

تشخيص الإصابة بفيروس كورونا بتحليل الصور المقطعية

طالبة دكتوراه: م. فتن خليل قسم هندسة البرمجيات ونظم المعلومات

كلية الهندسة المعلوماتية - جامعة البعث

إشراف: د. مهند رجب

ملخص:

منذ ظهور Covid-19 في أواخر 2019 في مدينة ووهان الصينية، أصبح التعرف على COVID-19 من خلال الصور الطبية موضوعاً بحثياً نشطاً وهاماً لكل من يعمل في مجال التعلّم الآلي والمجالات الأخرى المرتبطة. لوقف انتشار COVID-19، من الضروري التعرف على الأشخاص المصابين ثم حصرهم وقد أثبتت العديد من طرق التعرف كفاءتها بما في ذلك RT-PCR والمسح المقطعي والأشعة السينية. على الرغم من أن اختبار RT-PCR يعتبر المعيار الذهبي في تشخيص COVID-19، إلا أنه يحتوي على معدل سلبي زائف كبير، خاصة في المراحل المبكرة من الإصابة. في المقابل، يمكن أن يؤدي استخدام طرق المسح بالأشعة السينية وطرق المسح المقطعي المحوسب إلى نتائج فعالة من حيث الوقت والدقة. ولكن استخدام الأشعة المقطعية والأشعة السينية يتطلب وجود أخصائي أشعة خبير لتحديد العدوى، ولحل هذه المسألة يمكن أن توفر أنظمة الذكاء الاصطناعي وتحديداً التعلّم العميق حلاً بديلاً للتشخيص اليدوي لـ COVID-19. في هذا البحث قمنا بتطبيق طرائق التعلّم العميق الشائعة والهامة وهي التعلّم المتبقي والشبكات الكثيفة الاتصال وبنى Inception على قاعدة بيانات صور مقطعية للرئة للكشف عن الإصابة بـ COVID-19. وقد كانت أعلى دقة وصلنا إليها في التصنيف 85.7% والتي حصلنا عليها من خلال تطبيق Inception-v3 مع مصنف XG-Boost.

الكلمات المفتاحية: خوارزميات التعلّم العميق، التعلّم الآلي، الصور المقطعية، فيروس

كورونا، الشبكات المتبقية، الشبكات الكثيفة

Diagnosis of corona virus by analysing CT scans

Abstract

Since the appearance of the COVID-19 at the end of 2019, Wuhan, China, the recognition of COVID-19 with medical imaging has become an active research topic for the machine learning and computer vision community.

To stop the spread of COVID-19, it is mandatory to recognize and then confine infected persons. Many recognition methods have proved their efficiency including RT-PCR, CT scans, and X-ray scans. Despite the fact that the RT-PCR test is considered as the gold standard in diagnosing COVID-19, it has a considerable false negative rate, especially in early stages of infection. In contrast, using X-ray scan and CT scan methods can give efficient results in both time and accuracy. In fact, using CT scans and X-ray scans requires an expert radiologist to identify the COVID-19 infection. Artificial intelligence (AI) systems can provide an alternative solution for automatic diagnosis of vCOVID-19 infections. In this search we applied the most common and important deep learning methods as residual, dense Nets and Inception-V3 on lung Ct scan dataset to diagnosis the infection of COVID-19. The precision we have got was 85.7% by using Inception-v3 and XG-Boost classifier.

Keywords:

Deep learning algorithms, machine learning, CT scans, COVID-19, Resnets, Densenets

مقدمة:

بعد الإبلاغ عن الإصابة بفيروس كورونا الجديد لأول مرة في ووهان الصينية انتشرت بقوة منذ يناير 2020 في جميع أنحاء العالم. أعلنت منظمة الصحة العالمية [1] أن تفشي مرض فيروس كورونا 2019 (COVID-19) سيكون حالة طوارئ صحية عامة تثير قلقاً دولياً في 30 يناير 2020.

COVID-19 هو مرض تنفسي يسببه فيروس كورونا SARS-CoV-2 [2]. تشمل الأعراض الأكثر شيوعاً الحمى ، والتعب ، والسعال الجاف وفقدان الشهية وآلام الجسم والمخاط [3] إضافة إلى بعض الأعراض غير المحددة التي تشمل التهاب الحلق والصداع وقشعريرة مع اهتزاز في بعض الأحيان ، فقدان حاسة الشم أو الذوق ، سيلان الأنف أو القيء أو الإسهال [4]. قد يتعافى الأشخاص المصابون بأعراض خفيفة من تلقاء أنفسهم. الأشخاص الذين يعانون من حالات صحية أخرى مثل مرض السكري أو مشاكل في القلب قد يعانون من أعراض خطيرة [5].

بالمقارنة مع RT-PCR ، قد يكون التصوير المقطعي (CT) أكثر موثوقية وأسرع لتصنيف وتقييم COVID-19 ، لا سيما في منطقة الوباء.

يوجد في جميع المستشفيات تقريباً فحص بالصور المقطعية ويمكن استخدام التصوير المقطعي للصدر للكشف المبكر عن مرضى كوفيد-19. ولكن التصنيف المستند إلى التصوير المقطعي للصدر يتطلب خبيراً في الأشعة ، ويضيع الكثير من الوقت.

تستغرق نتائج اختبار COVID-19 أكثر من 24 ساعة للكشف عن الفيروس في جسم الإنسان. هناك حاجة ملحة للتعرف على المرض في المرحلة المبكرة ووضع المصابين فوراً تحت الحجر الصحي. ذكرت الحكومة الصينية أن التشخيص لتأكيد COVID-19 يتم بمساعدة تفاعل البلمرة المتسلسل في الوقت الحقيقي (RT-PCR) [6]. يعاني RT-PCR من معدلات سلبية زائفة عالية ويستهلك الكثير من الوقت لأن الجهاز

المستخدم للاختبار يستغرق حوالي 4-8 ساعات لمعالجة عينات المرضى. اختبار RT-PCR منخفض الحساسية غير مرضٍ في حالة الجائحة. في بعض الحالات قد لا يتم التعرف على المصابين في الوقت المحدد ولا يتلقون العلاج المناسب. يمكن تصنيف المصابين في بعض الأحيان على أنهم سلبيون لـ COVID-19 بسبب نتيجة سلبية خاطئة false-negative [7].

وبالتالي فإن التحليل الآلي للصور المقطعية للصدر أمر مرغوب فيه لتوفير الوقت الثمين للطواقم الطبي المتخصص. سيؤدي هذا أيضاً إلى تجنب التأخير في بدء العلاج.

التعلم العميق هو الأسلوب الأكثر فعالية الذي يمكن استخدامه في العلوم الطبية [8]. فهو طريقة سريعة وفعالة لتشخيص الأمراض المختلفة والتنبؤ بها بمعدل دقة جيد. كما أنه هناك نماذج مدربة بشكل خاص لتصنيف المدخلات إلى الفئات المختلفة التي يرغب بها المبرمجون.

