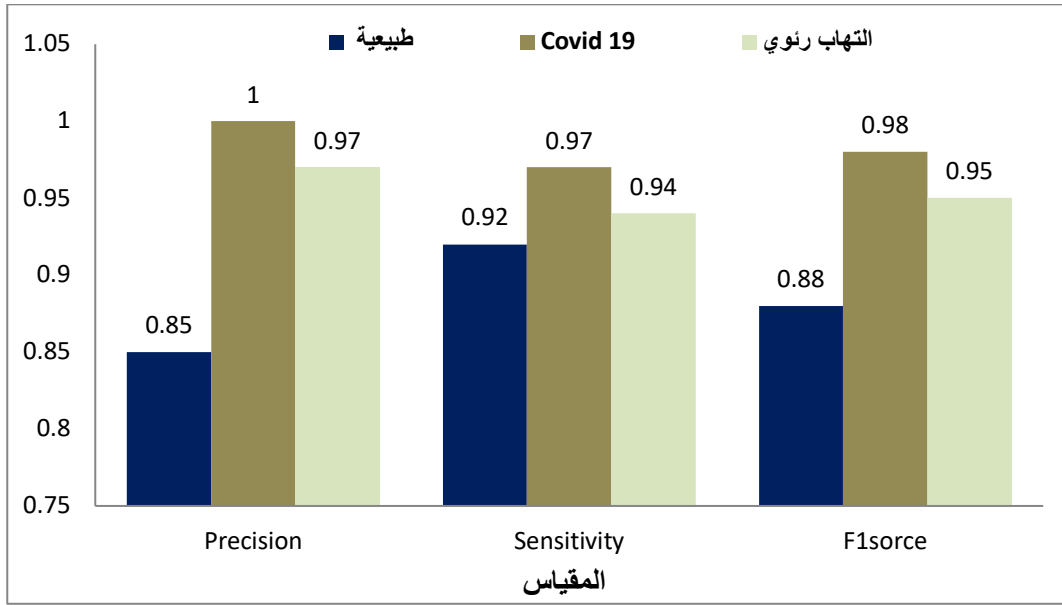
الشكل (7) منحنيات الفقد لعملية تدريب واختبار النموذج

الشكل (6) يوضح الدقة الخاصة بالنموذج (للتدريب والاختبار) مقابل عدد Epochs، حيث بلغت دقة التدريب 95% ودقة الاختبار 95% تقريبا، أما الشكل (7) يوضح الفقد مقابل عدد Epochs لكل من عملية التدريب والاختبار حيث بلغت 0.15 تقريبا للتدريب والاختبار.

الجدول (1) يوضح مقاييس أداء النموذج لكل تصنيف من التصنيفات الثلاثة

المقياس			تصنيف الصورة
F ₁ score	Sensitivity	Precision	
0.88	0.92	0.85	طبيعية (سليمة)
0.98	0.97	1	COVID-19
0.95	0.94	0.97	التهاب رئوي

من الجدول (1) والشكل (8) نلاحظ أن أفضل أداء للنموذج كان في تصنيف مرض كورونا يليه الالتهاب الرئوي ويأتي أخير تصنيف الحالات الطبيعية وهذا ما أظهرته المقاييس الثلاثة المستخدمة.



الشكل (8) يوضح اختبار أداء النموذج للمقاييس والتصنيفات الثلاثة

الشكل (9) يوضح Confusion matrix الخاصة باختبار النموذج للتصنيفات الثلاثة المعروفة سابقا، تم اختبار النموذج بعدد 112 صورة مصابة بمرض COVID-19 ونجح النموذج في تصنيفها بالكامل أي بنسبة 100%، ونجح النموذج في تصنيف 291 صورة طبيعية من أصل 341 أي بنسبة 85% وأخطأ في تصنيف 50 صورة، أخيرا نجح النموذج في تصنيف 806 مصابة بالتهاب رئوي وتمثل نسبة 97% وأخطأ في 29 صورة.

Confusion Matrix - Test Set

	Actual	COVID19	NORMAL	PNEUMONIA
Actual				
COVID19 -		112	1	3
NORMAL -		0	291	26
PNEUMONIA -		0	49	806
		COVID19	NORMAL	PNEUMONIA

الشكل (9) يوضح مصفوفة الارتباك (Confusion matrix) لعملية اختبار النموذج

كما ذكر سابقا أن تصنيف الحالات المصابة على أنها سليمة (FN) أخطر بكثير من تصنيف الحالات السليمة على أنها مصابة (FP)، هذا التشخيص الخاطئ (FN) يؤدي لانتقال العدوى وانتشار المرض كما حدث في مرض كورونا. لكن نلاحظ هنا في مصفوفة الأرباك أن النموذج قام بتصنيف عدد 50 صورة طبيعية (سليمة) على أنها مصابة وأيضا قام بتصنيف 29 صورة مصابة على أنها سليمة، حيث تمثل $FP=63.3\%$ و $FN=36.7\%$ وهذا ما يميز النموذج.

