



الجمهورية العربية السورية
وزارة التعليم العالي والبحث العلمي
جامعة دمشق
كلية الهندسة الميكانيكية والكهربائية
قسم هندسة الإلكترونيات والاتصالات

تطوير خوارزمية تصنيف الصور الرقمية عالية التمييزية

رسالة مقدمة لنيل درجة الماجستير في هندسة الإلكترونيات التطبيقية

إعداد

م. ايمان قابل

إشراف

د.م. طلال حمود

أستاذ مساعد في قسم هندسة الإلكترونيات والاتصالات

2022-2021

أعضاء لجنة الحكم والقرار الناظم بذلك

أقدم أسمى الشكر والامتنان والمحبة لأعضاء لجنة الحكم الموقرة لقبولهم قراءة خلاصة بحثي والحكم على رسالتي:

عضواً ومشرفاً علمياً

الدكتور طلال حمود

عضواً

الدكتور رؤوف حمدان

عضواً

الدكتور محمد ميهوب

بموجب قرار مجلس البحث العلمي والدراسات العليا رقم /3968/ م.ب.د تاريخ 2022/8/15 والقاضي بتأليف لجنة الحكم

د.محمد ميهوب

د.رؤوف حمدان

د.طلال حمود

تصريح خطي

أنا الموقعة أدناه أصرح بعلمي الكامل وقبولي:

1. أنّ كل ما ينتج عن البحث والرسالة هو ملكية فكرية ومالية بالتشارك مع جامعة دمشق، وأنا ألتزم بأخذ موافقة الجامعة في حال رغبتني في نشر البحث أو الرسالة أو جزء منها نصاً أو مضموناً خارج إطار الجامعة (من دور نشر أو مكنتبات أو مواقع إلكترونية وغيرها من وسائل النشر).

2. أنه لا يوجد أي جزء من هذه الرسالة تم اقتباسه من عمل علمي آخر أو أنجز للحصول على شهادة أخرى في جامعة دمشق أو أية جامعة أو معهد تعليمي داخل الجمهورية العربية السورية أو خارجها.

الاسم والتوقيع

كلمة شكر وتقدير

لا يسعني وأنا في المراحل الأخيرة من إنجاز هذه الرسالة، إلا أن أتقدم بالشكر الجزيل إلى الدكتور طلال حمود، المشرف العلمي على الرسالة، والذي تفانى معي بكل تواضع، وصبر، وصدق، ودقة، وأمانة علمية، لإتمام هذه الرسالة، من خلال ما قدمه لي من ملاحظات وتوجيهات قيمة، ومتابعة مستمرة.

وكذلك الشكر إلى قسم هندسة الإلكترونيات والاتصالات وجميع كادره التدريسي والفني. وأخيراً أتقدم بخالص شكري وعظيم امتناني لعائلتي وأصدقائي، وكل من مد لي يد العون والمساعدة لإتمام هذه الرسالة.

فهرس المحتويات

رقم الصفحة	العنوان
I	أعضاء لجنة الحكم والقرار الناظم بذلك
II	تصريح خطي
III	كلمة شكر وتقدير
IV	فهرس المحتويات
VIII	فهرس الأشكال التوضيحية
X	فهرس الجداول
XI	قائمة المصطلحات والاختصارات
XII	المستخلص
XIII	ABSTRACT
1	الفصل الأول: الإطار العام للبحث Research General Framework
2	1.1. المقدمة
3	2.1. بعض الدراسات السابقة
9	1.2.1. خلاصة الدراسات السابقة
9	2.2.1. الجديد في الدراسة الحالية
9	3.1. مشكلة البحث
10	4.1. هدف البحث
10	5.1. أهمية البحث ومسوغاته
11	6.1. محددات البحث
11	7.1. حدود البحث
11	8.1. منهج البحث وأدواته
12	9.1. بنية الرسالة
13	الفصل الثاني: التصوير المقطعي المحوسب Computed Tomography
14	1.2. تمهيد
14	2.2. مبدأ التصوير المقطعي (الطبقي) المحوسب
17	3.2. قياسات التصوير المقطعي (Quantitative CT)
18	4.2. الصور الرقمية

21	5.2. الصور الطبية الرقمية
22	1.5.2. الصور المقطعية المحوسبة CT
24	الفصل الثالث: آليات استخراج الميزات Features Extraction
25	1.3. تمهيد
25	2.3. ميزات الشكل Shape Features
25	3.3. ميزات الكثافة Intensity Features
27	4.3. ميزات التراكيب Texture Features
27	1.4.3. مصفوفة الحدود المشترك للمستوى الرمادي (GLCM)
29	2.4.3. خوارزمية النمط الثنائي المحلي (LBP)
29	3.4.3. مصفوفة الحدود الثنائي للمستوى الرمادي المحلي (LBGLCM)
30	4.4.3. مصفوفة طول التشغيل للمستوى الرمادي (GLRLM)
31	الفصل الرابع: التصنيف Classification
32	1.4. تمهيد
32	2.4. طرق التصنيف
32	1.2.4. التصنيف الخاضع للإشراف Supervised Classification
32	2.2.4. التصنيف غير الخاضع للإشراف Unsupervised Classification
33	3.4. خوارزميات التصنيف
33	1.3.4. خوارزمية آلة شعاع الدعم (SVM)
34	2.3.4. خوارزمية أقرب الجيران (KNN)
35	3.3.4. خوارزمية K-Means Clustering
36	4.3.4. الشبكات العصبونية التلافيفية (CNN)
40	1.4.3.4. شبكة AlexNet
41	2.4.3.4. شبكة VGG
41	3.4.3.4. شبكة GoogLeNet
42	4.4.3.4. شبكة DenseNet
43	5.4.3.4. شبكة ResNet
46	الفصل الخامس: تدريب الشبكات العصبونية Neural Network Training
47	1.5. تمهيد
47	2.5. التدريب الخاضع للإشراف

48	3.5. التدريب غير الخاضع للإشراف
48	4.5. مرحلة الانتشار الأمامي Forward Propagation
49	5.5. مرحلة الانتشار العكسي Backward Propagation
50	6.5. المعاملات الفائقة Hyperparameters
50	1.6.5. معدل التعلم Learning Rate
51	2.6.5. الحقبات Epochs
52	3.6.5. الدفعة Batch
53	4.6.5. المحسنات Optimizers
53	1.4.6.5. خوارزمية الانحدار المتدرج الدفعي Batch Gradient Decent(BGD)
54	2.4.6.5. خوارزمية الانحدار المتدرج العشوائي Stochastic Gradient Decent(SGD)
54	3.4.6.5. خوارزمية انحدار الدفعات الصغيرة المتدرجة Mini-Batch Gradient Decent(M-BGD)
55	4.4.6.5. خوارزمية الانحدار المتدرج مع الزخم Gradient Decent with Momentum
55	5.4.6.5. خوارزمية Nesterov Accelerated Gradient(NAG)
56	6.4.6.5. خوارزمية Adagrad
56	7.4.6.5. خوارزمية Adadelta
57	8.4.6.5. خوارزمية RMSprop
57	9.4.6.5. خوارزمية Adam
60	الفصل السادس: منهجية البحث وإجراءاته Research Methodology And Procedures
61	1.6. تمهيد
61	2.6. البيانات المستخدمة في البحث
61	1.2.6. قاعدة البيانات 1
63	2.2.6. قاعدة البيانات 2
64	3.2.6. قاعدة البيانات 3
66	4.2.6. تقسيم البيانات
67	3.6. الخوارزمية المقترحة
68	4.6. تقليل الإفراط في التعلم Overfitting
68	1.4.6. التسرب Dropout
69	2.4.6. نقل التعلم Transfer Learning
70	3.4.6. زيادة البيانات Data Augmentation
71	5.6. المعاملات الفائقة Hyperparameters

72	6.6. مقاييس أداء خوارزمية التصنيف
72	1.6.6. مصفوفة الارتباك Confusion Matrix
74	1.1.6.6. الحساسية (SEN)
74	2.1.6.6. الخصوصية (SPE)
75	3.1.6.6. الإحكام (PRE)
75	4.1.6.6. الدقة (ACC)
75	5.1.6.6. F-score
75	2.6.6. منحنى (ROC)
77	3.6.6. المساحة الواقعة تحت منحنى ROC (AUC)
78	7.6. البرنامج المستخدم في البحث
79	الفصل السابع: النتائج والمناقشة Results And Discussion
80	1.7. تمهيد
80	2.7. نتائج تدريب الخوارزمية المقترحة على قاعدة البيانات 1
81	1.2.7. مصفوفة الارتباك
83	2.2.7. منحنى خصائص التشغيل (ROC)
83	3.7. نتائج تدريب الخوارزمية المقترحة على قاعدة البيانات 2
85	1.3.7. مصفوفة الارتباك
86	2.3.7. منحنى خصائص التشغيل (ROC)
86	4.7. نتائج تدريب الخوارزمية المقترحة على قاعدة البيانات 3
88	1.4.7. مصفوفة الارتباك
89	2.4.7. منحنى خصائص التشغيل (ROC)
89	5.7. تقييم أداء الخوارزمية المقترحة
92	خاتمة البحث
93	التوصيات والمقترحات
94	المراجع

فهرس الأشكال التوضيحية

الصفحة	الشكل
14	الشكل (1-2) مبدأ عمل جهاز التصوير الطبقي المحوري (الجيل الخامس)
15	الشكل (2-2) مساقط مختلفة للتصوير المقطعي للصدر (Chest CT Scan)
16	الشكل (3-2) تناقص زمن التصوير للشريحة الواحدة مع تطور أجهزة التصوير CT
19	الشكل (4-2) آلية تحويل صورة مستمرة باستخدام نظام تصوير معين imaging system إلى صورة رقمية
19	الشكل (5-2) عناصر الصورة الرقمية الناتجة ممثلة في الإحداثيات الديكارتية
23	الشكل (6-2) مقارنة بين صور CT لمرضى كوفيد19 وأشخاص سليمين
29	الشكل (1-3) خوارزمية النمط الثنائي المحلي LBP
34	الشكل (1-4) التصنيف باستخدام SVM
35	الشكل (2-4) آلية عمل خوارزمية KNN
36	الشكل (3-4) بنية الشبكات العصبونية التلافيفية
37	الشكل (4-4) عملية الالتفاف
37	الشكل (5-4) تابع RELU
38	الشكل (6-4) التجميع الأقصى
39	الشكل (7-4) تمثيل لعملية التسطيح
39	الشكل (8-4) الطبقة المتصلة بالكامل
40	الشكل (9-4) هيكلية شبكة AlexNet
41	الشكل (10-4) هيكلية شبكة (VGG16)
42	الشكل (11-4) هيكلية شبكة GoogLeNet
42	الشكل (12-4) كتلة كثيفة نموذجية ذات 5 طبقات
44	الشكل (13-4) اتصال الهوية
50	الشكل (1-5) تأثير الحالات المختلفة لمعدل التعلم على التقليل من تابع الخسارة
55	الشكل (2-5) تأثير الزخم على خوارزمية SGD
58	الشكل (3-5) تدريب الشبكات العصبونية متعددة الطبقات على قاعدة البيانات MNIST
59	الشكل (4-5) تكلفة تدريب (TRAINING COST) للشبكات العصبونية التلافيفية CONVNET باستخدام قاعدة البيانات CIFAR-10
62	الشكل (1-6) صور مقطعية إيجابية لـ COVID19 مأخوذة من قاعدة البيانات 1
62	الشكل (2-6) صور مقطعية سلبية لـ COVID19 مأخوذة من قاعدة البيانات 1

63	الشكل (3-6) صور مقطعية إيجابية لـ COVID19 مأخوذة من قاعدة البيانات 2
64	الشكل (4-6) صور مقطعية سلبية لـ COVID19 مأخوذة من قاعدة البيانات 2
65	الشكل (5-6) أمثلة لصور CT لأشخاص سليمين ومصابين مأخوذة من قاعدة البيانات 3
67	الشكل (6-6) هيكلية الخوارزمية المقترحة
69	الشكل (7-6) تقنية التسرب
70	الشكل (8-6) تقنية زيادة البيانات
73	الشكل (9-6) مصفوفة الارتباك
76	الشكل (10-6) منحنى ROC
80	الشكل (1-7) منحنى الخسارة لمرحلة التدريب والاختبار لقاعدة البيانات 1
81	الشكل (2-7) منحنى الدقة لمرحلة التدريب والاختبار لقاعدة البيانات 1
82	الشكل (3-7) مصفوفة الارتباك لمجموعة الاختبار لقاعدة البيانات 1
83	الشكل (4-7) منحنى ROC لبيانات الاختبار لقاعدة البيانات 1
84	الشكل (5-7) منحنى الخسارة لمرحلة التدريب والاختبار لقاعدة البيانات 2
84	الشكل (6-7) منحنى الدقة لمرحلة التدريب والاختبار لقاعدة البيانات 2
85	الشكل (7-7) مصفوفة الارتباك لمجموعة الاختبار لقاعدة البيانات 2
86	الشكل (8-7) منحنى ROC لبيانات الاختبار لقاعدة البيانات 2
87	الشكل (9-7) منحنى الخسارة لمرحلة التدريب والاختبار لقاعدة البيانات 3
87	الشكل (10-7) منحنى الدقة لمرحلة التدريب والاختبار لقاعدة البيانات 3
88	الشكل (11-7) مصفوفة الارتباك لمجموعة الاختبار لقاعدة البيانات 3
89	الشكل (12-7) منحنى ROC لبيانات الاختبار لقاعدة البيانات 3

فهرس الجداول

الصفحة	الجدول
7	الجدول (1-1) ملخص الأبحاث العلمية للكشف عن COVID-19 بأحدث الطرق المختلفة
17	الجدول (1-2) معامل التخاذد لبعض الأنسجة المختلفة
45	الجدول (1-4) طبقات النماذج المختلفة للشبكات المتبقية
66	الجدول (1-6) إحصائيات تقسيم البيانات
71	الجدول (2-6) المعاملات الفائقة للخوارزمية المقترحة
77	الجدول (3-6) القاعدة الأساسية لتفسير قيمة AUC
82	الجدول (1-7) مقاييس أداء خوارزمية التصنيف لقاعدة البيانات 1
86	الجدول (2-7) مقاييس أداء خوارزمية التصنيف لقاعدة البيانات 2
89	الجدول (3-7) مقاييس أداء خوارزمية التصنيف لقاعدة البيانات 3
90	الجدول (4-7) مقارنة الخوارزمية المقترحة مع الدراسات السابقة التي استخدمت قاعدة البيانات (COVID-CT dataset)
91	الجدول (5-7) مقارنة الخوارزمية المقترحة مع الدراسات السابقة التي استخدمت قاعدة البيانات (SARS-CoV-2 CT-scan dataset)

قائمة المصطلحات والاختصارات

الاختصار	مقابله باللغة الإنكليزية	المصطلح باللغة العربية
ACC	Accuracy	الدقة
ADAM	Adaptive Moment Estimation	تقدير اللحظة التكيفية
AUC	Area Under Curve	المساحة الواقعة تحت المنحنى
ANNs	Artificial Neural Networks	الشبكات العصبونية الاصطناعية
CNN	Convolutional Neural Network	الشبكات العصبونية التلافيفية
GLCM	Gray Level Co-occurrence Matrix	مصفوفة الحدوث المشترك للمستوى الرمادي
GLRLM	Gray Level Run Length Matrix	مصفوفة طول التشغيل للمستوى الرمادي
KNN	K-nearest Neighbors	أقرب الجيران
LBGLCM	Local Binary Gray Level Co-occurrence Matrix	مصفوفة الحدوث الثنائي للمستوى الرمادي المحلي
LBP	Local Binary Pattern	النمط الثنائي المحلي
PRE	Precision	الإحكام
ROC	Receiver Operating Characteristic curve	منحنى خصائص تشغيل جهاز الاستقبال
RELU	Rectified Linear Unit	الوحدة الخطية المصححة
ResNet	Residual Network	الشبكات المتبقية
SEN	Sensitivity	الحساسية
SPE	Specificity	الخصوصية
SVM	Support Vector Machine	آلة شعاع الدعم
TNR	True Negative Rate	المعدل السالب الحقيقي
TPR	True Positive Rate	المعدل الموجب الحقيقي

المستخلص

خلفية البحث:

تمتلك الصور الرقمية عالية التمييزية مثل صور الأقمار الصناعية والصور الطبية دوراً مهماً في العديد من التطبيقات التي تمتلك تفاصيل دقيقة، فهي تستخدم في رسم الخرائط كما في حالة صور الأقمار الصناعية أو تشخيص الأمراض اعتماداً على الصور الطبية، وهذا ما يتطلب استخدام مصنفات بدقة عالية للحصول على نتائج دقيقة خلال زمن قصير.