في المجال الطبي ، يتم استخدام التعلم العميق للكشف عن مشاكل القلب والأورام باستخدام تحليل الصور وتشخيص السرطان والعديد من التطبيقات الأخرى [9]. يتم استخدامه أيضاً للتمييز بين صور الأشعة المقطعية للمرضى المصابين بـ COVID-19 على أنها إيجابية أو سلبية.

هدف البحث:

تشخيص الإصابة بمرض Covid19 بتحليل الصور المقطعية للرئة، واكتشاف قدرة خوارزميات التعلم العميق على اكتشاف الإصابة بهذا المرض وخصوصاً البنى الثلاثة المهمة للتعلم العميق Resnet ، Densenet و Inceptionv3 والتي أثبتت فعاليتها في اكتشاف أمراض أخرى في الرئة وغيرها عن طريق تحليل الصور المقطعية.

1. أدوات البحث:

تم إجراء البحث باستخدام حاسب بمعالج إنتل core i3 وذاكرة 8 غيغا بايت، ونظام تشغيل Windows 10 64bit.

تم استخدام الموقع www.kaggle.com كونه يعتبر فضاء مفتوح المصدر يسمح بتنفيذ الأكواد بلغة بايثون بشكل سريع.

2. الدراسات السابقة:

تم إجراء العديد من الدراسات والأبحاث في مجال التشخيص بتحليل الصور المقطعية (CT) باستخدام التعلّم العميق.

في البحث الذي أجراه Grewal وزملاؤه [10] تم دمج بنية DenseNet وطبقة الشبكة العصبونية المتكررة لتحليل 77 من الصور المقطعية للدماغ.

أما البحث الذي أجراه Song وزملاؤه [11] تم تصميم ثلاثة أنواع من الشبكات العصبية العميقة (CNN و DNN و SAE) لتصنيف سرطان الرئة. تم العثور على نموذج CNN بدقة أفضل مقارنة بالنماذج الأخرى.

باستخدام التعلّم العميق ، وتحديداً تحليل الشبكة العصبية التلافيفية (CNN) ، غونزاليس و زملاؤه [12] أثبتوا أنه يمكن أن يتم كشف مرض الانسداد الرئوي المزمن (COPD) والتنبؤ بأمراض الجهاز التنفسي الحادة (ARD) ووفيات المدخنين. عند ظهور COVID-19 ، تم اكتشاف أن CT تكون مفيدة في تشخيص مرضى COVID-19.

لاكتشاف العلاقة بين نتائج التصوير المقطعي للصدر والشروط السريرية لمرض COVID-19. تم جمع بيانات عن 101 حالة من حالات الالتهاب الرئوي COVID-19 من أربع مؤسسات في هونان الصينية. تم تقييم ومقارنة الخصائص السريرية الأساسية وميزات التصوير الدقيقة. أجرى بيرنهام وزملاؤه دراسة على التصوير المقطعي

المحوسب للصدر لـ 121 مريضاً مصاباً بفيروس كورونا [13] وحددوا السمات المميزة لعدوى COVID-19 كما تظهر في صور الأشعة المقطعية.

نظراً لصعوبة الحصول على مجموعات البيانات المتعلقة بـ COVID-19 ، قام Zhao وزملاؤه بإنشاء مجموعة بيانات COVID-CT مفتوحة المصدر ، والتي تحتوي على 349 صورة مقطعية لـ COVID-19 من 216 مريضاً و 463 صورة مقطعية سليمة. وباستخدام مجموعة البيانات السابقة ، طور Gozes وزملاؤه نموذج تشخيص قائم على الذكاء الاصطناعي لتشخيص COVID-19 من صور التصوير المقطعي للكشف عن فيروس كورونا وتتبعه [14]. كانت دقة النموذج المطور 95%.

تم تطوير نظام برمجي قائم على التعلم العميق للكشف التلقائي عن COVID-19 من الصور المقطعية للصدر من قبل Zheng وزملائه [15].

باستخدام 3D CT volumes للكشف عن COVID-19. تم استخدام شبكة UNet المدربة مسبقاً وشبكة عصبية عميقة ثلاثية الأبعاد للتنبؤ باحتمالية الإصابة بعدوى COVID-19 في مجموعة من 630 فحصاً بالأشعة المقطعية. من بين 1014 مريضاً، ثبتت إصابة 601 مريضاً بـ COVID-19 بناءً على RT-PCR وتمت مقارنة النتائج مع التصوير المقطعي للصدر، كانت حساسية التصوير المقطعي المحوسب للصدر في اقتراح Ai 97% .

أما الباحث Fang وزملاؤه قاموا بتكوين سلسلة من 51 مريضاً مع اختبارات CT و RT PCR للصدر تم إجراؤها في غضون 3 أيام [16] ، كانت حساسية التصوير المقطعي المحوسب لعدوى COVID-19 بلغت 98 % مقارنة بحساسية RT-PCR البالغة 71%.

3. خوارزميات التعلم العميق المستخدمة:

ResNet .i

الشبكات العميقة المتبقية residual networks مثل نموذج ResNet-50 الشهير عبارة عن شبكة عصبية تلافيفية (CNN) بعمق 50 طبقة. الشبكة العصبية المتبقية (ResNet) هي شبكة عصبية اصطناعية (ANN) من النوع الذي يكس الكتل المتبقية فوق بعضها البعض لتشكيل شبكة. وهي شبكة عصبية مبتكرة تم تقديمها لأول مرة بواسطة Kaiming He و Xiangyu Zhang و Shaoqing Ren و Jian Sun في ورقة بحثية حول الرؤية الحاسوبية لعام 2015 بعنوان "Deep Residual Learning for Image Recognition" [17].

بنية Resnet-34:

كانت بنية ResNet الأولى هي Resnet-34 ، والتي تضمنت إدخال اتصالات مختصرة في الشبكة لتحويل شبكة عادية إلى نظيرتها المتبقية. في هذه الحالة ، كانت الشبكة العادية مستوحاة من شبكات VGG العصبية (VGG-16 ، VGG-19) ، مع وجود فلاتر 3×3 للشبكات التلافيفية. ومع ذلك ، بالمقارنة مع شبكات VGGNets ، فإن شبكات ResNets لديها فلاتر أقل وتعقيد أقل. الشكل (1) يظهر بنية هذه الشبكة مقارنة مع نموذج vgg.

كما اتبعت هذه البنية قاعدتي تصميم بسيطتين حيث كان للطبقات نفس عدد الفلاتر لنفس حجم خريطة بارامترات الخرج ، وتضاعف عدد الفلاتر في حالة خفض حجم خريطة البارامترات إلى النصف من أجل الحفاظ على التعقيد الزمني لكل طبقة. وهي تتكون من 34 طبقة موزونة.

تمت إضافة اتصالات الاختصار إلى الشبكة العادية. بينما بقيت أبعاد الدخل والخرج نفسها ، تم استخدام identity shortcuts بشكل مباشر.

مع زيادة الأبعاد ، كان هناك خياران يجب النظر فيهما. الأول هو أن الاختصار سيستمر في إجراء identity mapping بينما ستم تعبئة إدخلات صفرية إضافية لزيادة الأبعاد. أما الخيار الآخر هو استخدام projection shortcut لمطابقة الأبعاد.