نلاحظ من المصفوفة أن الخطأ الأكبر في التصنيف كان بين الصور الطبيعية والالتهاب الرئوي بعدد 75 صورة، وأخطأ النموذج في تصنيف 3 صور فقط بين COVID-19 والالتهاب الرئوي أي أن النموذج فعال جدا في التمييز ما بين المرضين وهذا من الأهداف الأساسية لهذا العمل.

الجدول (2) يوضح بعض الأوراق البحثية السابقة ونتائجها مقارنة بالنموذج المقترح. نلاحظ من الجدول اختلاف النتائج حيث تتراوح الدقة ما بين 88% إلى 98%، ويتخلف عدد الصور المستخدمة للتدريب من 100 صورة إلى 6432 صورة، ويتراوح عدد التصنيفات من 2 إلى 4 تصنيفات. الاختلاف الأساسي في هذه النماذج هو عدد الطبقات المستخدمة، فبعض هذه النماذج بسيط جدا وبعدد طبقات قليلة كما في النموذج المقترح، أما البعض الآخر معقد وبعدد كبير من الطبقات كما في المراجع [8] [9] [10] وهذه من أحدث النماذج المستخدمة في هذا المجال. هناك نماذج أخرى تستند على آلية نقل التعلم من نموذج (مدرب مسبقا بكم هائل من الصور) إلى نموذج آخر كما في المراجع [11] [12] [18] [19] وهذا الأسلوب فعال ويرفع من دقة النموذج لكنه يحتاج إلى حواسيب ذات مواصفات عالية جدا لتنفيذها بالإضافة إلى كم هائل جدا من الصور للتدريب.

أداء ودقة النموذج المقترح ممتاز مقارنة ببعض النماذج الأخرى، حيث يتميز بالبساطة في التصميم والدقة في التصنيف والسرعة في الإعداد والتدريب، ويمكن تصميم وتدريب هذا النموذج بكم قليل من الصور وبحاسبات ذو مواصفات متوسطة عكس النماذج الأخرى، ويمكن تطبيقه بسهولة وفعالية في العديد من البيئات والأنظمة المختلفة دون الحاجة إلى موارد كبيرة.

على الرغم من أن النتائج توحى بأداء مرتفع للنموذج في تصنيف الصور، إلا أنه يجب مراعاة بعض النقاط الأخرى. على سبيل المثال، قد يكون هناك تباين في حجم عينة الصور المستخدمة للتدريب والاختبار، ويمكن أن تكون هناك عوامل خارجة عن النموذج نفسه قد تؤثر على دقة التصنيف، مثل جودة الصور المستخدمة في الاختبار أو عوامل التلاعب بالصور وقلة العينات المستخدمة.

الجدول (2) مقارنة النموذج المقترح بالأبحاث السابقة

رقم المرجع	الدقة (Accuracy)	الآلية المستخدمة	عدد الصور المستخدمة	عدد التصنيفات	ت
[8]	%96 %95 %98 %96	ResNET ResNet50 VGG19 InceptionV3	100	2	1
[9]	%96	CheXNet	1326	2	2
[10]	أعلى دقة %98	العديد من النماذج	6100	3	3
[11]	Binary class = 96% Multi class = 92.5%	Vgg16 نقل التعلم	1428	2	4
[12]	%92.93	نقل التعلم EfcientNetB0 Inceptionv3,VGG16	3106	3	5
[18]	%88.10	nCOVnet يعمل على نقل التعلم من النموذج VGG16	5863	4	6
[19]	%91.8	Random Forest Logistic Regression, Support Vector Machine	1400	2	7
-	%95	النموذج المقترح	6432	3	8

8.الاستنتاج

في هذه الورقة تم تصنيف صور الأشعة السينية للصدر باستخدام CNN وأظهر النموذج المقترح دقة مرتفعة وبلغت %95 وكانت هذه النسبة جيدة مقارنة بالنتائج السابقة، حيث أثبت هذا النموذج فعاليته في التصنيف وخاصة التمييز بين المرضين. تم حل مشكلة الصور القليلة باستخدام Image augmentation حيث كان هذا الحل فعال جزئياً في رفع دقة التدريب للنموذج، ومع ذلك لا يزال عدد العينات قليل. كانت المتغيرات في هذه الدراسة كثيرة جداً، حيث أثرت هذه المتغيرات تأثيراً مباشراً على دقة وأداء النموذج وتم العمل عليها واختيار الأنسب للوصول إلى أفضل نتائج ممكنة.

يمكن للذكاء الاصطناعي أن يساعد في التشخيص الطبي حيث يتميز بالسرعة والدقة، لكن يجب الإشارة هنا إلى أن الذكاء الاصطناعي يتطلب خبرة الأطباء والمتخصصين الطبيين في تحليل وتفسير البيانات التي يعتمد عليها بناء نماذج الذكاء الاصطناعي، حيث لا يمكن الاعتماد الكلي على الذكاء الاصطناعي بل يظل الإنسان هو الأساس وهذه الآليات ماهي إلا وسائل مساعدة فقط.