هدف البحث:

يهدف هذا البحث إلى بناء خوارزمية تصنيف باستخدام الشبكات العصبونية المتبقية من أجل تصنيف صور الأشعة المقطعية المحوسبة CT إلى فئتين: إما مصاب بفيروس كوفيد19 أو سليم.

المواد والطرائق:

لإنجاز البحث تم الاعتماد على ثلاث قواعد بيانات لتدريب المصنف واختباره. تم الحصول على قاعدة البيانات الأولى والثانية من مستودعي GitHub وKaggle. وقاعدة البيانات الثالثة تم الحصول عليها من مشفى المواساة بدمشق. وتم استخدام لغة برمجة بايثون لتنفيذ الخوارزمية المقترحة وتقييمها في البحث. واستخدم خدمة Google Colab السحابية استناداً إلى Jupiter's Notebooks.

النتائج العملية:

لأجل تقييم أداء خوارزمية التصنيف المقترحة في البحث، تم حساب بعض المقاييس الشائعة اعتماداً على مصفوفة الارتباك (Confusion Matrix)، وهي الدقة والحساسية والخصوصية والإحكام و F-score. حيث بلغت الدقة والحساسية والخصوصية والإحكام و F-score، 98.66%، 97.18%، 100%، 100%، 98.57% على الترتيب من أجل قاعدة البيانات الأولى و 99.19%، 98.71%، 99.62%، 99.56%، 99.13% على الترتيب من أجل قاعدة البيانات الثانية. و 99.07%، 98.33%، 100%، 100%، 99.15% على الترتيب من أجل قاعدة البيانات الثالثة.

الاستنتاجات من وجهة نظر الباحث:

أظهرت النتائج دقة النظام المقترح وموثوقيته، وبالتالي فإن خوارزمية التصنيف المقترحة تتيح دقة عالية في تشخيص فيروس COVID-19.

الكلمات المفتاحية:

الصور المقطعية المحوسبة، كوفيد19، تصنيف الصور، الشبكات المتبقية، مصفوفة الارتباك.

ABSTRACT

Research Background:

Highly discriminatory digital images, such as satellite images and medical images, have an important role in many applications that have fine details. They are used in mapping, as in the case of satellite images, or diagnosing diseases based on medical images, and this requires the use of high-accuracy classifiers to obtain Accurate results in a short time.

Thesis Aim:

This thesis aims to build a classification algorithm using residual neural networks in order to classify CT scan images into two categories: either infected with COVID-19 virus or healthy.

Materials and Methods:

To accomplish the research, three databases were used to train and test the classifier. The first and second databases were obtained from GitHub and Kaggle repositories, and the third database was obtained from Al-Mowasat Hospital in Damascus. The Python programming language was used to implement the proposed algorithm and evaluated in the research. It used Google Colab cloud service based on Jupiter's Notebooks.

Results and Conclusion:

In order to evaluate the performance of the proposed classification algorithm in the research, some common metrics were calculated based on the Confusion Matrix, which are accuracy, sensitivity, specificity, precision and F-score.

The accuracy, sensitivity, specificity, precision, and F-score were 98.66%, 97.18%, 100%, 100%, 98.57%, respectively, for the first database and 99.19%, 98.71%, 99.62%, 99.56%, and 99.13%, respectively, for the second database and 99.07%, 98.33%, 100%, 100%, 99.15%, respectively, for the third database.

Recommendations:

The results showed the accuracy and reliability of the proposed system, so the proposed classification algorithm enables high accuracy in diagnosing COVID-19 virus.

Key words:

Computed Tomography Image, Covid19, Image Classification, Residual Network, Confusion Matrix.

الفصل الأول

الإطار العام للبحث

Research General Framework

1.1 المقدمة:

نظراً لتطور تقنيات معالجة الصور الرقمية عالية التمييزية وخصوصاً الصور الطبية، بدأ تطوير أدوات التشخيص والتنبؤ الذكي في الظهور بوتيرة سريعة[1]. يمكن استخدام أساليب التعلم الآلي كأداة مفيدة لتحسين التشخيص والتنبؤ بالعديد من الأمراض، لذلك استُخدمت نماذج التعلم العميق على نطاق واسع في أنظمة التصوير الطبي نظراً لقدرتها على استخراج الميزات تلقائياً واستخدام نماذج مدربة مسبقاً مثل الشبكات العصبونية[2].

منذ بدء انتشار الفيروس التاجي الجديد كوفيد 19 (COVID-19)، كانت هناك جهود متزايدة لتطوير طرائق التعلم العميق لإجراء فحص COVID-19 استناداً إلى الصور الطبية مثل الصور المقطعية المحوسبة CT وصور الأشعة السينية للصدر[3]، إذ تظهر صور الأشعة المقطعية للأفراد المصابين بـ COVID-19 خصائص مميزة مثل عتامة الزجاج الأرضي (Ground-Glass Opacities) وهي بقع بيضاء ضبابية في الرئتين، وهي العلامة الأساسية لـ COVID-19[4].

وبالتالي يمكن إنجاز خوارزميات تصنيف تحقق تشخيص عالي الدقة لكوفيد 19 بالاعتماد على الصور المقطعية المحوسبة CT، بحيث يكون هذا التشخيص مساعداً للطبيب ومختصراً للوقت والجهد اللذين تتطلبهما عملية فحص الكميات الكبيرة من الصور الطبية.

في دراسة حديثة [5] مع 1014 مريضاً، كانت تقنية التعلم العميق قادرة على توقع 888 حالة إيجابية باستخدام صور الأشعة المقطعية لمرضى كوفيد 19 المشتبه بهم، في حين كان اختبار RT-PCR قادراً فقط على التنبؤ بـ 601 حالة إيجابية للمرضى المشتبه بإصابتهم بفيروس COVID-19. أظهرت النتائج أن صور الأشعة المقطعية كانت قادرة على تشخيص COVID-19 بشكل فعال وبالتالي إنقاذ المزيد من الأرواح.

اقترح في هذا البحث خوارزمية تصنيف باستخدام الشبكات العصبونية المتبقية لتصنيف صور CT إلى صور تحتوي على فيروس COVID-19 أو صور سليمة. وتم التغلب على ظاهرة الإفراط في التعلم الناتجة عن محدودية البيانات المستخدمة باستخدام تقنيات التسرب ونقل التعلم وزيادة البيانات. واختُبرت الخوارزمية المقترحة على ثلاث قواعد بيانات من الصور المقطعية المحوسبة CT، قاعدة البيانات 1 هي COVID-CT dataset وقاعدة البيانات 2 هي SARS-CoV-2 CT-scan dataset وقاعدة البيانات 3 هي Mwasa dataset التي تم الحصول عليها من مشفى المواساة بدمشق.

2.1 بعض الدراسات السابقة:

عندما ظهر COVID-19 لأول مرة، كان التحدي الرئيسي هو الافتقار إلى مجموعات البيانات لاختبار نماذج التعلم العميق وبنائها. استُخدمت مجموعة بيانات خاصة بواسطة (Xu, X.; et al.,2020)، حيث تم جمع 618 صورة مقطعية محوسبة CT، واستخدموا طريقة جديدة يمكنها تشخيص COVID-19 تلقائيًا بالكامل من خلال تقنيات التعلم العميق محققة دقة 86.7% [6].

نشر (Zhao, J.; et al.,2020) مجموعة بيانات عامة (COVID-CT dataset). حيث أكد أخصائي الأشعة الذي كان يعالج المرضى المصابين وبشخص إصابتهم منذ بداية هذا الوباء قيمة مجموعة البيانات الخاصة بهم. واعتمدوا على تقنيات التعلم تحت الإشراف الذاتي (Self-Supervised Learning) والتعلم متعدد المهام (Multi-Task Learning) لتشخيص COVID-19 وبلغت دقة نموذجهم 83% [7].

في أعقاب نشر صور الأشعة السينية والأشعة المقطعية للصدر، ركز الباحثون جهودهم على تطوير نماذج التعلم العميق بمتوسط وقت تصنيف منخفض ودقة عالية.

قدم (Loey, M.; et al.,2020) شبكات CGAN مع تقنيات زيادة البيانات الكلاسيكية القائمة على التعلم العميق، حيث ساعد استخدام زيادة البيانات الكلاسيكية و CGAN في زيادة مجموعة بيانات CT وحل مشكلة الإفراط في التعلم (Overfitting).

اختاروا خمسة نماذج مختلفة لشبكة CNN هي: AlexNet، ResNet50، VGGNet19، VGGNet16، GoogleNet. واستخدموا قاعدة البيانات (COVID-CT dataset). أظهرت نتائجهم التجريبية أن ResNet50 تفوق على النماذج العميقة الأربعة الأخرى في اكتشاف COVID-19 من مجموعة بيانات CT وحققوا دقة تصل إلى 82.91% [8].

التحدي الآخر هو استخراج ميزات من الصور المقطعية المحوسبة للصدر للكشف عن كوفيد19، حيث اقترحت طريقة اختيار ميزات هجينة جديدة بواسطة (Shaban, W.; et al.,2020) والتي تجمع بين طرق اختيار ميزات الغلاف والتصفية. استُخدمت تقريباً جميع نماذج التعلم العميق لاستخراج الميزات واستخدموا قاعدة البيانات (COVID-CT dataset)، وحققوا دقة 96% [9].

في بحث (Auliasari, K.; et al.,2021)، استُخرجت الميزات المورفولوجية والميزات التركيبية من الدرجة الأولى والدرجة الثانية GLCM، وصُنّفت بعد ذلك بواسطة طريقة التصنيف K-Means. وتبين أن أعلى قيمة دقة هي 50% لاستخراج الميزات التركيبية من الدرجة الأولى، في حين أن دقة استخراج الميزات المورفولوجية وميزات GLCM هي 49.23% و 47.69% على الترتيب [10].

في دراسة (Öztürk, Ş.; et al.,2020)، صُنّفت الصور إلى ست حالات بما في ذلك صور فيروس كورونا. استُخرجت ميزات قوية من جميع الصور باستخدام أربع تقنيات مختلفة لاستخراج الميزات هي:

(GLCM , GLRLM , LBGLCM , SFTA). واستُخدمت طريقة SVM لتصنيف الميزات التي تم الحصول عليها. وتتضمن مجموعة البيانات 4 صور ARds، و 101 صورة COVID، و 2 صور التهاب

رئوي، و 11 صورة سارس، و 6 صور للمكورات العنقودية، و 2 صور لم تُحدّد حالتها، وبلغت دقة النموذج 94.23% [11].

استخدم (He, Xuai.; et al.,2020) نهج التعلم تحت الإشراف الذاتي (Self-supervised learning) مع تقنية نقل التعلم وشبكة DenseNet-121. واستخدم مجموعة بيانات (COVID-CT dataset) وحصل على دقة 86% [12].

في حين استخدم (Alshazly, H.; et al.,2021) بنى CNN العميقة (DenseNet , ResNet) للكشف عن COVID-19 بدقة بلغت 93.96% [13].

أعطى بحث (Perumal,V.; et al.,2021) التحليل الشعاعي للصور المقطعية معدل تنبؤ أعلى مقارنة بتقنية RT-PCR، واستُخدمت نماذج التعلم الهجين (hybrid learning). وتبيّن أن النموذج المقترح يتفوق بدقة 96.69% [14].

صنف نموذج (Shah, V.; et al.,2021) الصور المقطعية المحوسبة على أنها COVID-19 أو سليمة باستخدام شبكة VGG-19 واستخدموا مجموعة بيانات (COVID-CT dataset)، وبلغت دقة نموذجهم 94.52% [15].

في بحث (Song, Y.; et al.,2021) استُخدمت الشبكة العصبونية DRENet التي بُنيت على أساس التدريب المسبق لشبكة ResNet50، وبلغت دقة النموذج 94% [16].

يستخدم (Naeem, H.; et al.,2021) الذاكرة طويلة المدى (LSTM) على طول شبكة CNN للكشف عن ميزات COVID-19 المستخرجة. تظهر النتائج أن النهج المقترح حصل على دقة 98.94% باستخدام مجموعة بيانات (SARS-CoV-2 CT-scan dataset) [17].

قدم (Wang, Z.; et al.,2020) استراتيجية تعلم مشتركة لتحديد COVID-19 التي تتعلم بكفاءة باستخدام مجموعات البيانات غير المتجانسة من مصادر البيانات المختلفة. وقاموا بإجراء تطبيع منفصل للميزات في مساحة كامنة لتقليل عدم تجانس البيانات.

وبلغت دقة نموذجهم 78.69% من أجل قاعدة البيانات (COVID-CT dataset) و 90.83% من أجل قاعدة البيانات (SARS-CoV-2 CT-scan dataset) [18].

اقترح (Jangam,E.,et al.,2021) مجموعة مكدسة تتضمن أربع شبكات CNN مدربة مسبقاً وهي (VGG19، ResNet101، DenseNet169، WideResNet50-2) لاكتشاف كوفيد19. حصل النموذج المقترح على دقة 94% باستخدام مجموعة بيانات (SARS-CoV-2 CT-scan dataset) ودقة 85% باستخدام مجموعة بيانات (COVID-CT dataset) [19].

قام (Mouhafid,M., et al.,2022) بدمج ثلاثة نماذج للتعلم العميق (VGG-19، والشبكة المتبقية ResNet-50، والشبكة التلافيفية ذات الاتصال الكثيف DenseNet-201)، واتبع مبدأ أن الأداء يكون أفضل مع مجموعة من المصنفات المختلفة من المصنفات الفردية. علاوة على ذلك، حُلّت مشكلة بيانات التدريب غير الكافية باستخدام تقنية زيادة البيانات. حصل النموذج المقترح على دقة 98.59% باستخدام مجموعة بيانات (SARS- CoV-2 CT-scan dataset) ودقة 95.05% باستخدام مجموعة بيانات (COVID-CT dataset) [20].

يلخص الجدول (1-1) الأساليب المذكورة أعلاه مع طرائق التصنيف المستخدمة والدقة (ACC) والحساسية (SEN) والإحكام (PRE) والخصوصية (SPE) و (F-score) لكل دراسة.