: ResNet50

هو نوع مختلف من ResNet الذي يحتوي على 48 طبقة التفاف إلى جانب طبقة واحدة MaxPool وطبقة واحدة average Pool. وهو نموذج ResNet مستخدم على نطاق واسع.

تعتمد بنية Resnet50 على نفس النموذج المذكور في بنية Resnet34 ، هناك اختلاف رئيسي واحد حيث تم تعديل الكتلة الإنشائية إلى تصميم عنق الزجاجة بسبب مخاوف بشأن الوقت الذي يستغرقه تدريب الطبقات. تم استخدام مكس من ثلاث طبقات بدلاً من استخدام طبقتين في البنية السابقة.

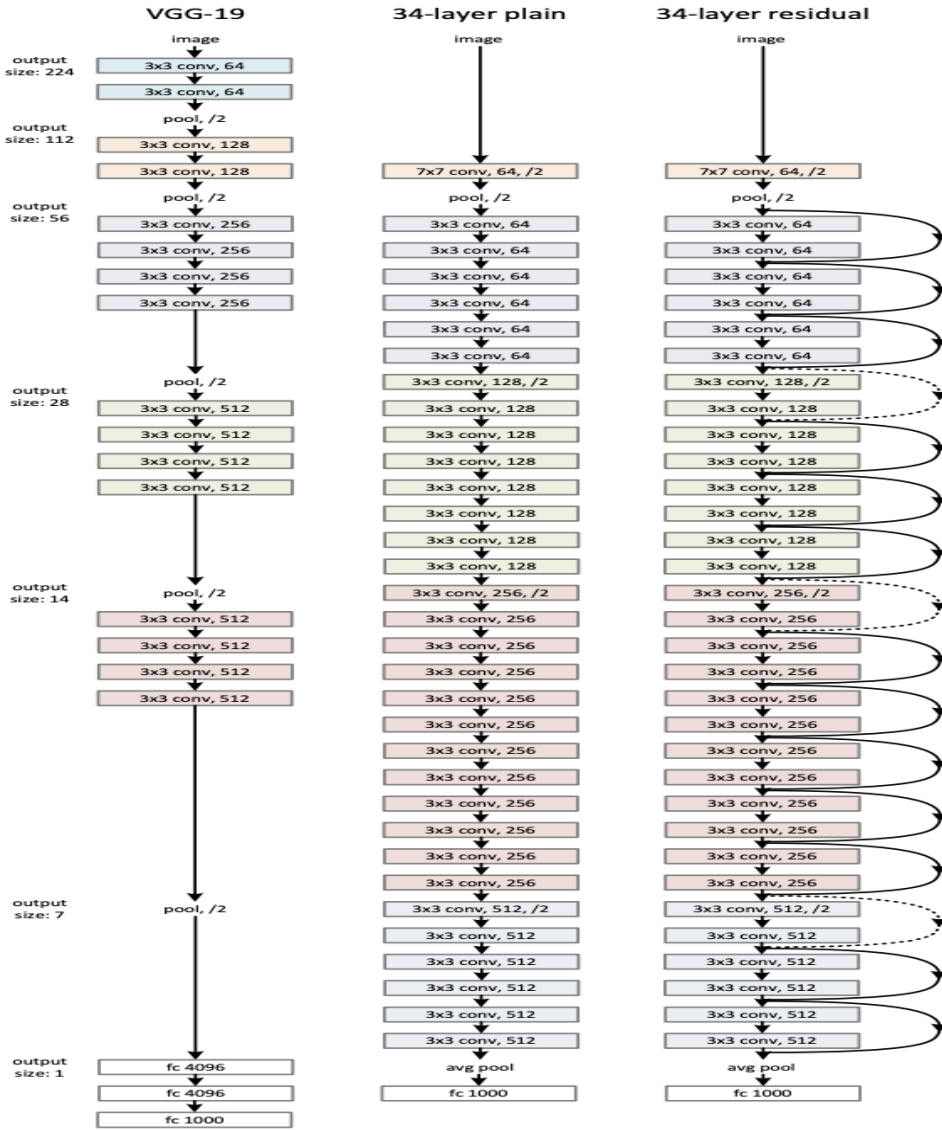
لذلك ، تم استبدال كل من الكتل المكونة من طبقتين في Resnet34 بكتلة عنق الزجاجة المكونة من ثلاث طبقات لتشكيل بنية Resnet 50. هذا التعديل يعطي دقة أعلى بكثير من نموذج ResNet المكون من 34 طبقة [18].

بنية ResNet-101 و ResNet-152

يتم إنشاء الشبكات الكبيرة المتبقية ذات 101 طبقة مثل ResNet101 أو ResNet152 باستخدام المزيد من الكتل ثلاثية الطبقات. وحتى مع زيادة عمق

الشبكة ، فإن شبكة ResNet ذات 152 طبقة لديها تعقيد أقل بكثير من شبكات VGG-16 أو VGG-19.

أي باختصار إن الشبكة المتبقية أو ResNet تعد ابتكارا هاما غير تدريب الشبكات العصبية التلافيفية العميقة للمهام المتعلقة بالرؤية الحاسوبية. بينما كانت Resnet الأصلية تحتوي على 34 طبقة وتستخدم كتل من طبقتين ، فإن التحسينات عليها مثل Resnet50 استخدمت كتل عنق الزجاجاة المكونة من 3 طبقات لضمان دقة محسنة ووقت تدريب أقل [18].



الشكل (1) بنية الشبكة من أجل ImageNet، إلى اليسار نموذج VGG-19 كمرجع، في المنتصف شبكة عادية من 34 طبقة ، اليمين Resnet مكونة من 34 طبقة.

التعلم المتبقي Residual العميق للتعرف على الصور:

أدت الشبكات العصبية التلافيفية العميقة إلى سلسلة من الاختراقات في تصنيف الصور، تدمج الشبكات العميقة بشكل طبيعي الميزات والمصنفات ذات المستوى المنخفض / المتوسط / العالي بطريقة شاملة متعددة الطبقات ، ويمكن إثراء "مستويات" الميزات بعدد الطبقات المكسدة (العمق)، تكشف الأدلة الحديثة أن عمق الشبكة له أهمية حاسمة ، والنتائج الرئيسية على مجموعة بيانات ImageNet جميعها تستغل النماذج "العميقة جداً" ، بعمق من ستة عشر إلى ثلاثين. استفادت أيضاً العديد من مهام التعرف المرئي بشكل كبير من النماذج العميقة جداً.


مدفوعاً بأهمية العمق ، يطرح سؤال: هل تعليم شبكات أفضل سهل مثل تكديس المزيد من الطبقات؟ كانت إحدى العقبات التي تحول دون الإجابة على هذا السؤال هي المشكلة المتمثلة في تلاشي / انفجار التدرجات ، مما يعيق التقارب منذ البداية. ومع ذلك ، تمت معالجة هذه المشكلة إلى حد كبير عن طريق التهيئة مع التسوية normalized initialization وطبقات التسوية الوسيطة intermediate normalization layers ، والتي تمكن الشبكات التي تحتوي على عشرات الطبقات للبدء في التقارب من أجل هبوط التدرج العشوائي (SGD) مع الانتشار العكسي. عندما تكون الشبكات الأعمق قادرة على البدء في التقارب ، يتم الكشف عن مشكلة تدهور حيث مع زيادة عمق الشبكة ، تصبح الدقة مشبعة ثم تتدهور بسرعة. بشكل غير متوقع ، لا ينتج هذا التدهور بسبب overfitting ، وإضافة المزيد من الطبقات إلى نموذج عميق بشكل مناسب يؤدي إلى خطأ تدريب أعلى. يشير تدهور (دقة التدريب) إلى أنه ليست كل الأنظمة سهلة التحسين .