لغة Python تعتبر من أفضل الاختيارات للتعلم الآلي والذكاء الاصطناعي بفضل نظام المكتبات الواسع الذي يتيح التعامل مع البيانات وتحليلها ومعالجتها (وذلك ما يعكسه التوجه الحالي لمثل هذه التطبيقات المبنية باستخدام المنصات السحابية). وأخيراً، فإن مواصفات الحاسوب المستخدم مثل (المعالج وحجم الذاكرة الوصول العشوائي وكثرت الشاشة) تؤثر على سرعة بناء النماذج وتدريبها، حيث كانت هذه أولى المشكلات والعقبات الأساسية في هذا العمل.

المراجع

- [1] World Health Organization, "WHO guidelines on the use of chest imaging in COVID-19," 2022.
- [2] World Health Organization, "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, 2020.
- [3] National Heart Lung and Blood Institute, "Pneumonia," [Online]. Available: <http://www.nhlbi.nih.gov/health/health-topics/topics/pnu>. [Accessed: Jul. 15, 2023].
- [4] J. H. Reynolds, G. McDonald, H. Alton, & S. B. Gordon, "Pneumonia in the immunocompetent patient," The British journal of radiology, vol. 83, no. 996, pp. 998-1009, 2010.
- [5] K. Simonyan & A. Zisserman, "Very deep convolutional networks for large-scale image recognition," arXiv preprint arXiv:1409.1556, September 2014.
- [6] K. He, X. Zhang, S. Ren, & J. Sun, "Identity mappings in deep residual networks," in Computer Vision - ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11-14, 2016, Proceedings, Part IV, vol. 9908, pp. 630-645, Springer International Publishing, 2016.
- [7] P. Rajpurkar, J. Irvin, K. Zhu, B. Yang, H. Mehta, T. Duan, D. Ding, A. Bagul, C. Langlotz, K. Shpanskaya, M. Lungren, & A. Ng, "CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning," arXiv preprint arXiv:1711.05225, November 2017.
- [8] M. Ilyas, H. Rehman, & A. Naït-Ali, "Detection of COVID-19 from Chest X-ray Images Using Artificial Intelligence: An Early Review," arXiv preprint arXiv:2004.05436, April 2020.
- [9] A. Haghanifar, M. M. Majdabadi, Y. Choi, S. Deivalakshmi, & S. Ko, "COVID-CXNet: Detecting COVID-19 in Frontal Chest X-ray Images Using Deep Learning," Multimedia Tools and Applications, vol. 81, no. 21, pp. 30615-30645, Jan. 2022.

-
- [10] B. Sekeroglu & I. Ozsahin, "<?COVID19?> Detection of COVID-19 from Chest X-Ray Images Using Convolutional Neural Networks," SLAS Technology: Translating Life Sciences Innovation, vol. 25, no. 6, pp. 553-565, Dec. 2020.
- [11] M. K. Pandit, S. A. Bandy, R. Naaz, & M. A. Chishti, "Automatic Detection of COVID-19 from Chest Radiographs Using Deep Learning," Radiography, vol. 27, no. 2, pp. 483-489, May 2021.
- [12] L. Gaur, U. Bhatia, N. Z. Jhanjhi, G. Muhammad, & M. Masud, "Medical Image-Based Detection of COVID-19 Using Deep Convolution Neural Networks," Multimedia Systems, pp. 1-10, Oct. 2021.
- [13] Y. LeCun, K. Kavukcuoglu, & C. Farabet, "Convolutional Networks and Applications in Vision," in Proceedings of 2010 IEEE International Symposium on Circuits and Systems, pp. 253-256, May 2010.
- [14] M. Mukherjee, "Convolutional Neural Networks, Explained," Towards Data Science, 2020. [Online]. Available: <https://towardsdatascience.com/convolutional-neural-networks-explained/> [Accessed: Jul. 20, 2023].
- [15] P. PATEL, "Chest X-ray (Covid-19 & Pneumonia)." Kaggle, 2019, <https://www.kaggle.com/datasets/prashant268/chest-xray-covid19-pneumonia/> [Accessed: Jul. 20, 2023].
- [16] B. Sekeroglu & I. Ozsahin, "Detection of COVID-19 from Chest X-Ray Images Using Convolutional Neural Networks," in Proceedings of the 2020 International Conference on Computer Science, Engineering and Applications (ICCSEA), pp. 291-297, December 2020.
- [17] M. Sokolova & G. Lapalme, "A Systematic Analysis of Performance Measures for Classification Tasks," Information Processing & Management, vol. 45, no. 4, pp. 427-437, Jul. 2009.
- [18] H. Panwar, P. K. Gupta, M. K. Siddiqui, R. Morales-Menendez, and V. Singh, "Application of Deep Learning for Fast Detection of COVID-19 in X-Rays Using nCOVnet," Chaos, Solitons & Fractals, vol. 138, pp. 109944, Aug. 2020.
- [19] M. Mijwil, "Implementation of Machine Learning Techniques for the Classification of Lung X-Ray Images Used to Detect COVID-19 in Humans," Iraqi Journal of Science, vol. 62, no. 4, pp. 2099-2109, Oct. 2021.