الجدول (1-1): ملخص الأبحاث العلمية للكشف عن COVID-19 بأحدث الطرق المختلفة

المرجع	الطريقة (Method)	قاعدة البيانات	ACC	SEN	PRE	SPE	F-score
Xu et al (2020)[6]	نموذج التعلم العميق ثلاثي الأبعاد	618 CT 219 COVID 175 Healthy 224 Influenza-A viral pneumonia	%86.7	-	-	-	-
Zhao et al (2020)[7]	التعلم متعدد المهام و التعلم تحت الإشراف الذاتي	COVID-CT dataset	%83	-	-	-	%85
Loey et al (2020)[8]	شبكة ResNet50	COVID-CT dataset	%82.91	%77.66	-	%87.62	-
Shaban et al (2020)[9]	اختيار ميزات هجينة	COVID-CT dataset	%96	%74	%75	-	%75
Auliasari et al (2021)[10]	استُخرجت الميزات المورفولوجية والميزات التركيبية من الدرجة الأولى والدرجة الثانية GLCM، وصُنفت بواسطة طريقة K-Means	130 CT 75 COVID-19 55 non-COVID	%50	%50	%50	%50	-
Öztürk et al (2020)[11]	استُخدمت أربع تقنيات مختلفة لاستخراج الميزات هي: (GLCM , GLRLM , LBGLCM , SFTA) واستُخدمت طريقة SVM للتصنيف	126CT 101 COVID 4 ARds images 2 pneumocystis pneumonia 11 Sars images 6streptococcus 2 No finding images	%94.23	%91.88	%96.73	%98.54	%93.99
He et al (2020)[12]	استخدم نهج التعلم تحت الإشراف الذاتي مع تقنية نقل التعلم وشبكة DenseNet-121	COVID-CT dataset	%86	-	-	-	%85
Alshazly et al (2021)[13]	بنى CNN (DenseNet) (ResNet)	4173 CT 2168 COVID 758 Healthy 1247 Others	%93.96	%99.13	-	%94	-
Perumal et al (2021)[14]	نماذج التعلم الهجين (hybrid learning)	1488 CT 488 COVID 500 CAP 500 Normal	%96.69	%96	-	%98	-

-	-	-	-	%94.52	COVID-CT dataset	شبكة VGG-19	Shah et al (2021)[15]
%94	-	%96	%93	%94	274 CT 88 COVID-19 100 bacteria pneumonia 86 Normal	استُخدمت الشبكة العصبونية DRENet التي بنيت على أساس التدريب المسبق لشبكة ResNet50	Song et al (2021)[16]
%99	-	%99	%99	%98.94	SARS-CoV-2 CT scan dataset	يستخدم الذاكرة طويلة المدى (LSTM) للكشف عن ميزات COVID-19 المستخرجة	Naeem et al (2021)[17]
%90.87	-	%95.75	%85.89	%90.83	SARS-CoV-2 CT-scan dataset	استراتيجية تعلم مشتركة و تطبيع منفصل للميزات	Wang et al (2020)[18]
%78.83	-	%78.02	%79.71	%78.69	COVID-CT dataset		
%94	-	%90	%98	%94	SARS-CoV-2 CT-scan dataset	استخدم مجموعة مكسدة تتضمن أربع شبكات CNN مدربة مسبقاً	Jangam et al(2021)[19]
%86	-	%78	%95	%85	COVID-CT dataset		
%98.65	-	%98.82	%99.22	%98.59	SARS-CoV-2 CT-scan dataset	استخدم مزيج من شبكات VGG19 و ResNet50 و DenseNet201 المدربة مسبقاً.	Mouhafid et al(2022)[20]
%94.93	-	%95.37	%95.28	%95.05	COVID-CT dataset		

1.2.1 خلاصة الدراسات السابقة:

اعتمدت الدراسات السابقة خوارزميات تصنيف مختلفة للكشف عن COVID-19 باستخدام الصور المقطعية المحوسبة CT وحقق معظمها نتائج جيدة. إلا أن هناك نقطة يجب ملاحظتها وهي أن معظم الأبحاث المذكورة باستثناء الدراسات [18-19-20] استخدمت مجموعة بيانات واحدة لتقييم الأداء، وهو أمر غير كافٍ عند التعامل مع تصنيف صور طبية.

2.2.1 الجديد في الدراسة الحالية:

1. الدمج بين عدة تقنيات لبناء نظام التصنيف والتغلب على ظاهرة الإفراط في التعلم الناتجة عن محدودية البيانات.
2. اختبار الخوارزمية على ثلاث قواعد بيانات ومن ضمنهم قاعدة محلية من الصور المقطعية المحوسبة تم الحصول عليها من مشفى المواساة بدمشق للكشف عن COVID-19 لم تستخدم من قبل في دراسات سابقة.

3.1 مشكلة البحث:

تكمن المشكلة العلمية التي يطرحها البحث في قصور الطرق الحالية لكشف الإصابة بالفيروس التاجي الجديد COVID-19 واحتمال فشلها في بعض الأحيان ما ينتج عن ذلك أخطار عدوى وانتشار المرض بين أشخاص جدد، الأمر الذي يستدعي ضرورة البحث عن طرق جديدة قادرة على تجاوز ذلك القصور، وبإمكانها الكشف بسرعة أكبر عن الإصابة.

4.1 هدف البحث:

يهدف هذا البحث إلى بناء خوارزمية تصنيف باستخدام الشبكات العصبونية المتبقية من أجل تصنيف صور الأشعة المقطعية المحوسبة CT إلى فئتين: إما مصاب بفيروس كوفيد 19 أو سليم.

5.1 أهمية البحث ومسوغاته:

يمكن استخدام مصنقات الصور الرقمية عالية التمييزية في العديد من التطبيقات مثل رسم الخرائط بالاعتماد على صور الأقمار الصناعية أو تشخيص الأمراض بالاعتماد على الصور الطبية. وجرى التركيز في بحثنا على بناء مصنف لتشخيص مرض COVID-19 بالاعتماد على الصور المقطعية المحوسبة CT. ويتم استخدام الصور المقطعية المحوسبة لفحص COVID-19 للأسباب الآتية:

- القدرة على اكتشاف المرض بسرعة وتمكين التشخيص السريع.
 - سهولة الوصول إلى الصور المقطعية نظراً لأن كل مستشفى بها أجهزة تصوير مقطعي محوسب.
 - الاستفادة من هذه الأنظمة في غرف العزل وهذا ما يقضي على مخاطر انتقال العدوى.
- وبالتالي يمكن تطبيق الكشف عن COVID-19 المستند إلى التصوير المقطعي المحوسب بكفاءة كطريقة لاختبار المرضى المصابين بشكل مكمل لفحص RT-PCR، ولكنها تتطلب تشخيصاً متخصصاً ووقتاً إضافياً من الكوادر الطبية، وهنا تأتي أهمية استخدام خوارزميات لتصنيف مرضى COVID-19 بناءً على صور الصدر المقطعية CT لإعطاء تشخيص عالي الدقة وبوقت قصير.

6.1 محددات البحث:

أبرز التحديات التي تواجه تصنيف الصور المقطعية المحوسبة CT لتشخيص فيروس COVID-19 هي محدودية البيانات، حيث احتوت قاعدة البيانات الأولى التي حصلنا عليها من مستودع (GitHub) على 746 صورة CT وتضمنت قاعدة البيانات الثانية 2482 صورة CT والتي حصلنا عليها من مستودع (Kaggle)، وتم الحصول على 536 صورة CT من مشفى المواساة بدمشق.

7.1 حدود البحث:

اقتصرت البحث على أحد الأمراض المنتشرة حديثاً فقط، واقتراح نظام (خوارزمية) تصنيف لتحديد ما إن كان الشخص مصاباً أم سليماً.

ويمكن تقسيم حدود البحث إلى:

- الحدود المكانية: تمثلت بإجراء الدراسة على صور CT لأشخاص مصابين أُخذت من مشفى المواساة الجامعي بدمشق.
- الحدود الزمانية: أُجريت الدراسة في العام 2021.

8.1 منهج البحث وأدواته:

استُخدم المنهج التحليلي /التجريبي لكونه أكثر المناهج استخداماً وملاءمة ومناسبة لموضوع البحث، واعتمد في جمع البيانات على الأدوات الآتية:

- مصادر البيانات الأولية عبارة عن قواعد البيانات المستخدمة في البحث.
- مصادر البيانات الثانوية كالكتب والابحاث المنشورة في مجال البحث.
- البرامج الحاسوبية اللازمة والضرورية لبناء النظام المقترح.

9.1 بنية الرسالة:

قُسِّمَ البحث إلى سبعة فصول متنوعة فقد أُشير في الفصل الأول إلى الإطار العام المتضمن الإشكالية البحثية والفرضيات والأهداف والأهمية، مع استعراض لأبرز الدراسات المرجعية السابقة ذات الصلة بالموضوع، وتمت الإشارة أيضاً إلى المنهج المتبع والأدوات المستخدمة.

أما الفصل الثاني فقد شُرحاً عن تقنية التصوير المقطعي المحوسب ومواصفات الصور المقطعية CT.

أما الفصل الثالث فقد استعرض أبرز الميزات المستخدمة في عملية التصنيف.

أما الفصل الرابع فقد تناول أهم طرق التصنيف، وتم التركيز على الشبكات العصبونية المتبقية نظراً لاعتمادنا عليها في تصميم الخوارزمية المقترحة في هذا البحث.

أما الفصل الخامس فقد استعرض آلية تدريب الشبكات العصبونية والمعاملات الفائقة الواجب ضبطها قبل تدريب الشبكة.

أما الفصل السادس فقد ضم مراحل الدراسة التي أنجزت لإنشاء الخوارزمية المقترحة بدءاً من البيانات المستخدمة في هذا البحث وتقسيمها وانتهاءً بمقاييس الأداء التي اعتمدت لتقييم الخوارزمية.

أما الفصل السابع فقد استعرض النتائج التي حصلنا عليها من تدريب خوارزمية التصنيف المقترحة على كل من قاعدة البيانات 1 وقاعدة البيانات 2 وقاعدة البيانات 3، ومقارنة هذه النتائج مع المصنفات التي اعتمدتها الدراسات السابقة لتشخيص COVID-19. ثم استعرضت خاتمة البحث وأبرز التوصيات والمقترحات.

الفصل الثاني

التصوير المقطعي المحوسب


Computed Tomography

1.2 تمهيد:


يعرض هذا الفصل المبدأ الأساسي لنظام التصوير الطبقي المحوري، وهي التقنية المستخدمة في تصوير الرئتين للكشف عن COVID-19 ومواصفات الصور المقطعية المحوسبة CT.

2.2 مبدأ التصوير المقطعي (الطبقي) المحوسب:

يُعرف جهاز التصوير الطبقي المحوري بأنه تقنية تقيس معامل تخامد الأشعة السينية باتجاه محور محدد في الأنسجة المختلفة (Tissues X-Ray Attenuation Coefficient) عن طريق تعريض جسم الإنسان لحزمة من الأشعة السينية من زوايا مختلفة كما هو موضح بالشكل (1-2)، واستخدام المساقط التي يتم الحصول عليها في عملية إعادة بناء الصورة للحصول على صور مقطعية للأنسجة الداخلية في جسم الإنسان، كما هو موضح في الشكل (2-2)، التي تم الحصول عليها باستخدام جهاز تصوير مقطعي متعدد الشرائح (MSCT) تظهر الرئتين والمناطق المحيطة بها في المساقط المختلفة، مساقط محورية (Axial Views) ومساقط سهمية (Sagittal Views) ومساقط جبهية (Coronal Views).



الشكل (1-2): مبدأ عمل جهاز التصوير الطبقي المحوري (الجيل الخامس)



الشكل (2-2): مساقط مختلفة للتصوير المقطعي للصدر (Chest CT Scan)

يتم في التصوير الشعاعي باستخدام الأشعة السينية إسقاط حزم الأشعة السينية ذات الكثافة المعينة على جسم يوضع أمام كاشف مناسب. ليس للهواء أي تأثير تخامد على فوتونات الأشعة السينية، ولكن معظم المواد (مثل الأنسجة والدم والعظام) تقلل من شدة الحزم التي تمر من خلالها إلى درجة معينة تعتمد على معامل تخامد الأشعة السينية إلى جانب ثخانة المادة التي ستعبرها هذه الأشعة. وبما أن معامل تخامد أشعة X لكل مادة يرتبط بشكل مباشر مع كثافة التصوير الشعاعي لذلك كثيراً ما تستخدم الكثافة الإشعاعية (Radio density) بدلاً من التخامد (Attenuation).


يمكننا باستخدام الكاشف قياس شدة الأشعة السينية خلف الجسم المصور، إذ يصبح بالإمكان توليد صورة ثنائية البعد والتي يمكن أن تفسر على أنها متوسط معاملات تخامد الجسم في اتجاه الأشعة السينية على مستوى الكاشف. استُخدم التصوير الشعاعي لأغراض التشخيص في وقت مبكر بعد اكتشاف الأشعة السينية في عام 1895، وكان تطورها بالتأكيد طفرة في الطب التشخيصي، وأصبح التصوير أكثر تطوراً على مر السنين، فهو كان الأسلوب الجراحي (non-invasive) الذي يمكن استخدامه بدلاً من إجراء قطع في الجسم لإلقاء نظرة من الداخل. وقد اكتشف لاحقاً أن لهذه الطريقة عيباً وهو أن الأشعة السينية

المؤينة ضارة للأنسجة البشرية ولا بد من أن تستخدم بحذر. وهذه المشكلة لم تحل بظهور التصوير المقطعي للأشعة السينية لذلك بقي الحافز مستمراً لإيجاد وتطوير تقنيات جديدة تخفض الجرعة الشعاعية عند التصوير باستخدام CT.

يتميز التصوير المقطعي المحوسب عن التصوير البسيط بنقاط عدة أهمها القضاء على مشكلة التراكب (superimposition)، وذلك من خلال تدوير مصدر الأشعة السينية حول الجسم أثناء التصوير، كما هو موضح بالشكل (2-1) وقياس الأشعة السينية باستمرار تقريباً.

يمكن إعادة بناء مصفوفة التخامد ثنائية البعد، والتي تمثل شريحة كاملة من الجسم باستخدام طريقة رياضية تسمى معكوس تحويل رادون (Inverse Radon Transform) [21]. وبتكرار هذا الإجراء للشرائح المجاورة، يمكن إنشاء صورة شعاعية للجسم من الداخل، كما هو مبين في الشكل (2-2).

تطورت أجهزة التصوير المقطعي بصورة كبيرة كالتطور الذي حصل في الدقة الحيزية للصورة ودقة التباين، وكذلك تطورها من خلال تقليل الزمن اللازم للحصول على شريحة تصوير واحدة، ويظهر الشكل (2-3) المنحني التدريجي الزمني للتطور مبيناً تقليل زمن التصوير مع تطور الأجهزة المقطعية بمعدل 1.34 في السنة [22]. يوجد بالإضافة إلى تقنية التصوير CT تقنيات تصوير أخرى تستخدم لتصوير الرئة مثل التصوير بالرنين المغناطيسي (MRI)، والتصوير المقطعي بالإصدار البوزيتروني (PET).



الشكل (2-3): تناقص زمن التصوير للشرريحة الواحدة مع تطور أجهزة التصوير CT.

3.2 قياسات التصوير المقطعي (Quantitative CT):

بغض النظر عن نوع الماسح CT يتم قياس الكثافة الإشعاعية μ باستخدام قيم CT أو وحدة هاونسفيلد (HU) المعطاة بالعلاقة:

$$HU = \frac{\mu - \mu_{water}}{\mu_{water}} 1000 \quad (1 - 2)$$

حيث μ_{water} يمثل معامل التخميد للماء. نظرياً قيمة HU غير منتهية، ولكن من الناحية العملية تبلغ نهايتها عند حوالي (3000HU). تُعرف العلاقة بأن الهواء يحتوي على معامل (-1000HU) والماء (0 HU). أنسجة الجسم (الدهون والعضلات وغيرها) لها قيمة CT تتراوح بين (-100 HU) و حتى (60 HU) وفقاً لمعامل تخميد كل نسيج، كما هو موضَّح في الجدول (1-2) [23].

الجدول (1-2): معامل التخميد لبعض الأنسجة المختلفة

Linear Attenuation Coefficient (cm ⁻¹)	Tissue
0.0003	Air
0.162	Fat
0.180	Water
0.181	Cerebrospinal fluid
0.187	White matter
0.184	Gray matter
0.182	Blood
0.46	Dense bone


وباستخدام هذا المعيار وجد أن معامل الدهون محدّد على أن يكون (-120 HU) تقريباً، ومعامل العضلات (40 HU) ومعامل العظام (1000 HU) وما فوق. وللدّم أيضاً معامل HU أعلى قليلاً من (0 HU). وتستخدم المواد الظليلة لفحص الأوعية الدّمويّة كمعامل تباين لزيادة كثافة الدّم في الصورة.

إنَّ العين البشرية غير قادرة على تمييز المجال الديناميكي من (1000 HU-) وحتى (3000 HU) الذي يعادل 4000 سوية رمادية. وقد أظهرت دراسات حديثة أنَّ العين البشرية قادرة على تمييز سويات رمادية ضمن المجال من (700) وحتى (900) سوية.