في هذه الورقة نضيء على معالجة مشكلة التدهور من خلال تقديم إطار عمل التعلم المتبقي العميق. بدلاً من أن نأمل أن تتلاءم كل مجموعة قليلة من الطبقات المكدسة بشكل مباشر مع الخرائط الأساسية المرغوبة ، فإننا نجعل هذه الطبقات تتناسب residual mapping.

بشكل رسمي ، بالإشارة إلى underlying mapping المطلوب بالاسم $H(x)$ ، نسمح للطبقات غير الخطية المكدسة لتلائم تعيين آخر $F(x) = H(x) - x$. ويتم إعادة صياغة التعيين الأصلي إلى $F(x) + x$. نفترض أنه من الأسهل تحسين residual mapping بدلاً من تحسين mapping الأصلي غير المرجعي.

إذا كان identity mapping هو الأمثل ، فسيكون من الأسهل دفع المتبقي إلى الصفر بدلاً من احتواء تعيين الهوية بواسطة مجموعة من الطبقات غير الخطية. يمكن تحقيق صياغة $F(x) + x$ من خلال الشبكات العصبية الأمامية ذات "وصلات الاختصار" shortcut connections (الشكل 2).

وصلات الاختصار هي تلك التي تتخطى طبقة واحدة أو أكثر. في حالتنا ، تؤدي وصلات الاختصار ببساطة identity mapping، وتضاف مخرجاتها إلى مخرجات الطبقات المكدسة (الشكل 2). لا تضيف الاتصالات المختصرة هذه أي بارامترات إضافية ولا تعقيداً حسابياً.



الشكل (2) التعلم المتبقي، كتلة بناء واحدة

يمكن اختصار ما سبق بنتيجتين رئيسيتين:

(1) من السهل تحسين الشبكات المتبقية العميقة للغاية ، لكن الشبكات "العادية" المقابلة (التي تقوم ببساطة بتكديس الطبقات) تظهر خطأ تدريب أعلى عندما يزداد العمق

(2) يمكن للشبكات العميقة المتبقية أن تتمتع بسهولة بمكاسب الدقة من العمق المتزايد بشكل كبير ، مما ينتج عنه نتائج أفضل بكثير من الشبكات السابقة.

تم تقديم نماذج مدربة بنجاح على مجموعة البيانات هذه مع أكثر من 100 طبقة ، في مجموعة بيانات تصنيف ImageNet والحصول على نتائج ممتازة من خلال شبكات متبقية عميقة للغاية. الشبكة المتبقية ذات 152 طبقة هي أعمق شبكة تم تقديمها على الإطلاق على ImageNet ، بينما لا تزال أقل تعقيداً من شبكات VGG.

مكتشفو الشبكات المتبقية فازو بالمركز الأول في مسابقة تصنيف ILSVRC 2015. تتمتع التمثيلات العميقة للغاية أيضاً بأداء تعميم ممتاز في مهام التعرف ونتوقع أن يكون قابلاً للتطبيق في مشاكل الرؤية وعدم الرؤية الأخرى[17].

.ii DenseNet

شبكة DenseNet هي نوع من الشبكات العصبية التلافيفية التي تستخدم اتصالات كثيفة بين الطبقات ، من خلال Dense Blocks ، حيث نقوم بتوصيل جميع الطبقات (بأحجام خريطة خصائص متطابقة) مع بعضها البعض مباشرة. للحفاظ على طبيعة التغذية الأمامية ، تحصل كل طبقة على مدخلات إضافية من كل الطبقات السابقة وتكرر خرائط الميزات الخاصة بها إلى كل الطبقات اللاحقة.

أظهرت الأبحاث الأخيرة أن الشبكات التلافيفية يمكن أن تكون أعمق بكثير وأكثر دقة وكفاءة للتدريب إذا كانت تحتوي على اتصالات أقصر بين الطبقات القريبة من المدخلات وتلك القريبة من المخرجات.

الشبكة التلافيفية الكثيفة (DenseNet) تربط كل طبقة بكل طبقة أخرى بطريقة التغذية الأمامية. في حين أن الشبكات التلافيفية التقليدية ذات عدد طبقات L لها اتصالات عددها L ، واحدة بين كل طبقة وطبقها اللاحقة ، تحتوي الشبكة الكثيفة على توصيلات مباشرة $(L + 1) / 2$ لكل طبقة ، تُستخدم خرائط الميزات لجميع الطبقات السابقة كمدخلات ، وتُستخدم خرائط الميزات الخاصة بها كمدخلات في جميع الطبقات اللاحقة.

تتمتع DenseNets بالعديد من المزايا: فهي تخفف من مشكلة vanishing-gradient ، وتقوي انتشار الميزات feature propagation ، وتشجع على إعادة استخدام الميزات ، وتقليل عدد البارامترات بشكل كبير.

تم تقييم بنية DenseNets على أربع مهام معيارية للتعرف على الأغراض شديدة التنافسية (CIFAR-10 و CIFAR-100 و SVHN و ImageNet).

- ميزات الشبكة الكثيفة وفروقاتها عن الشبكات السابقة


الشبكات العصبية التلافيفية (CNN) هي نهج التعلم الآلي المهيمن للتعرف على الأغراض المرئية. على الرغم من تقديمها في الأصل منذ أكثر من 20 عاماً [19] ، إلا أن التحسينات في أجهزة الكمبيوتر وبنية الشبكة مكنت من تدريب شبكات CNN العميقة بشكل جيد مؤخراً فقط. يتكون LeNet5 الأصلي [19] من 5 طبقات ، وظهر VGG في 19 طبقة [29] ، وفي العام الماضي فقط تجاوزت شبكات Highway والشبكات المتبقية ResNets حاجز 100 طبقة.

عندما تصبح شبكات CNN أكثر عمقاً ، تظهر مشكلة بحثية جديدة لأنه مع مرور المعلومات حول المدخلات أو التدرج عبر العديد من الطبقات يمكن أن تختفي و "تتلاشى" في الوقت الذي تصل فيه إلى نهاية (أو بداية) الشبكة. العديد من المنشورات الحديثة تعالج هذه المشكلة أو المشاكل ذات الصلة.

ResNets وشبكات Highway تجاوز الإشارة من طبقة إلى أخرى عبر identity connections. يعمل العمق العشوائي [20] على تقصير شبكات ResNets عن طريق حذف الطبقات بشكل عشوائي أثناء التدريب للسماح بمعلومات أفضل وتدفق متدرج.