4.2 الصور الرقمية:

يمكن تعريف الصورة الضوئية المستمرة (continuous image) كدالة ثنائية البعد $f(x,y)$ ، إذ إن x و y هما الإحداثيان الحيزيان، ومطال f عند أي زوج من الإحداثيات (x,y) يسمى الشدة (intensity) أو السوية الرمادية gray level عند تلك النقطة من الصورة. عندما تكون قيم احداثيات الصورة f وشدتها جميعها كميات محددة متقطعة، تسمى الصورة صورة رقمية (digital image) وهكذا فإن الصورة الرقمية تتكون من عدد محدد من العناصر كل منها له قيمته الخاصة به ومكانه المحدد في الصورة. تسمى هذه العناصر عناصر صورة (picture elements) أو (pixels) والتسمية الأخيرة (pixels) هي الأكثر شيوعاً [24].

يعرض الشكل (2-4) توضيحاً للمفاهيم السابقة بتوضيح آلية تحويل صورة مستمرة باستخدام نظام تصوير معين (imaging system) إلى صورة رقمية، حيث تتم إضاءة الجسم المراد تصويره من منبع ضوئي لتتحول صورة الجسم إلى صورة داخلية (internal image) في نظام التصوير المعين الذي يعطي خرجاً صورة رقمية للجسم المراد تصويره (digitized image). ويبين الشكل (2-5) عناصر الصورة الرقمية الناتجة ممثلة في الإحداثيات الديكارتية وفق الاتجاه الشائع للمحاور في كتب معالجة الصور الرقمية.



الشكل (4-2) آلية تحويل صورة مستمرة باستخدام نظام تصوير معين imaging system إلى صورة رقمية



الشكل (5-2) عناصر الصورة الرقمية الناتجة ممثلة في الإحداثيات الديكارتية

حيث إنَّ:

M: هي عدد عناصر الصورة الرقمية في الاتجاه العمودي (ارتفاع الصورة high).

N: هي عدد العناصر في الاتجاه الأفقي (عرض الصورة width).

(0,0): هما إحداثيا المبدأ origin.

f(x,y): هي الصورة الرقمية.

Pixel: هو عنصر الصورة.

التمثيل الاصطلاحي الذي قدمناه في الفقرة السابقة يمكننا من كتابة الصورة الرقمية الكاملة وفق الصيغة

المصفوفية المختصرة الآتية:

$$f(x, y) = \begin{bmatrix} f(0,0) & f(0,1) \dots & f(0, N-1) \\ f(1,0) & f(1,1) & f(1, N-1) \\ \vdots & \vdots & \vdots \\ f(M-1,0) & f(M-1,1) \dots & f(M-1, N-1) \end{bmatrix} \quad (2-2)$$

الجانب الأيمن من هذه المعادلة هو بالتعريف الصورة الرقمية، وكل عنصر من هذه المصفوفة يدعى

"عنصر الصورة" (pixel).

تتطلب عملية الرقمنة اتخاذ قرار بخصوص M و N وعدد السويات الرمادية المتقطعة L لكل عنصر

صورة. لا يوجد أية متطلبات لقيم M و N باستثناء أن تكونا صحيحتين موجبتين، ولكن نظراً لمتطلبات

المعالجة والتخزين وتجهيزات الاعتيان، يجب أن يكون عدد السويات الرمادية قابلاً للتمثيل بقوى صحيحة

للرقم 2:

$$L=2^K \quad (3-2)$$

حيث L هو عدد السويات الرمادية المتقطعة لكل عنصر صورة، و k عدد صحيح.

نفترض أن السويات الرمادية المتقطعة متباعدة بانتظام ويقيم صحيحة ضمن المجال $[0, L-1]$. يدعى هذا المجال عادة المدى الديناميكي. ونقول عن الصور التي تشغل سوياتها الرمادية قدراً كبيراً من هذا المجال أن لها مدى ديناميكياً عريضاً، وهذا النوع من الصور يتمتع بتباين عالٍ لسوياته الرمادية ووضوح ممتاز لتفاصيله. وبالعكس، فالصور التي لها مدى ديناميكي منخفض تبدو باهتة من دون تفاصيل واضحة. إن عدد البتات اللازم لتخزين صورة مرقمة هو:

$$b = N * M * k \quad (4-2)$$

5.2 الصور الطبية الرقمية:

الصورة الطبية عموماً هي صورة للجسم أو لأحد أعضائه أو لبعضها أنتجت لتستخدم من أجل التشخيص أو المعالجة أو لكليهما. الصور الطبية في هذه الأيام في معظمها صور رقمية تنتجها أنظمة التصوير الحديثة كالصور المقطعية المحوسبة (Computed Tomography Image (CTI)).

وصور الرنين المغناطيسي (Magnetic Resonance Images (MRI)) والصور المأخوذة بالأشعة فوق الصوتية (Ultrasound Images (UI)) وصور أشعة غاما (Gamma Ray Images)، ولا تزال بعض أنواع الصور الطبية غير الرقمية كصور الأشعة السينية المألوفة للصدر والعظام والأسنان، وصور المجاهر البصرية تستعمل في تطبيقات شائعة مع انخفاض أهميتها مقارنة مع صور الأنظمة الرقمية الحديثة.

وهذه الصور غير الرقمية يمكن تحويلها إلى صور رقمية باستخدام ماسحات الصور (scanners) والكاميرات الرقمية (digital cameras) للاستفادة من مزايا وتقنيات معالجة الصور الرقمية وإمكاناتها في التشخيص والمعالجة. إن الغالبية العظمى للصور الطبية كصور الأشعة السينية والصور المقطعية المحوسبة CT وصور المرنان هي صور رمادية، وهي صور ذات وضوح كافٍ نظراً لتطور التجهيزات التي تنتجها.

عادةً ما تحتوي الصور الطبية التي تنتجها أجهزة الكشف عن الأشعة السينية وأجهزة التصوير المقطعي المحوسب (CT) والطرائق الأخرى على ما بين 12-16 بت / بكسل، وهو ما يعادل 4096-65.536 لونًا رماديًا. من ناحية أخرى، نرى أن هذه الصور يتم تصويرها من خلال شاشات طبية بها عدد أقل بكثير من الظلال الرمادية. لفترة طويلة دعمت شاشات LCD الطبية 8 بت أو 256 لونًا رماديًا لكل بكسل. مع إدخال العروض الطبية المحسّنة، زاد العدد المتاح من المقاييس الرمادية إلى 1024 [25].


1.5.2 الصور المقطعية المحوسبة CT:

الصور التي يتم الحصول عليها هي صور مقطعية عرضية، وبالإستعانة بالحاسوب يمكن إعادة تركيب صور ثلاثية الأبعاد من هذه الشرائح ثنائية الأبعاد.

يزودنا التصوير المقطعي المحوسب CT بدقة تباين عالية للبنى التشريحية، ويعد التصوير المقطعي CT تقنية حيوية في تشخيص وإدارة مرضى COVID-19. وانطلاقاً من أن كمية البيانات التي يتم الحصول عليها من التصوير المقطعي للصدر كبيرة جداً، إذ إنّ عدد الشرائح من أجل شريحة بثخانة أقل من 1mm قد يحصل على شرائح تصل إلى 500 شريحة من تصوير الرئة كلها باستخدام جهاز مقطع حلزوني. ومع تزايد طلب الحصول على دقة أكبر فإن كمية البيانات التي سيتم الحصول عليها لفحص الرئة ستزيد عبء العمل على أخصائيي الأشعة الذين سيضطرون إلى تحليل عدد كبير من الصور الشعاعية في وقت قصير. قد يؤدي هذا العبء إلى أخطاء في الكشف أو عدم الكشف. لذلك هناك حاجة إلى تطوير خوارزميات للتصنيف لمساعدة أخصائيي الأشعة في الكشف والتشخيص.

استُخدم في هذا البحث الصور المقطعية المحوسبة CT لتدريب خوارزمية تصنيف مرض COVID-19 واختبارها، إذ يعطي استخدام تقنيات التصوير المقطعي المحوسب CT للتشخيص المبكر للأمراض الوبائية

نتائج سريعة ودقيقة [26]. يُعرض في الشكل (2-6) مقارنة بين صور CT لمرضى كوفيد 19 وأشخاص سليمين.



الشكل (2-6)

(A) يُظهر التصوير المقطعي المحوسب لرئتي مريض COVID-19، حيث يظهر عتامة الزجاج الأرضي في الفصوص السفلية (الأسهم الحمراء). (B) يمثل التصوير المقطعي لرئتي شخص سليم، التي لا يوجد بها أي شذوذ. (C) يصور عينات البقعة المصابة. (D) يعكس عينات رقعة غير مصابة. تعد قاعدة البيانات 1 مصدر هذه الصور [27].

الفصل الثالث

آليات استخراج الميزات

Features Extraction

1.3 تمهيد:

تقوم آليات استخراج الميزات بتحليل الصور واستخراج أبرز الميزات التي تمثل مختلف فئات العناصر. يتم استخدام الميزات كمدخلات إلى المصنّفات التي تعينهم للفئة التي يمثلونها. الغرض من استخراج الميزات هو تقليل البيانات الأصلية عن طريق قياس خصائص معينة تميز نمط إدخال عن نمط ادخال آخر [28]. يعد استخراج الميزات أهم خطوة في عملية التصنيف، لأن الميزات الجيدة يمكن أن تزيد من مستوى دقة التصنيف. يوجد أنواع عدة للميزات منها:

2.3 ميزات الشكل Shape Features:

تستخدم جميع البكسلات داخل منطقة الشكل وتستخدم للحصول على وصف الشكل. تتطلب تكلفة حسابية والمزيد من التخزين. ومنها ميزات المساحة (Area) والمحيط (Perimeter) والدائرية (Circularity) وعدم الانتظام (Irregularity) والانحراف المركزي (Eccentricity) [29].

3.3 ميزات الكثافة Intensity Features:

تحتسب مباشرة من المدرج التكراري (Histogram) للصورة، ولا تأخذ بالحسبان العلاقة بين عناصر الصورة المتجاورة وبالتالي لا تعطينا المعلومات التركيبية للصورة. يوصف هيستوغرام الصورة بأنه مخطط يمثل عدد العناصر عند قيمة كل شدة (intensity) مختلفة في الصورة. نستطيع حساب هذه الميزات بفرض $P(i)$ احتمالية ظهور كل سوية رمادية i في الصورة و G العدد الكلي للسويات الرمادية في الصورة [30].

- المتوسط (Mean): يمثل متوسط اللون في الصورة.

$$\mu = \sum_{i=0}^{G-1} i \cdot P(i) \quad (1-3)$$

حيث μ هو المتوسط.

- الانحراف المعياري (Standard deviation): هو معدل انحراف قيمة كثافة عناصر الصورة عن المتوسط.

$$\sigma = \sqrt{\sum_{i=0}^{G-1} (i - \mu)^2 \cdot P(i)} \quad (2-3)$$

حيث σ الانحراف المعياري.

- التباين (Variance): وهو قياس لتباين السويات الرمادية، ويعطي التباين قياساً لكيفية اختلاف كل بكسل عن القيمة المتوسطة.

$$variance = \sum_{i=0}^{G-1} (i - \mu)^2 \cdot P(i) \quad (3-3)$$

- الالتواء (Skewness): وهو قياس لميلان الهيستوغرام، أي يصف درجة عدم تماثل التوزيع حول المتوسط.

$$skewness = \sigma^{-3} \left[\sum_{i=0}^{G-1} (i - \mu)^3 \cdot P(i) \right] \quad (4-3)$$

- **التفطح (Kurtosis):** وهو عبارة عن مقدار يقيس درجة تسطح توزيع ما، ويكون سالباً إذا كان التسطح عريضاً، وموجباً إذا كان التسطح حاداً على شكل شوكة.

$$kurtosis = \sigma^{-4} \left[\sum_{i=0}^{G-1} (i - \mu)^4 \cdot P(i) \right] \quad (5 - 3)$$

- **العشوائية (Entropy):** هي قياس لدرجة عشوائية النظام (درجة الاضطراب في الصورة).

$$entropy = - \sum_{i=0}^{G-1} P(i) \log_2 P(i) \quad (6 - 3)$$

4.3 ميزات التراكيب Texture Features:

تعكس التوزيع المكاني للسويات الرمادية للصورة والعلاقة بين أزواج البكسل ومحيطها. توفر ميزات التراكيب قياساً لمدى الانتظام (regularity) والخشونة (roughness) والنعومة (smoothness) في مناطق معينة. ويوجد طرق عدة لاستخراج ميزات التراكيب منها:

1.4.3 مصفوفة الحدوث المشترك للمستوى الرمادي:

:Gray Level Co-occurrence Matrix (GLCM)

وهي تقنية شائعة من أجل استخلاص معلومات تركيبية من الصورة والتي تأخذ بالحسبان العلاقة المكانية بين عناصر الصورة (بكسل). تُوصَف مصفوفة الحدوث المشترك بأنها مصفوفة ثنائية الأبعاد تعتبر أن الموقع المحدد للبكسل مرتبط بالعناصر المجاورة. يتم تمثيلها من خلال عنصر المصفوفة $P(i,j | d, \theta)$ الذي يمثل الاحتمال المشترك لحدوث السويات الرمادية i و j لزوج عنصر الصورة المفصول بمسافة d و زاوية θ . حُسبت هذه الميزات من أجل مسافة $d=1$ وأربع قيم لـ θ وهي $(0^\circ, 45^\circ, 90^\circ, 135^\circ)$ و G العدد الكلي للسويات الرمادية في الصورة [31].

يمكن استخدام مصفوفة الحدوث المشترك لاشتقاق العديد من الميزات التركيبية بما في ذلك ما يأتي:

- الطاقة (Energy): تقيس تماثل توزيع مستوى الكثافة وتُعطى الطاقة كمجموع مربع لقيم البكسل كافة.

$$Energy = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} \{P(i,j)\}^2 \quad (7-3)$$

- التباين (Contrast): يعبر عن الاختلاف في قياس قيم الكثافة بين البكسل والبكسل المجاور. إذا كان هناك العديد من التغيرات فإن قيمة التباين مرتفعة.

$$Contrast = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} (i-j)^2 P(i,j) \quad (8-3)$$

- التجانس (Homogeneity): هو قياس لتقارب توزيع عناصر مصفوفة GLCM بالنسبة للقطر الرئيسي وتتراوح قيمتها بين المجال [0 1].

$$Homogeneity = \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} \frac{p(i,j)}{1 + (i-j)^2} \quad (9-3)$$

- الترابط (Correlation): هو قياس لمدى ارتباط البكسل مع البكسلات المجاورة.

$$Correlation = \frac{\sum_{i=0}^{G-1} \sum_{j=0}^{G-1} (i,j) P(i,j) - (\mu_x \cdot \mu_y)}{\sigma_x \cdot \sigma_y} \quad (10-3)$$


حيث μ_x, μ_y المتوسط لكل من p_x و p_y وكل من σ_x, σ_y الانحراف المعياري لكل من p_x و p_y .

- العشوائية (Entropy): هي قياس لدرجة العشوائية في تركيب الصورة.

$$Entropy = - \sum_{i=0}^{G-1} \sum_{j=0}^{G-1} p(i,j) \log(p(i,j)) \quad (11-3)$$

2.4.3 خوارزمية النمط الثنائي المحلي (LBP): Local Binary Pattern

تقوم خوارزمية LBP بتسمية وحدات البكسل الخاصة بالصورة بأرقام عشرية، تسمى الأنماط الثنائية المحلية أو رموز LBP، والتي تقوم بترميز البنية المحلية حول كل بكسل. كما هو موضح في الشكل (3-1)، في كل خلية تتم مقارنة كل بكسل بجيرانه الثمانية في جوار 3×3 عن طريق طرح قيمة البكسل المركزي. تُرمز القيم السالبة الناتجة بالرمز 0 والموجبة بالرقم 1، يتم الحصول على رقم ثنائي من خلال تسلسل كل هذه الرموز الثنائية في اتجاه عقارب الساعة بدءاً من أعلى اليسار، وتُستخدم القيمة العشرية المقابلة له في وضع العلامات. تتمثل أهم ميزات خوارزمية LBP في مقاومة التغيرات في المستوى الرمادي والبساطة الحسابية التي يمكن استخدامها في تطبيقات الوقت الفعلي [32].