على الرغم من أن هذه الأساليب المختلفة تختلف في طوبولوجيا الشبكة وإجراءات التدريب ، إلا أنها تشترك جميعاً في خاصية رئيسية: فهي تنشئ مسارات قصيرة من الطبقات المبكرة إلى الطبقات اللاحقة.

تم اقتراح بنية DenseNet تقطع هذه الرؤية إلى نمط اتصال بسيط: لضمان أقصى تدفق للمعلومات بين الطبقات في الشبكة ، نقوم بتوصيل جميع الطبقات (بأحجام خرائط ميزات متطابقة) مع بعضها البعض مباشرة. للحفاظ على طبيعة التغذية الأمامية ، تحصل كل طبقة على مدخلات إضافية من كل الطبقات السابقة وتكرر خرائط الميزات الخاصة بها إلى كل الطبقات اللاحقة. يوضح الشكل 3 هذا التخطيط . أي على عكس ResNets ، نحن لا نجمع أبداً الميزات من خلال الجمع قبل أن يتم تمريرها إلى طبقة بل يتم دمج الميزات من خلال ربطها معاً.



الشكل (3) كتلة كثيفة من 5 طبقات مع معدل نمو $k=4$. كل طبقة تأخذ كل خرائط الميزات السابقة كمدخل

ومن ثم ، فإن الطبقة $k\%$ تحتوي على k مدخلا وتتكون من خرائط الميزات لجميع الكتل التلافيفية السابقة. يتم تمرير خرائط الميزات الخاصة بها إلى جميع الطبقات $L-1$ اللاحقة. هذا يقدم اتصالات عددها $(L + 1) / 2$ في شبكة L -layer ، بدلاً من L اتصالاً في البنى التقليدية. بسبب نمط الاتصال الكثيف ، تسمى هذه البنية شبكة تلافيفية كثيفة (DenseNet). من المحتمل أن يكون التأثير غير البديهي لنمط الاتصال الكثيف هذا هو أنه يتطلب بارامترات أقل من الشبكات التلافيفية التقليدية ، حيث لا توجد حاجة لإعادة تعلم خرائط الميزات بشكل زائد عن الحاجة.

يمكن النظر إلى البنى التقليدية ذات التغذية الأمامية على أنها خوارزميات ذات حالة ، والتي يتم تمريرها من طبقة إلى أخرى. تقرأ كل طبقة الحالة من طبقتها السابقة وتكتب إلى الطبقة اللاحقة. إنه يغير الحالة ولكنه يمرر أيضاً المعلومات التي يجب الحفاظ عليها.

تجعل ResNets الحفاظ على هذه المعلومات صريحاً من خلال تحويلات الهوية المضافة additive identity transformations كما تُظهر الأشكال الحديثة لشبكات

ResNet أن العديد من الطبقات تساهم بشكل ضئيل جداً ويمكن في الواقع حذفها عشوائياً أثناء التدريب. هذا يجعل حالة شبكات ResNets مشابهة للشبكات العصبية المتكررة [21] ، لكن عدد بارامترات شبكات ResNets أكبر بكثير لأن كل طبقة لها أوزانها الخاصة.


تميز بنية DenseNet بشكل صريح بين المعلومات التي تمت إضافتها إلى الشبكة والمعلومات المحفوظة كما تعد طبقات DenseNet ضيقة جداً (على سبيل المثال ، 12 فلتر لكل طبقة) ، وتضيف فقط مجموعة صغيرة من خرائط الميزات إلى "المعرفة الكلية" للشبكة وتحتفظ بخرائط الميزات المتبقية دون تغيير - ويتخذ المصنف النهائي قراراً بناءً على جميع خرائط الميزات في الشبكة.

إلى جانب كفاءة البارامترات تتمثل إحدى الميزات الهامة لـ DenseNets بتحسين تدفق المعلومات والتدرجات عبر الشبكة ، مما يسهل تدريبها و تتمتع كل طبقة بوصول مباشر إلى التدرجات من خلال loss function وإشارة الدخل الأصلية ، مما يؤدي إلى إشراف ضمني عميق [22]. هذا يساعد على تدريب معماريات أعمق للشبكة. علاوة على ذلك ، نلاحظ أيضاً أن الاتصالات الكثيفة لها تأثير تنظيمي ، مما يقلل من overfitting في المهام ذات أحجام مجموعات التدريب الأصغر


تم تقييم DenseNets على أربع مجموعات بيانات معيارية عالية التنافسية (CIFAR-10 و CIFAR-100 و SVHN و ImageNet). وتم التحقق أن النماذج الكثيفة تميل إلى طلب بارامترات أقل بكثير من الخوارزميات الموجودة بدقة مماثلة. كما أنها تفوقت بشكل كبير على أحدث النتائج الحالية في معظم المهام المعيارية.

.iii Inception V3

Inception V3 by Google هو الإصدار الثالث في سلسلة من البنى التلافيفية للتعلم العميق. تم تدريب Inception V3 باستخدام مجموعة بيانات من 1000 فئة من مجموعة بيانات ImageNet الأصلية التي تم تدريبها بأكثر من مليون صورة تدريبية ، ويحتوي إصدار Tensorflow على 1001 فئة والتي ترجع إلى فئة "background" إضافية ليست مستخدمة في ImageNet الأصلية. تم تدريب Inception V3 على تحدي التعرف البصري الكبير على ImageNet حيث احتل المركز الثاني.



الشكل (4) بنية Inception v3



الشكل (5) استخدام التعلم بالنقل مع Inception V3

يتيح لك التعلم بالنقل إعادة تدريب الطبقة النهائية لنموذج موجود ، مما يؤدي إلى انخفاض كبير ليس فقط في وقت التدريب ، ولكن أيضاً في حجم مجموعة البيانات المطلوبة. يعد Inception V3 أحد أشهر النماذج التي يمكن استخدامها في التعلم بالنقل. تم تدريب هذا النموذج في الأصل على أكثر من مليون صورة من فئة 1000 على بعض الأجهزة القوية جداً.

تعني القدرة على إعادة تدريب الطبقة النهائية أنه يمكنك الحفاظ على المعرفة التي تعلمها النموذج أثناء تدريبه الأصلي وتطبيقه على مجموعة البيانات الأصغر ، مما يؤدي إلى تصنيفات دقيقة للغاية دون الحاجة إلى تدريب مكثف وقوة حسابية.

تمت مراجعة Inception-v3 من خلال إعادة التفكير في بنية inception ، يتم تحقيق الكفاءة الحسابية وعدد أقل من البارامترات لأنه مع عدد أقل من البارامترات ، يمكن تحقيق شبكة التعلم العميق المكونة من 42 طبقة ، مع تعقيد مماثل لـ VGGNet.

AlexNet : 60 مليون بارامتر

VGGNet : 3 × عدد بارامترات أكبر من AlexNet

GoogLeNet / Inception-v1 : 7 مليون بارامتر

من خلال 42 طبقة ، تم الحصول على معدل خطأ أقل ، مما جعله المركز الأول في تصنيف الصور في مسابقة ILSVRC لعام 2015.