الشكل (3-1) خوارزمية النمط الثنائي المحلي LBP

3.4.3 مصفوفة الحدوث الثنائي للمستوى الرمادي المحلي:

:Local Binary Gray Level Co-occurrence Matrix (LBGLCM)

هي تقنية هجينة تعتمد على مزيج من خوارزميات LBP و GLCM، حيث يتم أولاً تطبيق خوارزمية LBP على الصورة الأولية لإنشاء الصورة التركيبية. بعد ذلك تُستخرج ميزات GLCM من صورة LBP التي تم إنشاؤها.

تعمل خوارزمية GLCM التقليدية على أساس البكسل والبكسل المجاور له عند استخراج الميزات. ولا تهتم بالأنماط المحلية الأخرى للصورة. ومع ذلك باستخدام خوارزمية LBGLCM يتم استخراج الميزات من

خلال النظر في كل من البنية التركيبية والمعلومات المكانية. بفضل هذه المزايا يمكن أن تنتج خوارزمية LBGLCM نتائج أكثر نجاحاً من خوارزمية GLCM في العديد من تطبيقات معالجة الصور [33].

4.4.3 مصفوفة طول التشغيل للمستوى الرمادي:

:Gray Level Run Length Matrix(GLRLM)

تستخدم تقنية GLRLM طرقاً إحصائية ذات ترتيب أعلى (high-order) لاستخراج الميزات المكانية لوحدات البكسل ذات المستوى الرمادي.

مصفوفة الميزات التي تم الحصول عليها هي ثنائية الأبعاد، إذ يعطي كل عنصر في هذه المصفوفة العدد الإجمالي لتكرارات المستوى الرمادي في الاتجاه المحدد [34].

الفصل الرابع

التصنيف

Classification

1.4 تمهيد:

يمكن تعريف التصنيف بأنه عملية تجميع الأشياء المتشابهة معاً، ويشترك جميع أعضاء المجموعة الواحدة أو القسم الواحد أو الصنف الواحد الناتج عن التصنيف في خاصية محددة واحدة على الأقل لا يملكها أعضاء الأقسام أو الأصناف الأخرى للاستفادة في مجالات علمية. فالتصنيف يظهر في حال كون البيانات المتوفرة كبيرة. ولا يقتصر التصنيف في مجال العلوم فحسب بل يستخدم التصنيف بشكل واسع في حل كثير من المشكلات خاصة تلك التي تتعلق بالأعمال من خلال تحليل مجموعة من البيانات ووضعها على شكل أصناف أو أقسام يمكن استخدامها فيما بعد لتصنيف البيانات المستقبلية وفق تصنيف معين [35].

2.4 طرق التصنيف:

تقسم المصنفات على أساس نموذج التدريب المستخدم إلى:

1.2.4 التصنيف الخاضع للإشراف Supervised Classification:

وهو الأكثر انتشاراً وتغذى فيه الخوارزميات بالبيانات والفئات (Classes)، وتدريب على الربط بين كل ميزة والفئة التي تمثلها. ثم تختبر عينات مشابهة لما دربت عليه دون فئات مقابلة، ويجب أن نتعرف إلى فئات هذه العينات.

2.2.4 التصنيف غير الخاضع للإشراف Unsupervised Classification:

هي طريقة تفحص عدداً كبيراً من البكسلات المجهولة وتقسّمها إلى فئات على أساس التجمعات الطبيعية الموجودة في قيم الصورة. يحدد الكمبيوتر طيفياً فئة منفصلة، ثم يحدد قيمة المعلومات الخاصة بهم ولا تتطلب أي معرفة مسبقة.

3.4 خوارزميات التصنيف:


اقترح العديد من خوارزميات التصنيف، حيث هذه الخوارزميات لديها القدرة على تنفيذ العمليات اعتماداً على الميزات التي تم الحصول عليها. وسوف نتناول في هذا الفصل أبرز خوارزميات التصنيف.

1.3.4 خوارزمية آلة شعاع الدعم (Support Vector Machine(SVM):

يعد SVM أحد نماذج التعلم الخاضع للإشراف المستخدمة على نطاق واسع في التعلم الآلي، والتي يمكنها تعيين نقاط بيانات جديدة لفئات مختلفة عند إعطاء مجموعة من أمثلة التدريب. طُوِّر SVM لمعالجة البيانات القابلة للفصل الخطي، ثم جرى تمديدها للتعامل مع البيانات غير القابلة للفصل كذلك سواء بطريقة خطية أو غير خطية [36].

تنقسم عملية التصنيف عادةً إلى مرحلتين: مرحلة التدريب ومرحلة الاختبار. يتم في مرحلة التدريب توفير بيانات التدريب (مصفوفة الميزات ومصفوفة الهدف الذي يحتوي الفئات Classes). يهدف الـ SVM بالاعتماد على بيانات التدريب إلى إيجاد نموذج قادر على تصنيف الحالات الجديدة (حالات الاختبار) عند توفر مصفوفة الميزات لها فقط.

الفكرة الأساسية للعملية التي يقوم بها SVM هي نقل عينات التدريب إلى فضاء متعدد الأبعاد باستخدام تابع غير خطي (nonlinear transfer)، ثم يتم إيجاد المستوى الفاصل (Hyperplane) بين عينات التدريب، بحيث يتم ترك فواصل بين عينات التدريب المختلفة، كما تُجمَع العينات المتشابهة من الصنف نفسه مع بعضها. متجهات الدعم (Support Vectors) هي البيانات القريبة من المستوى الفاصل، والتي تشكل الحدود الفاصلة كما في الشكل (4-1). يمكن تلخيص هدف عملية التصنيف باستخدام SVM بإيجاد مستوى فاصل يعطي أقصى هامش (margin) بين نقاط بيانات كلا الفئتين، إذ إنّ زيادة مسافة الهامش تمكن من تصنيف نقاط البيانات المستقبلية بشكل أفضل [37].




الشكل (4-1): التصنيف باستخدام SVM

2.3.4 خوارزمية أقرب الجيران (K-nearest neighbors(KNN):

هي خوارزمية تعلم خاضعة للإشراف، وهي خوارزمية بسيطة تخزن جميع الحالات المتاحة، وتصنف الحالات الجديدة بناء على مقياس التشابه (تابع المسافة)[38].

آلية عمل الخوارزمية الشكل(4-2):

- نحدد قيمة المتغير k الذي يعبر عن عدد الجيران.
- نحسب قيمة المسافة بين المثال الجديد والأمثلة المخزنة.
- نحصل على المجاورين اعتماداً على أقل مسافة حُسبت ونأخذ منهم عدد k مجاور.
- نحدد الفئة للمجاورين.
- نعين المثال الجديد إلى الفئة التي تحتوي على أقصى عدد من أقرب الجيران.



الشكل (2-4) آلية عمل خوارزمية KNN

3.3.4 خوارزمية K-Means Clustering:

قُدِّمَت هذه الخوارزمية بواسطة J.B. MacQueen في عام 1976. وتعد خوارزمية تعلم غير خاضعة للإشراف، إذ تقسم هذه الخوارزمية البيانات إلى مجموعات بحيث يتم تجميع البيانات ذات الخصائص نفسها في المجموعة نفسها، ويتم تجميع البيانات ذات الخصائص المختلفة في مجموعات أخرى.

الهدف من هذه الخوارزمية هو تقسيم عدد من العناصر (البيانات) إلى عدد k من المجموعات الفرعية (clusters) والتي ينضم فيها كل عنصر إلى المجموعة ذات النقطة المركزية الأقرب (centroid)، إذ تمثل النقطة المركزية الأساس الذي يتم بناءً عليه تقسيم البيانات وتصنيفها [39].

وتُحسب أقرب نقطة مركزية لكل نقطة ادخال x_i باستخدام المسافة الإقليدية (Euclidean Distance)، فإذا كان $p = (p_1, p_2, \dots, p_n)$ و $q = (q_1, q_2, \dots, q_n)$ نقطتان في الفضاء الإقليدي فإن المسافة (d) من p إلى q أو من q إلى p تعطى وفق العلاقة (1-4).

$$d(p, q) = d(q, p) = \sqrt{\sum_{i=1}^n (q_i - p_i)^2} \quad (1-4)$$


4.3.4 الشبكات العصبونية التلافيفية (CNN) Convolutional Neural Network:

CNN هي نوع خاص من الشبكات العصبونية العميقة (ANNs) التي تعتمد على العلاقة بين وحدات البكسل المتجاورة. وتتكون هذه الشبكة من خلايا عصبونية لها معاملات يمكنها التعلم، حيث تستخدم معاملات محددة عشوائياً للإدخال في البداية وتقوم بتعديلها في عملية التدريب. بمجرد الانتهاء من التدريب تستخدم الشبكة هذه المعاملات المعدلة للتنبؤ والتحقق من صحة النتيجة في عملية الاختبار.

حققت الشبكات العصبونية التلافيفية نجاحاً كبيراً في مشكلة تصنيف الصور، إذ إنّ الطبيعة المحددة لشبكة CNN تطابق توزيع نقاط البيانات في الصور. إلى جانب كونها إحدى الطرق القليلة التي تمكنت من تجاوز القدرات البشرية في مهام معينة للتعرف على الأنماط في الصور [40].


تتكون شبكة CNN من ثلاثة أنواع رئيسة من الطبقات هي:

الطبقات التلافيفية (Convolutional layers) وطبقات التجميع (Pooling layers) والطبقات المتصلة بالكامل (Fully Connected layers) الشكل (3-4).




الشكل (3-4) بنية الشبكات العصبونية التلافيفية

الطبقة التلافيفية هي المكون الرئيسي لشبكة CNN، حيث تنفذ ما يُعرف باسم "عملية الالتفاف" وهي عملية تتضمن تطبيق مرشح (Kernel) على الصورة المدخلة. يمكن استخراج ميزات مختلفة للصورة من خلال الطبقات التلافيفية، حيث تكتشف الطبقات الأولى الحواف وتكتشف الطبقات الثانية الأشكال، ثم الطبقات اللاحقة قد تكتشف كائنات كاملة مثل الوجوه أو الأشكال الهندسية المعقدة الأخرى [41]. يصف الشكل (4-4) كيفية تنفيذ عملية الالتفاف.



الشكل (4-4) عملية الالتفاف

ويتبع الطبقات التلافيفية وظيفة تنشيط غير خطية مثل تابع RELU الذي يعطي في خرجه 0 إذا كانت القيمة المدخلة سالبة، ويعطي قيمة الدخل نفسها إذا كانت قيمتها موجبة الشكل (4-5) [42]. وتسمى المخرجات الناتجة خرائط الميزات. تعطي خرائط الميزات (المعروفة أيضاً باسم خرائط التنشيط) استجابة المرشح في كل موضع مكاني.




الشكل (4-5) تابع RELU

يتم الحصول على خرائط الميزات من خلال التطبيق المتكرر لعملية الالتفاف * للصورة باستخدام مرشح خطي أوزانه W ، مضافاً لكل مرشح انحياز b ثم تطبيق تابع غير خطي $Relu$.

$$h_{ij} = Relu((W * x)_{ij} + b) \quad (2 - 4)$$


حيث تُحدَّث أوزان المرشحات والانحيازات أثناء عملية التدريب.

وتتمثل وظيفة طبقة التجميع في تقليل أبعاد خرائط الميزات لتخفيض التعقيد الحسابي. وتوجد تقنيات مختلفة للتجميع مثل التجميع الأقصى (max-pooling) والتجميع المتوسط (average-pooling). يأخذ التجميع الأقصى أكبر قيم البكسل في المنطقة كما هو موضح في الشكل (4-6). يقلل التجميع من عدد المعاملات المراد حسابها وبالتالي يزيد من الكفاءة الإحصائية ويقلل من متطلبات الذاكرة لتخزين المعاملات. لا تحتوي طبقة التجميع على معاملات للتعلم [43].




الشكل (4-6) التجميع الأقصى

بعد طبقات تلافيفية وتجميع عدة، تُحوَّل خرائط الميزات التي لدينا عند خرج هذه الطبقات إلى متجه (Vector) عن طريقة الطبقة المسطحة Flatten layer. تجمع الطبقة المسطحة خرج الطبقات السابقة في متجه واحد. يوضح الشكل (4-7) مثالاً بسيطاً لعملية التسطيح.



الشكل (4-7) تمثيل لعملية التسطيح

تتم عملية التصنيف من خلال أخذ خرائط الميزات النهائية، وتستخدم كمدخلات للطبقات المتصلة بالكامل الشكل (4-8). تحتوي الطبقة النهائية المتصلة بالكامل على خلايا عصبونية بعدد الفئات نفسها التي يجب التعرف إليها. يُعد خرج الطبقة الأخيرة خرجاً نهائياً للمصنف.



الشكل (4-8) الطبقة المتصلة بالكامل

Softmax هي وظيفة التنشيط الأكثر شيوعاً المستخدمة في طبقة الخرج [44]. تحسب درجة الاحتمال لكل فئة، ويظهر التمثيل الرياضي لتابع Softmax في المعادلة (4-3).

$$\sigma(z)_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (3-4)$$

من أجل $i=1,2,\dots,k$ و $z=(z_1,z_2,\dots,z_k) \in \mathbb{R}^K$

ويوجد تصاميم عدة لـ CNN مثل شبكات AlexNet ،VGGNet ،GoogLeNet وResidual.

1.4.3.4 شبكة AlexNet:


هي النموذج الفائز في مسابقة ImageNet 2012 والذي بدأ بالتركيز على التعلم العميق. تتكون شبكة

AlexNet من 8 طبقات قابلة للتدريب عبارة عن 5 طبقات تلافيفية و3 طبقات متصلة بالكامل [45].

تحتوي الطبقات المتصلة بالكامل على 4096 خلية عصبونية. ساعد استخدام الوحدة الخطية المصححة

(ReLU) بعد الطبقات التلافيفية والطبقات المتصلة بالكامل على تدريب نموذجهم بشكل أسرع من الشبكات

المماثلة التي تحتوي على وحدات (Tanh). ويوضح الشكل (4-9) هيكلية شبكة AlexNet.



الشكل (4-9) هيكلية شبكة AlexNet

2.4.3.4 شبكة VGG:


طُوِّرت شبكة VGG بواسطة Simonyan و Zisserman [46]، واستخدموا مرشحات صغيرة الحجم 3×3 لجميع الطبقات، وجعلوا الشبكة أعمق مقارنة مع شبكة AlexNet مع الحفاظ على المعاملات الأخرى ثابتة. لقد استخدموا إجمالي 6 نماذج مختلفة لـ CNN هي: A-LRN ، A ، B ، C ، D (VGG16) و E (VGG19) والتي تختلف فقط في العدد الإجمالي للطبقات في الشبكة. عُرضت التفاصيل الهيكلية لشبكة VGG16 في الشكل (4-10).



الشكل (4-10) هيكلية شبكة (VGG16)

3.4.3.4 شبكة GoogLeNet:


تختلف بنية GoogLeNet التي اقترحها Szegedy وآخرون عن CNN التقليدية. فقاموا بزيادة عدد الوحدات في كل طبقة باستخدام مرشحات متوازية تسمى وحدة البداية (inception) [47]، بحجم 1×1 و 3×3 و 5×5 في كل طبقة التقاف. وقاموا أيضاً بزيادة عدد الطبقات إلى 22 طبقة. على الرغم من وجود 22 طبقة، فإنّ عدد المعاملات المستخدمة في شبكة GoogLeNet هي 24 مليون معامل أقل من AlexNet ودقتها أفضل بكثير. يوضح الشكل (4-11) هيكلية شبكة GoogLeNet.