ImageNet ، هي مجموعة بيانات تضم أكثر من 15 مليون صورة عالية الدقة مع حوالي 22000 فئة. يستخدم ILSVRC مجموعة فرعية من ImageNet من حوالي 1000 صورة في كل فئة من أصل 1000 فئة. إجمالاً ، هناك ما يقرب من 1.2 مليون صورة تدريبية و 50000 صورة تحقق و 100000 صورة اختبار.

حول إصدارات Inception

يوجد 4 إصدارات. الإصدار GoogLeNet الأول هو Inception-v1 ، ولكن هناك العديد من الأخطاء المطبعية في Inception-v3 والتي تؤدي إلى توصيفات خاطئة حول إصدارات Inception. ربما يرجع ذلك إلى المنافسة الشديدة لـ ILSVRC في تلك اللحظة. وبالتالي ، هناك العديد من المراجعات في الإنترنت التي تخط بين الإصدارين 2 و 3. حتى أن بعض المراجعات اعتقدت أن الإصدارين v2 و v3 متماثلان مع بعض الإعدادات المختلفة البسيطة فقط. ومع ذلك ، في Inception-v4 ، تمتلك Google وصفاً أكثر وضوحاً حول مشكلة الإصدار [23].

" تم تقديم بنية Inception التلافيفية العميقة باسم GoogLeNet في (Szegedy وآخرون 2015a) ، المسمى هنا Inception-v1. في وقت لاحق تم تحسين بنية Inception بطرق مختلفة ، أولاً من خلال إدخال batch normalization وهو ما يسمى Inception-v2 (Szegedy و Ioffe 2015). ثم إضافة عوامل إضافية في التكرار الثالث (Szegedy وآخرون 2015) والتي يشار إليها باسم Inception-v3 "

وهكذا ، يتحدث BN-Inception / Inception-v2 عن batch normalization
بينما يتحدث Inception-v3 عن factorization ideas.

4. البيانات المستخدمة:

قدم تحدي Covid-19 SPGC 2021 مجموعة بيانات SPGC-Covid لتقييم
أساليب المشاركين. تحتوي مجموعة البيانات على صور مقطعية للصدر لمرضى
إيجابيين يحملون COVID-19 ، والالتهاب الرئوي المكتسب للمجتمع (CAP) ،
والمرضى الطبيعيين أي لا يحملون COVID-19. يتكون كل فحص بالأشعة المقطعية
من جميع شرائح التصوير المقطعي بصيغة Digital Imaging and
(DICOM) Communications in Medicine ، بحجم 512 x 512 .

تم جمع حالات Covid-19 من شباط 2020 إلى نيسان 2020 ، في حين تم جمع
حالات CAP والحالات العادية من نيسان 2018 إلى كانون الأول 2019 وكانون
الثاني 2019 إلى أيار 2020.

يعتمد تشخيص عدوى COVID-19 على نتائج اختبار سلسلة الاختبار الإيجابية
للنسخ العكسي (RRT-PCR) ، والبارامترات السريرية ، ومظاهر المسح المقطعي
المحدد من قبل ثلاثة أطباء إشعاعيين صديريين ذوي خبرة. تجدر الإشارة إلى أن كل
فحص بالأشعة المقطعية يأتي من مريض مختلف ، وبالتالي فإن عدد من الأشخاص
يساوون عدد المسوحات المقطعية.

هذه البيانات مقسمة إلى ثلاثة أجزاء تدريب ، اختبار و تحقق ، ال labels للصور
المقطعية معروفة من أجل بيانات التدريب والتحقق ولكن بيانات الاختبار غير معروفة .
تم الحصول على مجموعات التدريب والتحقق من 307 مسحاً بالأشعة المقطعية للصدر
(171 مريضاً إيجابياً لـ COVID-19 ، و 60 مصاباً بالتهاب رئوي مكتسب من
المجتمع (CAP) ، و 76 حالة طبيعية).

تم اختيار 30% من هذه الصور المقطعية بشكل عشوائي كمجموعة تحقق ،
واستخدمت 70% المتبقية كمجموعة تدريب.

تم الحصول على جميع فحوصات التصوير المقطعي المحوسب والتدريبات والتحقق من
الصحة بواسطة الماسح الضوئي SOMATOM Scope، SIEMENS بجرة إشعاع
عادية وسماكة شريحة 2 مم. على الإصابة. بالإضافة إلى مجموعتي التدريب والتحقق
هناك ثلاث مجموعات اختبار.


○ ثلاثون صورة مقطعية لـ COVID-19 و CAP وحالات عادية من
نفس المركز الذي تم الحصول منه على مجموعات التدريب / التحقق
من الصحة.

○ ثلاثون صورة مقطعية بجرعة منخفضة (LDCT) لـ COVID-19
والحالات العادية التي تم الحصول عليها بسمك شريحة 2 مم.

○ ثلاثون صورة أشعة مقطعية لـ COVID-19 و CAP وطبيعية مع
وجود تاريخ من أمراض القلب أو عملية يظهر فيها مظاهر غير
طبيعية وقد أخذت هذه المجموعة بسمك شريحة وجرعات إشعاع
مختلفة.

5. تهيئة البيانات والطريقة المتبعة للتصنيف:

5.1- التقطيع segmentation:



الشكل (6) يظهر تقطيع صور الرئة، العمود الأول يظهر الصورة الأصلية، العمود الثاني يظهر قناع الرئة، العمود الثالث يظهر نتيجة التقطيع. السطر الأول والثاني COVID-19 والسطر الثالث Cap.

5.2- التصنيف على مستوى الشريحة:

الهدف من هذه المرحلة هو ضبط نماذج CNN المُدرّبة مسبقاً لتصنيف شرائح التصوير المقطعي المحوسب إلى فئة عادية أو COVID-19 أو Cap. يعد التصنيف على مستوى الشريحة أهم مرحلة لأنها يمكن أن تؤثر على تنبؤ التصوير المقطعي المحوسب بالكامل. في مرحلة المعالجة المسبقة، نقرأ صور الشرائح من ملف ".dcm" الذي يعطي صورة بقناة واحدة (تدرج الرمادي). و لأن معظم معماريات CNN صُممت للصور الملونة، فإننا نقترح تكديس الصورة الرمادية والقناع و نتيجة التقطيع لتصبح

النتيجة صورة ثلاثية البعد مثل RGB. بالإضافة إلى وجود ثلاث قنوات كمدخلات لبنى CNN ، فإن التقسيم يوجه تصنيف الشرائح من خلال التركيز على ميزات فصوص الرئة وإزالة الميزات غير ذات الصلة. لتدريب التصنيف المستند إلى الشرائح ، لدينا 10294 و 2482 و 742 شريحة للفئات العادية و COVID-19 و Cap ، على التوالي. من عدد الشرائح لكل فئة ، نلاحظ أنها غير متوازنة. للتعامل مع هذه المشكلة، استخدمنا تقنيات زيادة البيانات لشرائح COVID-19 و Cap. بالنسبة لفئة COVID-19 ، قمنا بإنشاء 3 صور نتيجة زيادة البيانات من كل شريحة. من ناحية أخرى ، قمنا بإنشاء 10 صور لكل شريحة CAP. في المجموع ، حصلنا على 9928 و 8162 ل COVID-19 و Cap ، على التوالي.

✓ هنا قمنا باستخدام بنى CNN التالية : Resnet-50 و Densenet-161 و Inception-v3 (معماريات CNN الأساسية هي النماذج المدربة مسبقاً التي تم تدريبها على قاعدة بيانات تحدي ImageNet [33]). في بحثنا ، قمنا بتدريب جميع بنى CNN باستخدام استراتيجية متعددة المهام. بمزيد من التفصيل ، قمنا بضبط نماذج CNN المدربة مسبقاً ، حيث تم تهيئة طبقات FC فقط بشكل عشوائي باستخدام تهيئة توزيع موحدة. تتمثل مهمة التدريب متعدد المهام في تصنيف صورة الإدخال إلى : عادية و COVID-19 و Cap.

5.3- التصنيف على مستوى المريض:

نظراً لأن الصور المقطعية تحتوي على عدد مختلف من الشرائح ، فإننا نقترح تقسيم هذه الصور إلى 20 مجموعة حيث تحتوي كل مجموعة على نفس عدد الشرائح. بعد ذلك ، طبقنا البنى المدربة على مستوى الشرائح للتنبؤ بتسميات شرائح كل مجموعة . ثم نحسب النسبة المئوية للشرائح المتوقعة لكل فئة داخل المجموعة. ينتج عن ذلك $60 = 3 \times 20$ ميزة لكل صورة مقطعية باستخدام إحدى بنى CNN المدربة. لتصنيف صور التصوير المقطعي المحوسب ، نقوم بتغذية مجموعة من جميع ميزات بنية CNN المدربة ، ثم نستخدم مصنف XG-Boost .

6. النتائج:

6.1 - التصنيف على مستوى الشريحة:

نظرًا لأن الشريحة التي تمت قراءتها من ملف "dcm." عبارة عن صورة ذات تدرجات رمادية أحادية القناة وإدخال نماذج CNN سابقة التدريب (على ImageNet) يتضمن ثلاث قنوات (صور RGB) ، فقد قمنا بتكديس شريحة التدرج الرمادي للحصول على صورة تشبه RGB ، في هذه الورقة البحثية تم تدريب جميع بنى CNN بشكل كامل باستخدام transfer learning لمدة 20 epochs باستخدام مُحسَّن آدم [36]. معدل التعلم الأولي هو 0.0001 ، والذي ينقص بمقدار 0.1 بعد 10 epochs ، يليه تناقص آخر قدره 0.1 بعد 15 دوراً. يلخص الجدول 1 النتائج التي تم الحصول عليها. من هذه النتائج ، نلاحظ أن بنى CNN الأربعة حققت نتائج متماثلة مع نتائج أفضل قليلاً باستخدام بنية Densenet-161.

النموذج	دقة التصنيف على مستوى الشريحة
Resnet-50	80.6 %
Densenet-161	81.70 %
Inception-v3	81.62 %

الجدول -1- دقة تصنيف النماذج الأربعة على مستوى الشريحة

يحتوي الشكل 7 على confusion matrices الخاصة ببنى CNN على بيانات التحقق من الصحة. من هذه المصفوفات نلاحظ أن بنية Densenet-161 حققت أفضل أداء في التعرف على شرائح COVID-19 و Cap بدقة 65.87% و 56.19% على التوالي. أما بالنسبة للتعرف على الشرائح العادية حققت بنية Inception-v3 أفضل أداء بدقة بلغت 93.73%.

تشخيص الإصابة بفيروس كورونا بتحليل الصور المقطعية

True labels	Normal	3191 92.63%	157 4.56%	97 2.82%
	Covid-19	488 36.61%	830 62.27%	15 1.13%
	CAP	200 45.87%	44 10.09%	192 44.04%
		Normal	Covid-19 Predicted labels	CAP

True labels	Normal	3143 91.23%	211 6.12%	91 2.64%
	Covid-19	446 33.46%	878 65.87%	9 0.68%
	CAP	156 35.78%	35 8.03%	245 56.19%
		Normal	Covid-19 Predicted labels	CAP

True labels	Normal	3229 93.73%	147 4.27%	69 2.00%
	Covid-19	467 35.03%	849 63.69%	17 1.28%
	CAP	216 49.54%	34 7.80%	186 42.66%
		Normal	Covid-19 Predicted labels	CAP

الشكل (7) confusion matrices للبنى الثلاثة Densenet-50،

Inception-v3 و Resnet-161

6.2- التصنيف بعد تطبيق زيادة البيانات augmentation

في هذه التجربة ، اقترحنا زيادة صور الرئة المكسدة والمجزأة للحصول على قاعدة بيانات متوازنة. يلخص الجدول 2 النتائج التي تم الحصول عليها لبنى CNN باستخدام البيانات التي تمت زيادتها. من هذه النتائج ، نلاحظ أن بنية Inception-v3 حققت نتيجة أفضل قليلاً من بنى CNN الأخرى. بالمقارنة مع نتائج الجدول 1 نلاحظ أن أداء البنى قد تحسن.

النموذج	دقة التصنيف على مستوى الشريحة
Resnet-50	% 88.5
Densenet-161	% 88.40
Inseption-v3	% 88.62

الجدول -2- دقة تصنيف النماذج الأربعة بعد زيادة البيانات

يحتوي الشكل 8 على مصفوفات confusion الخاصة ببنى CNN (Resnet-50 و Densenet-161 و Inception-v3) على بيانات التحقق من الصحة. من هذه المصفوفات نلاحظ أن بنى Resnet-50 و Inception-v3 و Densenet-161 حققت أداء أفضل في التعرف على الشرائح الطبيعية (94.43%)، (84.32%) COVID-19 و Cap (68.81) %، على التوالي. في هذا السيناريو ، نلاحظ أن معدل التعرف على شرائح cap قد تحسن مقارنة بالتجربة السابقة. هذا يثبت كفاءة استخدام تقنيات زيادة البيانات.

تشخيص الإصابة بفيروس كورونا بتحليل الصور المقطعية

True labels	Normal	3253 94.43%	135 3.92%	57 1.65%
	Covid-19	212 15.90%	1104 82.82%	17 1.28%
	CAP	126 28.90%	52 11.93%	258 59.17%
		Normal	Covid-19 Predicted labels	CAP

True labels	Normal	3206 93.06%	170 4.93%	69 2.00%
	Covid-19	205 15.38%	1124 84.32%	4 0.30%
	CAP	81 18.58%	75 17.20%	280 64.22%
		Normal	Covid-19 Predicted labels	CAP

True labels	Normal	3217 93.38%	136 3.95%	92 2.67%
	Covid-19	217 16.28%	1105 82.90%	11 0.83%
	CAP	58 13.30%	78 17.89%	300 68.81%
		Normal	Covid-19 Predicted labels	CAP

الشكل (8) confusion matrices للبنى الثلاثة Densenet-50، Resnet-161 و Inception-v3

6.3- التصنيف على مستوى المريض

في هذا القسم ، استخدمنا بنى CNN المدربة السابقة للتصنيف على مستوى الشريحة.