الشكل (4-11) هيكلية شبكة GoogLeNet

4.4.3.4 شبكة DenseNet:

قدم هوانغ وآخرون الشبكات التلافيفية الكثيفة (DenseNet) [48]، التي تتضمن استخدام كتل كثيفة في CNN التقليدية. إدخال طبقة معينة في كتلة كثيفة هو عبارة عن سلسلة من مخرجات جميع الطبقات السابقة كما هو موضح في الشكل (4-12)، إذ تعيد كل طبقة استخدام ميزات جميع الطبقات السابقة، وهذا ما يعزز انتشار الميزات ويقلل من مشكلة تلاشي التدرج اللوني، ويؤدي استخدام عدد قليل من المرشحات إلى تقليل عدد المعاملات أيضاً.



الشكل (4-12) كتلة كثيفة نموذجية ذات 5 طبقات

5.4.3.4 شبكة ResNet:

منذ عام 2013، بدأ مجتمع Deep Learning في بناء شبكات أعمق لأنها كانت قادرة على تحقيق قيم عالية الدقة. علاوة على ذلك، يمكن أن تمثل الشبكات الأعمق ميزات أكثر تعقيداً، وبالتالي يمكن زيادة قوة النموذج والأداء. ومع ذلك لم يكن تكديس المزيد من الطبقات مناسباً للباحثين.

أثناء تدريب شبكات أعمق، لوحظت مشكلة تدهور الدقة. بمعنى آخر، إضافة المزيد من الطبقات إلى الشبكة جعل قيمة الدقة إما مشبعة أو أنها بدأت في الانخفاض فجأة، وكان السبب وراء تدهور الدقة هو اختفاء تأثير التدرج (vanishing gradient) الذي لا يمكن ملاحظته إلا في الشبكات الأعمق.

في أثناء مرحلة الانتشار العكسي، يُحسب الخطأ وتُحدّد قيم التدرج. تُعاد التدرجات إلى الطبقات المخفية وتحديث الأوزان وفقاً لذلك. تستمر عملية تحديد التدرج وإرساله إلى الطبقة المخفية التالية حتى يتم الوصول إلى طبقة الإدخال. يصبح التدرج أصغر وأصغر عندما يصل إلى الجزء السفلي من الشبكة. لذلك، ستُحدّث أوزان الطبقات الأولية ببطء شديد أو تظل كما هي. بعبارة أخرى لن تتعلم الطبقات الأولية للشبكة بصورة فعالة. وستبدأ الدقة إما في التدهور أو الإشباع بقيمة معينة. على الرغم من معالجة مشكلة التدرج المتلاشي باستخدام التهيئة المعيارية للأوزان إلا أن دقة الشبكة الأعمق بقيت ثابتة.

لحل مشكلة التدرج المتلاشي، اقترح إطار عمل التعلم المتبقي العميق. فقاموا بتضمين التعيين المتبقي المعادلة (4-4).


$$(H(x) = F(x) + x) \quad (4 - 4)$$

بدلاً من التعيين الأساسي المطلوب ($H(x)$) في شبكتهم وسموا نموذجهم باسم الشبكات المتبقية

(Residual network)[49].

تتشابه الشبكات المتبقية مع الشبكات الأخرى التي تحتوي على طبقات الالتفاف والتجميع والتنشيط والطبقات المتصلة بالكامل المكسدة واحدة فوق الأخرى. البناء الوحيد للشبكة البسيطة لجعلها شبكة متبقية هو اتصال الهوية (Identity Connection) بين الطبقات. يوضح الشكل (4-13) الكتلة المتبقية المستخدمة في الشبكة، حيث يظهر اتصال الهوية كسهم منحني ينشأ من الإدخال حتى نهاية الكتلة المتبقية [50].

يسمح اتصال الهوية بأخذ التنشيط من طبقة واحدة وإضافته إلى طبقة أخرى، وهذا ما يؤدي إلى ضغط الشبكة في بضع طبقات فقط، ويتيح التعلم بصورة أسرع. وبالتالي يسمح استخدام الشبكات المتبقية تدريب شبكات عميقة جداً وتجنب مشكلة اختفاء تأثير التدرج. لا يحتوي اتصال الهوية على أي معاملات إضافية أو تعقيد حسابي وهو موجود فقط لإضافة الخرج من الطبقة السابقة إلى الطبقة القادمة.



الشكل (4-13) اتصال الهوية
(a) الشبكة العادية (b) الكتلة المتبقية

لا تمتلك الشبكات المتبقية أي معاملات إضافية بالمقارنة مع الشبكات البسيطة بعدد الطبقات نفسها وبالتالي لن يؤدي استخدامها إلى زيادة التعقيد الحسابي. يوجد أنواع عدة للشبكات المتبقية منها:

(ResNet-152, ResNet-110, ResNet-101 ResNet-50, ResNet-34, ResNet-18)

ويوضح الجدول (4-1) الطبقات المستخدمة لكل نوع من الشبكات المتبقية.

الجدول (1-4) طبقات النماذج المختلفة للشبكات المتبقية

layer name	34-layer	50-layer	101-layer
conv1	$7 \times 7, 64, \text{stride } 2$		
conv2_x	$3 \times 3 \text{ max pool, stride } 2$		
	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
conv3_x	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$
conv4_x	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$
conv5_x	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$

الفصل الخامس

تدريب الشبكات العصبونية

Neural Network Training

1.5 تمهيد:

بمجرد إنشاء شبكة عصبونية لتطبيق معين تصبح هذه الشبكة جاهزة للتدريب. لبدء هذه العملية، يُجرى اختيار المعاملات الأولية للشبكة عشوائياً، ثم يبدأ التدريب أو التعلم.

هناك طريقتان للتدريب إما خاضع للإشراف أو غير خاضع للإشراف. يتضمن التدريب الخاضع للإشراف آلية لتزويد الشبكة بالمخرجات المرغوبة، إما عن طريق تصنيف أداء الشبكة يدوياً أو من خلال توفير المخرجات المرغوبة مع المدخلات. في التدريب غير الخاضع للإشراف يجب على الشبكة أن تفهم فيه المدخلات دون مساعدة خارجية.

2.5 التدريب الخاضع للإشراف:

في التدريب الخاضع للإشراف، يتم توفير المدخلات والمخرجات. تقوم الشبكة بعد ذلك بمعالجة المدخلات وتقارن مخرجاتها الناتجة مقابل المخرجات المرغوبة، ثم تُنشر الأخطاء مرة أخرى من خلال النظام، وهذا ما يتسبب في قيام النظام بضبط المعاملات التي تتحكم في الشبكة. تحدث هذه العملية مراراً وتكراراً حيث تُعدّل المعاملات باستمرار. تسمى مجموعة البيانات التي تتيح التدريب بـ "مجموعة التدريب".

أثناء تدريب الشبكة، تُعالج مجموعة البيانات نفسها مرات عدة وتُحدّث المعاملات. ومع ذلك، فإن بعض الشبكات لا تتعلم أبداً. وقد يكون هذا بسبب أن بيانات الإدخال لا تحتوي على المعلومات المحددة التي يتم اشتقاق المخرجات المطلوبة منها. لا تتقارب الشبكات أيضاً إذا لم تكن هناك بيانات كافية لتمكين التعلم الكامل. يحتاج التدريب الخاضع للإشراف إلى حجب مجموعة من البيانات تسمى "مجموعة الاختبار" لاستخدامها في اختبار النظام بعد خضوعه للتدريب. عندما يتم تدريب النظام بصورة صحيحة في النهاية، فلا حاجة إلى مزيد من التعلم ويمكن تجميد المعاملات.

3.5 التدريب غير الخاضع للإشراف:

في التدريب غير الخاضع للإشراف، يتم تزويد الشبكة بالمدخلات ولكن ليس بالمرجات المرغوبة. يجب أن يقرر النظام بنفسه بعد ذلك الميزات التي سيستخدمها لتجميع بيانات الإدخال. يُشار إلى هذا غالباً بالتنظيم الذاتي أو المتكيف.

يتكون تدريب الشبكة العصبونية عادةً من مرحلتين: مرحلة الانتشار الأمامي التي يتم فيها تمرير المدخلات بالكامل عبر الشبكة، ومرحلة الانتشار الخلفي التي يتم فيها حساب التدرجات وتحديث المعاملات.

4.5 مرحلة الانتشار الأمامي Forward Propagation:

يتم إدخال الصور في طبقة الإدخال على شكل أرقام. تشير هذه القيم العددية إلى شدة البكسل في الصورة. تطبق الخلايا العصبونية في الطبقات التلافيفية بعض العمليات الحسابية على هذه القيم.

من أجل إجراء هذه العمليات الحسابية، هناك قيم معاملات معينة تُهيأ عشوائياً. بعد هذه العمليات الحسابية في الطبقات التلافيفية، تُرسل النتيجة إلى طبقة الخرج التي تولد التنبؤ النهائي.

تعطي كل طبقة تلافيفية الخرج Z الذي يُحسب وفق العلاقة:

$$Z = W^T.X + b \quad (1-5)$$

حيث X هي المدخلات، W هي الأوزان و b هي الانحيازات

وبعد تطبيق وظيفة التنشيط Relu تصبح المعادلة:

$$F(x) = \text{Relu}(W^T.X + b) \quad (2-5)$$

تُهيأ المعاملات (W, b) لجميع الطبقات عشوائياً في مرحلة الانتشار الأمامي ثم يتم إيجاد خرج الشبكة العصبونية. في مرحلة الانتشار العكسي يحاول النموذج تحديث هذه المعاملات بحيث تكون التنبؤات الإجمالية أكثر دقة [51].

5.5 مرحلة الانتشار العكسي Backward Propagation:

بمجرد إنشاء الناتج، فإن الخطوة التالية هي مقارنة الناتج بالقيمة الفعلية. بناءً على الناتج النهائي، ومدى قرب أو بعد ذلك من القيمة الفعلية، تُحدَّث قيم المعاملات (W, b) . وتكرّر عملية الانتشار الأمامي باستخدام قيم المعاملات المحدثة وتُنشأ مخرجات جديدة.

في التعلم العميق لدينا مفهوم الخسارة الذي يخبرنا عن مدى ضعف أداء النموذج. تُستخدم هذه الخسارة لتدريب شبكتنا بحيث تعمل بشكل أفضل. يجب تقليل تابع الخسارة لأن الخسارة الأقل تعني أن نموذجنا سيؤدي بصورة أفضل.


سنتنشر الأخطاء التي تم الحصول عليها من طبقة الخرج إلى العقد الأخرى في اتجاه عكسي. تُستخدم هذه الأخطاء لحساب التدرج (gradient) لوظيفة الخسارة. ثم يتم إدخال التدرج إلى خوارزمية التحسين، والتي بدورها تستخدمه لتحديث المعاملات (W, b) في محاولة لتقليل تابع الخسارة [52].

6.5 المعاملات الفائقة Hyperparameters:

المعاملات الفائقة هي المتغيرات التي تحدد بنية الشبكة العصبونية وتسمح لها بالتدريب [53]، إذ تتحكم قيمتها في عملية التعلم وتحدد قيم معاملات النموذج بعد نهاية مرحلة تدريب الشبكة. وهذه المعاملات الفائقة هي:

1.6.5 معدل التعلم Learning Rate:

يشير معدل التعلم إلى المقدار الذي يتم من خلاله تحديث المعاملات أثناء التدريب (المعروف أيضاً باسم حجم الخطوة) لنماذج التعلم الآلي. وهو أحد المعاملات الفائقة المهمة المستخدمة في تدريب الشبكات العصبونية. والقيم الاعتيادية لمعدل التعلم هي $[0.1, 0.01, 0.001, 0.0001, 0.00001, 0.000001]$. إن تحديد معدل تعليمي منخفض للغاية، يجعل نموذجنا بطيئاً للغاية من حيث تحديد الحد الأدنى من تابع الخسارة، في حين يؤدي اختيار قيمة عالية إلى تجاوز النقطة المثلى لأن النموذج سيستمر في اتخاذ خطوات كبيرة الشكل (5-1) [54].



الشكل (5-1) تأثير الحالات المختلفة لمعدل التعلم على التقليل من تابع الخسارة

وبالتالي يوجد حالات عدة لضبط معدل التعلم:

- يتناقص خطأ الاختبار بسرعة في أثناء التدريب: يشير إلى الاختيار الجيد لمعدل التعلم.
- يتناقص خطأ الاختبار ببطء شديد في أثناء التدريب: يشير إلى ضرورة زيادة معدل التعلم.
- يتزايد خطأ الاختبار ببطء في أثناء التدريب: يشير إلى ضرورة تقليل معدل التعلم.

وقد اقترح العديد من الاستراتيجيات في الأبحاث العلمية لضبط معدل التعلم. من بين تلك الاستراتيجيات آلية معدل التعلم التكيفي، إذ تتغير قيمة معدل التعلم في أثناء عملية التدريب [55]. ومعدل تعلم الموجة الجيبية المتناقص بشكل كبير [56]. واستخدام بعض أبحاث الخوارزميات الجينية لتعلم ضبط معدل التعلم [57].

تسمح بعض النماذج الحديثة من خوارزميات انداز التدرج مثل خوارزمية Adam بمعدلات التعلم التكيفية فتتم مراقبة أداء النموذج على مجموعة بيانات التدريب بواسطة الخوارزمية، ويُعدّل معدل التعلم استجابةً لذلك.

2.6.5 الحقبات Epochs:

الحقبة هي دورة يُجرى خلالها تمريرة واحدة فقط للأمام وللخلف على جميع بيانات التدريب. حقبة واحدة تعني أن كل عينة في مجموعة بيانات التدريب قد أُتيحت لها فرصة لتحديث معاملات النموذج الداخلي. تتكون الحقبة من دفعة واحدة أو أكثر. يعد توجيه الشبكة العصبونية للقيام بالعديد من الحقبات أمراً بالغ الأهمية لآلية التعلم نظراً لأن حقبة واحدة لا يمكن أن توفر تدريباً كافياً لتصنيف موثوق. وعندما يكون عدد فترات التدريب مرتفعاً جداً، تحدث مشكلة تُعرف باسم مشكلة الإفراط في التعلم (Overfitting)، يحدث

ذلك عندما تصل دقة بيانات التدريب (وليس بيانات الاختبار) إلى 100%. عندما تصل الشبكة إلى هذه المرحلة، تكون قد حفظت كل شيء عن بيانات التدريب، وبالتالي تتخفف دقة الاختبار بصورة كبيرة [58].

3.6.5 الدفعة Batch:

حجم الدفعة هو معلمة فائقة تحدد عدد العينات للعمل من خلالها قبل تحديث معاملات النموذج الداخلي. الدفعة عبارة عن تكرار للحلقة الواحدة على عينة واحدة أو أكثر وعمل تنبؤات. حيث يمكن تقسيم مجموعة بيانات التدريب إلى دفعة واحدة أو أكثر.

عندما تُستخدم جميع عينات التدريب لإنشاء دفعة واحدة، فإن خوارزمية التعلم تسمى الانحدار المتدرج الدفعي (BGD). عندما تكون الدفعة بحجم عينة واحدة، فإن خوارزمية التعلم تسمى الانحدار المتدرج العشوائي (SGD)، وعندما يكون حجم الدفعة أكثر من عينة واحدة وأقل من حجم مجموعة بيانات التدريب، فإن خوارزمية التعلم تسمى انحدار الدفعات الصغيرة المتدرجة (M-BGD).

في حالة خوارزمية انحدار الدفعات الصغيرة المتدرجة، تتضمن أحجام الدفعات الشائعة 32 و 64 و 128 عينة. إذا كان حجم الدفعة صغيراً جداً، فسوف يتم تدريب الخوارزمية ببطء شديد. ومع ذلك، إذا كان حجم الدفعة كبيراً جداً، فإن الشبكة لا تقوم بتحديث المعاملات بصورة كافية [59].

4.6.5 المحسنات Optimizers:

تُحدّد خوارزميات التحسين كيفية تغيير المعاملات ومعدلات التعلم للشبكات العصبونية لتقليل تابع الخسارة وتحقيق أدق النتائج الممكنة. يُدرّب نموذج CNN العميق عن طريق تحديث معاملات جميع الطبقات في الشبكة بصورة تكرارية ويؤدي المُحسّن دوراً مهماً هنا. لتقليل تابع الخسارة، تُحدّث المعاملات في الاتجاه العكسي في كل تكرار، وتُقارن المخرجات المرغوبة والمخرجات المتوقعة ويُحسب تابع الخسارة مرة أخرى. تكون قيمة تابع الخسارة قريبة من الصفر عندما يكون الخرج المطلوب والخرج المتوقع متماثلين تماماً، وهذا هو الهدف الرئيسي لأي خوارزمية تحسين [60].

يوجد أنواع مختلفة لخوارزميات التحسين:

بفرض أن دالة الهدف التي يجب تصغيرها هي $f(x)$ و $x \in R^n$. التدرج المقابل هو $\Delta f(x)$ وحجم الخطوة للتكرار k هو t_k .

1.4.6.5 خوارزمية الانحدار المتدرج الدفعي (BGD): Batch Gradient Decent

تقوم هذه الخوارزمية بتحديث المعاملات x بعد مسح مجموعة التدريب بأكملها:

$$x_{k+1} = x_k - t_k \Delta f(x_k)^{(1:n)} \quad (3-5)$$

في المهام ذات الصلة بالتعلم العميق، تحتوي مجموعة التدريب على ملايين أو حتى مليارات العينات، والتي ستكلف وقتاً طويلاً لمسح مجموعة التدريب بأكملها لحساب التدرج، وهذا ما يؤدي إلى بطء شديد في الأداء. علاوة على ذلك، فإن ذاكرة الحساب محدودة أيضاً ويصعب إدخال جميع البيانات في النموذج في وقت واحد، لذلك نادراً ما تستخدم نماذج التعلم العميق طريقة خوارزمية الانحدار المتدرج الدفعي للتعامل مع مشكلة التحسين.

2.4.6.5 خوارزمية الانحدار المتدرج العشوائي (SGD):

تقوم خوارزمية SGD بحساب التدرج وتحديث المعاملات لكل عينة تدريب:

$$x_{k+1} = x_k - t_k \Delta f(x_k)^{(i)} \quad (4 - 5)$$

على الرغم من أن حجم الخطوة الصغير يمكن أن يجعل SGD متقارباً إلى نقطة جيدة، إلا أنه يجعل التدريب بطيئاً. علاوة على ذلك، عندما نستخدم وحدات معالجة الرسومات GPU لإجراء الحساب، فإن تبديل البيانات المتكرر بين الذاكرة ووحدة معالجة الرسومات والذاكرة المحلية يقلل أيضاً من الكفاءة.

3.4.6.5 خوارزمية انحدار الدفعات الصغيرة المتدرجة (M-BGD):


تدمج هذه الخوارزمية مزايا خوارزميتين SGD و BGD، وتُحدّث المعاملات بعد الحصول على التدرج لمجموعة صغيرة من العينات:

$$x_{k+1} = x_k - t_k \Delta f(x_k)^{(i:i+m)} \quad (5 - 5)$$

حيث m هو حجم الدفعة. نظرًا لأننا نستخدم مجموعة من البيانات بدلاً من أخذ مجموعة البيانات بأكملها، فإننا نحتاج إلى عدد أقل من التكرارات. وبالتالي فإن خوارزمية M-BGD أسرع من كل من خوارزميات SGD و BGD. وباعتبار أن هذه الخوارزمية تستخدم التجميع، فلا يلزم تحميل جميع بيانات التدريب في الذاكرة، مما يجعل العملية أكثر كفاءة في التنفيذ. ومع ذلك فإن خوارزمية انحدار الدفعات الصغيرة المتدرجة لا تضمن تقارباً جيداً، كما يحتاج ضبط حجم الخطوة إلى بعض الخبرة.

4.4.6.5 خوارزمية الانحدار المتدرج مع الزخم :Gradient Decent with Momentum

الزخم [61] هو إحدى الآليات المستخدمة لتحديد الاتجاه وتخمين التذبذبات كما يتضح من الشكل (2-5). يقوم بذلك عن طريق إضافة جزء من متجه التحديث للخطوة الزمنية الماضية إلى متجه التحديث الحالي.



الشكل (2-5) تأثير الزخم على خوارزمية SGD

$$v_k = mv_{k-1} + t_k \Delta f(x_k) \quad (6-5)$$

$$x_{k+1} = x_k - v_k$$

يحدد $m \in [0,1]$ عدد التكرارات التي دُمجت فيها التدرجات السابقة في التحديث الحالي. بشكل عام يتم ضبط m على 0.5 حتى يستقر التعلم الأولي ثم يُزاد إلى 0.9 أو أعلى.

5.4.6.5 خوارزمية (NAG) :Nesterov Accelerated Gradient

إن فكرة خوارزمية NAG تشبه إلى حد بعيد خوارزمية SGD بزخم متغير طفيف. حيث يمكننا استخدام خوارزمية NAG لإجراء التحسين من خلال التطلع إلى الأمام لتقريب الاتجاه [62].

$$v_k = mv_{k-1} + t_k \Delta f(x_k - mv_{k-1}) \quad (7-5)$$

$$x_{k+1} = x_k - v_k$$

6.4.6.5 خوارزمية Adagrad:

تقيس خوارزمية Adagrad [63] حجم الخطوة لكل معامل وفقاً للتدرجات السابقة الخاصة بهذا المعامل والتي تجري بصورة أساسية عن طريق قسمة التدرج الحالي في قاعدة التحديث على مجموع التدرجات السابقة.

$$G_k = G_{k-1} + \Delta f(x_k)^2 \quad (8-5)$$

$$x_{k+1} = x_k - \frac{t}{\sqrt{G_k + \varepsilon}} \Delta f(x_k)$$

حيث G هو تراكم التدرجات السابقة، و ε مصطلح تجانس لتجنب القسمة على صفر.

يختلف حجم الخطوة لكل معامل. حيث يكون أكبر بالنسبة للمعاملات ذات التدرجات السابقة الصغيرة (G تكون صغيرة) ويكون صغيراً كلما كانت التدرجات السابقة كبيرة نسبياً. لذلك، لا نحتاج إلى ضبط حجم الخطوة يدوياً. يمكننا استخدام القيمة الافتراضية 0.01. ولكن عندما يصبح التراكم G أكبر، سيصل حجم الخطوة إلى الصفر عند اللانهاية.

7.4.6.5 خوارزمية Adadelta:

اشتُقت خوارزمية Adadelta [55] من خوارزمية Adagrad. تدمج هذه الخوارزمية مزايا الزخم وخوارزمية Adagrad، وعلى وجه التحديد تقيس حجم الخطوة بناءً على التدرج السابق، لكنها تستخدم فقط أحدث نافذة زمنية بدلاً من التدرجات السابقة بأكملها مثل Adagrad. فيما يأتي تفاصيل عملية Adadelta:

$$\begin{aligned}
E[\Delta f(x)^2]_k &= \rho E[\Delta f(x)^2]_{k-1} + (1 - \rho) \Delta f(x_k)^2 \\
\hat{x}_k &= - \frac{\sqrt{E[\hat{x}^2]_{k-1} + \varepsilon}}{\sqrt{E[\Delta f(x)^2]_k + \varepsilon}} \Delta f(x_k) \quad (9 - 5) \\
E[\hat{x}^2]_k &= \rho E[\hat{x}^2]_{k-1} + (1 - \rho) \hat{x}_k^2 \\
x_{k+1} &= x_k + \hat{x}_k
\end{aligned}$$

حيث ρ هو ثابت التدهور، و ε قيمة صغيرة تستخدم للاستقرار العددي.

8.4.6.5 خوارزمية RMSprop:

اقترحت خوارزمية RMSprop [64] أيضاً لمعالجة مشكلة تلاشي حجم الخطوة في Adagrad. كما أنها تستخدم متوسط التدهور للتدرجات السابقة:

$$\begin{aligned}
E[\Delta f(x)^2]_k &= \rho E[\Delta f(x)^2]_{k-1} + (1 - \rho) \Delta f(x_k)^2 \\
x_{k+1} &= x_k - \frac{t}{\sqrt{E[\Delta f(x)^2]_k + \varepsilon}} \Delta f(x_k) \quad (10 - 5)
\end{aligned}$$

حيث ρ هو ثابت التدهور.

9.4.6.5 خوارزمية Adam:

هي خوارزمية [65] تحسب حجم الخطوة التكيفية لكل معامل، وتستخدم كلاً من متوسط التدهور للتدرجات السابقة وقيمها التربيعية. تتكون قاعدة تحديث Adam من الخطوات الآتية:


$$\begin{aligned}
m_k &= \beta_1 m_{k-1} + (1 - \beta_1) \Delta f(x_k) \\
v_k &= \beta_2 v_{k-1} + (1 - \beta_2) \Delta f(x_k)^2 \quad (11 - 5) \\
\hat{m}_k &= \frac{m_k}{1 - \beta_1^k}, \hat{v}_k = \frac{v_k}{1 - \beta_2^k} \\
x_{k+1} &= x_k - \frac{t}{\sqrt{\hat{v}_{k+1} + \varepsilon}} \hat{m}_k
\end{aligned}$$

يُعدّ كل من β_1 و β_2 ثوابت لإبقاء التغييرات في التدرج ومعدل التعلم قيد الفحص.

أُجريت مقارنة بين المحسنات (Adam , AdaDelta , SGD Nesterov , RMSProp , AdaGrad)

من أجل نموذج شبكة عصبونية مع طبقتين مخفيتين متصلتين بالكامل و 1000 وحدة مخفية لكل منهما، واستُخدم تابع التنشيط ReLU مع حجم الدفعة 128 واستُخدمت قاعدة البيانات MNIST.

يوضح الشكل (3-5) أن Adam يحرز تقدماً أسرع في خفض تكلفة التدريب (training cost) مع زيادة عدد فترات التدريب مقارنة مع بقية المحسنات.



الشكل (3-5) تدريب الشبكات العصبونية متعددة الطبقات على قاعدة البيانات MNIST


وتظهر فعالية المحسن Adam في شبكات CNN العميقة أيضاً، حيث تم إجراء مقارنة بين المحسنات

(AdaGrad , SGD Nesterov , Adam) مع ومن دون إضافة طبقات التسرب من أجل شبكة CNN

تحتوي على ثلاث مراحل متتالية من مرشحات الالتفاف 5×5 وتجميع 3×3 كحد أقصى بخطوة 2

متبوعة بطبقة متصلة بالكامل من 1000 وحدة مخفية خطية مصححة (ReLU's). ويُطبق التسرب على طبقة الإدخال والطبقة المتصلة بالكامل. وتم ضبط حجم الدفعة على 128.

وُجدَ أنه على الرغم من إحراز كل من Adam و AdaGrad تقدماً سريعاً في خفض التكلفة في المرحلة الأولية من التدريب، كما هو موضح في الشكل (4-5) (يسار)، فإن SGD و Adam يتقاربان في النهاية بصورة أسرع بكثير من Adagrad لشبكات CNN الموضحة في الشكل (4-5) (يمين)، ويتقارب Adagrad بصورة أبطأ بكثير من الآخرين في هذه التجربة.



الشكل (4-5) تكلفة تدريب (training cost) للشبكات العصبونية التلافيفية ConvNet باستخدام

قاعدة البيانات CIFAR-10

(يمين) تكلفة التدريب على مدى 45 فترة ، (يسار) تكلفة تدريب للفترات الثلاث الأولى

الفصل السادس

منهجية البحث وإجراءاته

Research Methodology and Procedures

1.6 تمهيد:

يضم هذا الفصل مراحل الدراسة التي أنجزت بدءاً من البيانات المستخدمة وتقسيمها، وهيكلية الخوارزمية المقترحة، وتقنيات التغلب على ظاهرة الإفراط في التعلم (Overfitting) الناتجة عن محدودية البيانات المستخدمة. كما يضم أيضاً المعاملات الفائقة المستخدمة في تدريب الخوارزمية، ومقاييس الأداء التي اعتمدت لتقييم الخوارزمية المقترحة.


2.6 البيانات المستخدمة في البحث:

اعتمد على ثلاث قواعد بيانات من الصور المقطعية المحوسبة CT لتدريب الخوارزمية المقترحة واختبارها وهي:


1.2.6 قاعدة البيانات 1:

وهي قاعدة البيانات COVID-CT dataset، حيث جُمعت صور هذه القاعدة من الأوراق ذات الصلة بـ COVID-19 من (medRxiv، bioRxiv، NEJM، JAMA، Lancet) [27]. تحتوي قاعدة البيانات 1 على 349 صورة مقطعية محوسبة CT من 216 مصاباً بـ COVID-19 و 397 صور CT تُستخدم كأمثلة للتدريب السلبي. تم تأكيد فائدة مجموعة البيانات هذه من قبل أخصائي الأشعة الذي مارس بصورة مكثفة تشخيص مرضى COVID-19 وعلاجهم. هذه الصور المقطعية لها أحجام مختلفة حيث الحد الأدنى والمتوسط والحد الأقصى للارتفاع هو 153 و 491 و 1853 على التوالي. والحد الأدنى والمتوسط والحد الأقصى للعرض هو 124 و 383 و 1485 على التوالي.

يوضح الشكل (1-6) بعض الأمثلة على صور مقطعية إيجابية لـ COVID-19، والشكل (2-6) أمثلة على صور مقطعية سلبية لـ COVID-19.



الشكل (1-6) صور مقطعية إيجابية لـ COVID-19 مأخوذة من قاعدة البيانات 1




الشكل (2-6) صور مقطعية سلبية لـ COVID-19 مأخوذة من قاعدة البيانات 1

نظراً لأن صور قاعدة البيانات 1 المستخدمة لها أحجام مختلفة، فقد جرى تغيير حجم صور هذه القاعدة إلى 480×480 .


2.2.6 قاعدة البيانات 2:

وهي قاعدة البيانات SARS-CoV-2 CT-scan dataset [66]. تحتوي قاعدة البيانات هذه على 2482 صورة مقطعية محوسبة CT، والتي تم الحصول عليها من 120 مريض ومقسمة إلى 1252 صورة CT لأشخاص مصابين بـ COVID-19 و 1230 صورة CT لأشخاص سليمين. تم جمع مجموعة البيانات في عام 2020 من مستشفيات في ساو باولو بالبرازيل. تتراوح أبعاد هذه الصور من 119×104 إلى 512×416 .

يوضح الشكل (3-6) بعض الأمثلة على صور مقطعية إيجابية لـ COVID-19، والشكل (4-6) أمثلة على صور مقطعية سلبية لـ COVID-19.



الشكل (3-6) صور مقطعية إيجابية لـ COVID-19 مأخوذة من قاعدة البيانات 2



الشكل (4-6) صور مقطعية سلبية لـ COVID-19 مأخوذة من قاعدة البيانات 2


نظراً لأن صور قاعدة البيانات 2 المستخدمة لها أحجام مختلفة، فقد جرى تغيير حجم صور هذه القاعدة إلى 380×380 .

3.2.6 قاعدة البيانات 3:

وهي قاعدة البيانات Mwasa dataset، حيث تتضمن 536 صورة مقطعية محوسبة CT توزعت كالآتي: 268 صورة CT لمرضى مصابين بكوفيد 19 و 268 صورة CT لأشخاص سليمين. تم الحصول على قاعدة البيانات هذه من قسم الأشعة في مشفى المواساة في دمشق، مع الحصول على الموافقة الأخلاقية لكل الحالات. تم إثبات إصابة المرضى بـ COVID-19 بعمل اختبار RT-PCR. صُوِّر المرضى باستخدام جهاز التصوير المقطعي المحوري متعدد الشرائح (CT-64) الموجود في مشفى المواساة.