بعد ذلك ، استخدمنا النسبة المئوية للتنبؤ بالفئات الثلاثة داخل مناطق الصور المقطعية (تقسم كل صورة مقطعية إلى 20 منطقة) لتدريب واختبار اثنين من المصنفات ، وهما SVM و XG-Boost ، لتصنيف الصور المقطعية. تم تلخيص النتائج التي تم الحصول عليها على بيانات التحقق من الصحة في الجدول 3. ومن هذه النتائج ، نلاحظ أن ميزات Inception-v3 مع مصنف XG-boost حققت أفضل أداء مقارنة بميزات البنى الأخرى. من ناحية أخرى ، فإن الجمع بين ميزات جميع النماذج الأربعة مع مصنف XG-Boost حقق أفضل أداء. هذا يثبت كفاءة استخدام المصنف XG-Boost لميزات البنى الفردية بالإضافة إلى الجمع بين جميع ميزات البنى.

النموذج	تصنيف الصور المقطعية	
	SVM	XG-Boost
Resnet-50	81.62	79.59
Densenet-161	82.63	82.63
Inseption-v3	82.65	85.70

الجدول 3 مقارنة نتيجة تصنيف SVM و XGBOOST باستخدام ميزات البنى الثلاثة .

7. مناقشة النتائج:

قمنا بتدريب ثلاثة بنى CNN هي :

Resnet-50, Densenet-161, Inception-v3 ، وباستخدام استراتيجيات زيادة البيانات والمهام المتعددة. كمدخلات لبنى CNN هذه ، قمنا بتكديس صورة شريحة التدرج الرمادي مع تجزئة فص الرئة. في المرحلة الثانية ، استخدمنا بنى CNN المدربة لاستخراج ميزات التصوير المقطعي بالكامل. لتقييم الأداء استخدمنا بيانات التحقق من الصحة لتحدي COVID-19 SPGC 2021 لكل من التقييمات على مستوى الشريحة ومستوى المريض. بالإضافة إلى ذلك ، تم استخدام مجموعات الاختبار الثلاث لتحدي COVID-19 SPGC 2021 للتقييم على مستوى المريض.

وقد حققت النماذج الثلاثة نتائج جيدة في التجربة الأولى قبل زيادة البيانات، ولكن عند زيادة البيانات وجعلها متوازنة ازدادت الدقة للنماذج الثلاثة وكانت الدقة كمايلي: Resnet-50 أعطت أداء أفضل في التعرف على الشرائح الطبيعية (94.43%) أما Inception-v3 أعطت أفضل أداء في التعرف على الشرائح المصابة بدقة (84.32) % و Densenet-161 أعطت أفضل نتيجة في التعرف على Cap بنسبة (68.81) % .

في المرحلة الأخيرة تمت مقارنة مصنفي SVM و XG-BOOST و وجدنا أن XG-BOOST أعطى النتيجة الأفضل في التصنيف مع ميزات Inception-v3. لتحسين النتائج ، خاصة بالنسبة لفئة Cap ، نقترح استخدام المزيد من فحوصات Cap CT لتصنيف مستوى الشريحة ومستوى المريض.

المراجع:

- [1] Wang C, Horby PW, Hayden FG, Gao GF , "A novel coronavirus outbreak of global health concern", Lancet 395(10223):470,2020
- [2] Wang LS, Wang YR, Ye DW, Liu QQ , "A review of the 2019 novel coronavirus (covid-19) based on current evidence", International journal of antimicrobial agents, 105948,2020.
- [3] Singhal T , "A review of coronavirus disease-2019 (covid-19)", The Indian Journal of Pediatrics, 1-6,2020
- [4] Wang R, Pan M, Zhang X, Han M, Fan X, Zhao F, Miao M, Xu J, Guan M, Deng X et al," Epidemiological and clinical features of 125 hospitalized patients with covid-19 in Fuyang", Anhui, China, Int J Infect Dis 95:421,2020
- [5] Li B, Yang J, Zhao F, Zhi L, Wang X, Liu L, Bi Z, Zhao Y , "Prevalence and impact of cardiovascular metabolic diseases on covid-19 in China", Clin Res Cardiol 109(5):531,2020.
- [6] Singh D, Kumar V, Kaur M , "Classification of covid-19 patients from chest ct images using multi-objective differential evolution based convolutional neural networks", European Journal of Clinical Microbiology & Infectious Diseases, 1-11,2020.

- [7] Anjishnu Das SK ,"Why covid testing is a slow process and types of tests available",2020.
- [8] Shen D, Wu G, Suk HI ,"Deep learning in medical image Analysis", Ann Rev Biomed Eng 19:221",2017.
- [9] Ker J, Wang L, Rao J, Lim T ,"Deep learning applications in medical image analysis", Ieee Access 6:9375,2017
- [10] Grewal M, Srivastava MM, Kumar P, "Radiologist level accuracy using deep learning for hemorrhage detection in ct scans. In: IEEE 15th International symposium on biomedical imaging (ISBI 2018)", IEEE, pp 281–284,2018.
- [11] Song Q, Zhao L, Luo X, Dou X ,"Using deep learning for classification of lung nodules on computed tomography images", Journal of healthcare engineering, 2017
- [12] Gonz´alez G, Ash SY, Vegas–S´anchez–Ferrero G, Onieva,"Disease staging and prognosis in smokers using deep learning in chest computed tomography", Am J Respir Crit Care Med 197(2):193,2017.
- [13] Bernheim A, Mei X, Huang M, Yang Y, Fayad ZA, Zhang N, Diao K, ,"Chest CT findings in coronavirus disease–19 (covid–19): relationship to duration of infection", Radiology, 200463,2017

[14] Gozes O, Frid-Adar M, Greenspan H, Browning PD, Zhang H, JiW, Bernheim A, Siegel E, "Rapid ai development cycle for the coronavirus (covid-19) pandemic: initial results for automated detection & patient monitoring using deep learning ct image analysis", arXiv:2003.05037,2020

[15] Zheng C, Deng X, Fu Q, Zhou Q, Feng J, Ma H, Liu W, Wang X, "Deep learning-based detection for covid-19 from chest CT using weak label", medRxiv,2020

[16] Fang Y, Zhang H, Xie J, Lin M, Ying L, Pang P, Ji W, "Sensitivity of chest CT for covid-19: comparison to RT-PCR" Radiology ,2020.

[17] Kaiming He, Xiangyu Zhang, Jian Sun, "Deep Residual Learning for Image Recognition",2015.

[18] R. K. Srivastava, K. Greff, and J. Schmidhuber, "Training very deep networks", 1507.06228, 2015.

[19] Y. LeCun, B. Boser, J. S. Denker, D. Henderson, R. E. Howard, W. Hubbard, "applied to handwritten zip code recognition" Neural computation,1(4):541-551, 1989

- [20] G. Huang, Y. Sun, Z. Liu, D. Sedra, "Deep networks with stochastic depth", In ECCV, 2016.
- [21] Q. Liao and T. Poggio, "Bridging the gaps between residual learning, recurrent neural networks and visual cortex", arXiv preprint arXiv, 2016.
- [22] Gao Huang, Zhuang Liu," Densely Connected Convolutional Networks",2018.
- [23] Sik-Ho Tsang, "Inception-v3 1st Runner Up (Image Classification) in ILSVRC 2015" ,2018.