مواصفات الصور المستخدمة:

- نوع الصور: صور مقطعية محوسبة لمنطقة الصدر مأخوذة بالأشعة السينية لثلاثة مستويات في منطقة الصدر. وهي عبارة عن شرائح متوازية من النمط Gray Scale بأبعاد (512×512).
 - تم تحويل الصور من صيغة DICOM إلى صيغة PNG من أجل التعامل معها ضمن الخوارزميات المطورة ضمن بيئة Python.
 - إنّ الشرائح المستخدمة في البحث هي الشرائح التي تمثل منطقة الصدر من أصل الشرائح الناتجة عن عملية التصوير والتي يمكن أن يصل عددها إلى 72 شريحة أو أكثر للحالة الواحدة. لذلك يجب القيام في البداية باختيار الشريحة (الصورة) التي تحتوي على التمثيل الأفضل لمنطقة الصدر من بين الشرائح الناتجة عن عملية التصوير، وقد نُفِّذ ذلك يدوياً وتم اختيار 4 شرائح لكل حالة.
- يبين الشكل (5-6) صور CT لأشخاص سليمين ومصابين مأخوذة من قاعدة البيانات 3.



الشكل (5-6)

يمثل A صورة CT لشخص مصاب بكوفيد 19 و B صورة CT لشخص سليم.

4.2.6 تقسيم البيانات:

نظراً لعدم توفر أعداد كبيرة من البيانات قمنا بتقسيمها إلى مجموعتين: مجموعة تدريب ومجموعة اختبار (مجموعة الاختبار منفصلة عن مجموعة التدريب ولم تستخدم في عملية التدريب). وقد تم الاستغناء عن مجموعة التحقق من الصحة في سبيل تحسين عملية التدريب والاختبار. تُستخدم مجموعة التدريب للتدريب النموذجي والتعلم بالإضافة إلى ضبط المعاملات، وتُستخدم مجموعة الاختبار لإثبات النتائج النهائية لنموذجنا.

وكانت النسبة المستخدمة كالآتي:

- مجموعة التدريب 80%.

- مجموعة الاختبار 20%.

ويبين الجدول (6-1) إحصائيات تقسيم البيانات لكل من قاعدة البيانات 1 وقاعدة البيانات 2 وقاعدة البيانات 3، حيث قُسمت البيانات عشوائياً.


الجدول (6-1) إحصائيات تقسيم البيانات

قاعدة البيانات	التقسيم (Split)	COVID-19	Normal	Total
قاعدة البيانات 1 COVID-CT dataset	Training	278	318	596
	Test	71	79	150
قاعدة البيانات 2 SARS-CoV-2 CT-scan dataset	Training	1019	966	1985
	Test	233	264	497
قاعدة البيانات 3 Mwasa dataset	Training	206	222	428
	Test	62	46	108

3.6 الخوارزمية المقترحة:

يوفر النظام المقترح الموضح في الشكل (6-6) نموذج تصنيف فعال لتصنيف الصور المقطعية المحوسبة

CT للمرضى على أنه إما مصاب ب COVID-19 أو سليم (Normal).



الشكل (6-6) هيكلية الخوارزمية المقترحة

استُخدمت الشبكة المتبقية ResNet-50 حيث يستخدم في الطبقة الالتفافية الأولى مرشح بحجم 7×7 و 64 مرشحاً مختلفاً. بعد ذلك، استُخدمت طبقة MaxPool بحجم 3×3 . في الكتلة الالتفافية الثانية، يوجد مرشحات تبلغ أحجامها 1×1 و 3×3 و 1×1 و 64 و 64 و 256 مرشحاً على التوالي. تُكرر هذه المرشحات الثلاث ثلاث مرات، وبالتالي الحصول على خريطة ميزات من 9 طبقات. تتكون الكتلة الالتفافية الثالثة من مرشحات بحجم 1×1 و 128 مرشحاً و 3×3 و 128 مرشحاً و 1×1 و 512 مرشحاً. تُكرر لأربع مرات، وهذا ما يعطي خريطة ميزات من 12 طبقة. الكتلة الالتفافية التالية لها مرشحات يبلغ أحجامها 1×1 و 3×3 و 1×1 و 256 و 256 و 1024 مرشحاً على التوالي، وتتكرر هذه العملية ست مرات وهذا ما يعطي إجمالاً 18 طبقة. ثم الكتلة الالتفافية التالية التي تحتوي على مرشحات بحجم 1×1

و512 مرشحاً و 3×3 و 512 مرشحاً و 1×1 و 2048 مرشحاً، والتي تكررت ثلاث مرات وأعطت إجمالياً 9 طبقات. ثم استُخدمت طبقة AveragePool بحجم 3×3 .

أضيفت طبقتا تسريبٍ بمعدل حذف 50%. وأضيفت طبقة متصلة بالكامل تحتوي على 128 عصبوناً ومعامل تنشيط Relu. واستُخدمت طبقة خرج بعصبونين وعامل تنشيط Softmax.


4.6 تقليل الإفراط في التعلم Overfitting:

يمكن أن يؤدي تدريب نماذج التعلم العميق على مجموعة بيانات تحوي عدداً محدوداً من الصور إلى الإفراط في التعلم (Overfitting). فالنموذج سيحقق أداءً جيداً في بيانات التدريب، ولكنه يعمم بشكل سيئ في اختبار البيانات [67]. لمعالجة هذه المشكلة نلجأ إلى استخدام تقنيات التسرب ونقل التعلم وزيادة البيانات.

1.4.6 التسرب Dropout:

يتم عن طريق ضبط ناتج كل خلية عصبونية مخفية على الصفر مع احتمال 0.5. الخلايا العصبونية التي "تسربت" بهذه الطريقة لا تساهم في التمرير الأمامي ولا تشارك في الانتشار العكسي [68]. أحد الأسباب التي تجعل التسرب يعطي تحسينات كبيرة في الانتشار العكسي هو أنه يشجع كل وحدة مخفية فردية على تعلم ميزة مفيدة دون الاعتماد على وحدات مخفية أخرى محددة لتصحيح أخطائها.

الفكرة الأساسية هي إسقاط الوحدات عشوائياً جنباً إلى جنب مع اتصالاتها من الشبكة العصبونية أثناء التدريب، وهذا يمنع الوحدات من التكيف المشترك أكثر من اللازم أثناء التدريب. من خلال إسقاط وحدة ما، فإننا نعني إزالتها مؤقتاً من الشبكة إلى جانب جميع اتصالاتها الواردة والصادرة، كما هو موضح في الشكل (6-7) [69].



الشكل (6-7) تقنية التسرب

يبين الشكل (6-7) على اليسار شبكة عصبونية قياسية بطبقتين مخفيتين وعلى اليمين الشبكة التي تم إنتاجها عن طريق تطبيق التسرب على الشبكة الموجودة على اليسار، حيث تم إسقاط الوحدات المتقاطعة.

في الخوارزمية المقترحة أضيفت طبقتا تسرب بمعدل حذف 50% في الطبقات المتصلة بالكامل.

2.4.6 نقل التعلم Transfer Learning:


في المجال الطبي، استُخدم نقل التعلم أيضاً على نطاق واسع في تصنيف الصور الطبية ومهام التعرف مثل تصنيف الأورام [70]. بالنظر إلى المهمة المستهدفة (تشخيص COVID-19 من الصور المقطعية المحوسبة التي تحتوي على بيانات تدريب محدودة)، يهدف نقل التعلم إلى الاستفادة من البيانات واسعة النطاق والعلامات التي يوفرها الإنسان من مهام المصادر الأخرى لتعلم تمثيلات تعبيرية وقابلة للتعميم للمساعدة في تعلم المهمة المستهدفة.

عادةً ما يُجرى نقل التعلم عن طريق نقل بنية عصبونية قياسية إلى جانب أوزانها المعاد تدريبها مسبقاً على مجموعات البيانات واسعة النطاق مثل ImageNet [71]. ثم ضبط الأوزان على المهمة المستهدفة. في الخوارزمية المقترحة تم تدريب شبكة ResNet-50 مسبقاً على مجموعة ImageNet، ثم جرى تجميد أوزان

أول 28 طبقة من الخوارزمية المقترحة وإعادة ضبط الأوزان للطبقات المتبقية عند تدريب الخوارزمية على قواعد البيانات المستخدمة في البحث.

3.4.6 زيادة البيانات Data Augmentation:

زيادة البيانات هي تقنية شائعة تستخدم لتحسين تدريب الشبكات العصبونية التلافيفية [72]. الطريقة الأكثر شيوعاً لزيادة البيانات هي إجراء مجموعة من التحويلات التقريبية العشوائية للصورة الأصلية كالدوران والانعكاس والتصغير والتكبير والقص [73]. يمثل الشكل (6-8) كيفية إنشاء صور جديدة باستخدام تقنية زيادة البيانات عن طريق إجراء انعكاس أفقي (horizontal_flip) وعمودي (vertical_flip) وتدوير (rotation_range) بمقدار 10 درجات للصورة الأساسية.



الشكل (6-8) تقنية زيادة البيانات

سوف نستخدم لتنفيذ تقنية زيادة البيانات تابع ImageDataGenerator، حيث يقوم بقبول مجموعة من الصور المستخدمة للتدريب، ويطبق سلسلة من التحويلات العشوائية على كل صورة (بما في ذلك التدوير والانعكاس وتغيير الحجم والقص وما إلى ذلك). ويستبدل المجموعة الأصلية بالمجموعة الجديدة المحولة عشوائياً لتدريب خوارزمية التصنيف عليها (أي إنَّ البيانات الأصلية نفسها لا تُستخدم للتدريب). في مرحلة الاختبار، لا نطبق زيادة البيانات ونقوم بتقييم شبكتنا المدربة على بيانات الاختبار غير المعدلة.

5.6 المعاملات الفائقة Hyperparameters:

المعاملات الفائقة التي قمنا بتحديددها لشبكتنا هي المحسن ومعدل التعلم الابتدائي وحجم الدفعة وعدد مرات التدريب وعدد المعاملات التي تم تدريبها (Trainable parameters) وعدد المعاملات التي لم يتم تدريبها (Non-Trainable parameters). ويبين الجدول (2-6) قيم هذه المعاملات.

الجدول (2-6) المعاملات الفائقة للخوارزمية المقترحة

المحسن (Optimizer)	معدل التعلم الابتدائي (Learning rate)	حجم الدفعة (Mini-batch size)	عدد مرات التدريب (Epochs)	Trainable parameters	Non-trainable parameters	Total parameters
Adam	0.00001	64	50	9,193,858	14,656,384	23,850,242

يُعطى قيمة ابتدائية لمعدل التعلم 0.00001، وتقوم خوارزمية التحسين ADAM بتكييف معدل التعلم وذلك بمراقبة أداء النموذج على مجموعة بيانات التدريب، وتعديل معدل التعلم استجابةً لذلك.


6.6 مقاييس أداء خوارزمية التصنيف:

بعد الانتهاء من تدريب الشبكة العصبونية واختبارها يُقِيم عادةً أدائها من خلال مجموعة من المقاييس التي تعكس جودة أداء الشبكة العصبونية وتعطي معلومات مهمة كدقة التصنيف، عدد الحالات الفعلية والحالات المُتنبأ بها، عدد الحالات الموجبة الحقيقية، عدد الحالات الموجبة الكاذبة، عدد الحالات السالبة الحقيقية، وعدد الحالات السالبة الكاذبة، ومن هذه المقاييس نذكر الآتي:

1.6.6 مصفوفة الارتباك Confusion Matrix:

تستخدم مصفوفة الارتباك في أنظمة التصنيف لتقييم أدائها عن طريق البيانات التي تحتويها، فهي تحتوي على معلومات عن التصنيف الفعلي والتصنيف المُتنبأ به الناتج عن نظام التصنيف، إذ تمثل أعمدة هذه المصفوفة الفئات المُتنبأ بها (خرج الخوارزمية المقترحة) أما أسطرها فتمثل الفئات الحقيقية (الأهداف).

يظهر الشكل (6-9) مصفوفة الارتباك لتصنيف COVID-19، حيث تمثل الفئة الأولى الأشخاص المصابين بكوفيد 19 (سُميت هذه الفئة باسم COVID-19)، أما الفئة الثانية فتمثل الأشخاص الأصحاء (سُميت هذه الفئة باسم Normal)، وتمثل الأرقام على طول المحور الرئيسي للمصفوفة القرارات الصائبة المتخذة، أما الأرقام على طول المحور الثانوي فتمثل القرارات الخاطئة المتخذة.



الشكل (6-9) مصفوفة الارتباك

ونستطيع الحصول على مصفوفة الارتباك من أجل مجموعة بيانات التدريب فقط، ومجموعة بيانات الاختبار فقط، ومجموعة بيانات التحقق إن وجدت، ومجموعة البيانات الكلية، بما أن مصفوفة الارتباك تحتوي على معلومات عن عدد الحالات الحقيقية وعدد الحالات المُتنبأ بها، وبالتالي سنحصل من خلالها على مجموعة المفاهيم الآتية:

- **الحالات الموجبة الحقيقية (True Positive(TP):**

هي الحالات التي كان فيها الأشخاص مصابين فعلياً بالمرض وقامت الشبكة بتصنيفهم بصورة صحيحة على أنهم مصابون (عدد الصور المصنفة بشكل صحيح التي تحتوي على COVID-19).

- **الحالات الموجبة الكاذبة (False Positive(FP):**

هي الحالات التي يكون فيها الأشخاص أصحاء فعلياً وقامت الشبكة بتصنيفهم بصورة غير صحيحة على أنهم مصابون (عدد الصور السليمة المصنفة بشكل خاطئ على أنها مصابة بـ COVID-19).

• الحالات السالبة الحقيقية (True Negative(TN):

هي الحالات التي يكون فيها الأشخاص أصحاء فعلياً وقامت الشبكة بتصنيفهم بصورة صحيحة على أنهم أصحاء (عدد الصور السليمة المصنفة بصورة صحيحة).

• الحالات السالبة الكاذبة (False Negative (FN):

هي الحالات التي يكون فيها الأشخاص مصابين فعلياً بالمرض وقامت الشبكة بتصنيفهم بصورة غير صحيحة على أنهم أصحاء. (عدد الصور المصابة بـ COVID-19 المصنفة بصورة خاطئة على أنها صور سليمة).

تستخدم هذه المفاهيم في حساب مجموعة من المقاييس التي تعبر عن جودة أداء المصنف [74] ومنها:

1.1.6.6 الحساسية (Sensitivity(SEN):

تعرف الحساسية على أنها معدل الحالات الموجبة الحقيقية (True Positive Rate(TPR) وتقيس نسبة الأشخاص المصابين والذين شُخصوا بصورة صحيحة على أنهم مصابون، وتحسب من القانون الآتي:

$$\text{Sensitivity} = \frac{TP}{(TP + FN)} \quad (1 - 6)$$

2.1.6.6 الخصوصية (Specificity (SPE):

تعرف الخصوصية بأنها معدل الحالات السالبة الحقيقية (True Negative Rate(TNR) وتقيس نسبة الأشخاص الأصحاء والذين شُخصوا بصورة صحيحة على أنهم أصحاء، وتحسب من القانون الآتي:

$$\text{Specificity} = \frac{TN}{(TN + FP)} \quad (2 - 6)$$

ومنه يُستنتج معدل الكشف الخاطئ (False Positive Rate(FPR) الذي يحسب وفق العلاقة:

$$FPR = 1 - \text{Specificity} \quad (3 - 6)$$

3.1.6.6 الإحكام (Precision (PRE):

يعرف الإحكام بأنه معدل الحالات المصابة التي شُخصت بصورة صحيحة ويقاس نسبة الحالات الموجبة الحقيقية ضمن كل النتائج الموجبة (وتشمل الموجبة الحقيقية والموجبة الكاذبة)، أي عندما تتبأ المصنف بالحالات بأنها مصابة فكم مرة كانت هي فعلياً مصابة، ويحسب من القانون الآتي:

$$Precision = \frac{Tp}{(TP + FP)} \quad (4 - 6)$$

4.1.6.6 الدقة (Accuracy (ACC):

تعرف الدقة بأنها معدل عدد الحالات المصنفة بصورة صحيحة. ويقاس نسبة النتائج الحقيقية (السالبة الحقيقية والموجبة الحقيقية) ضمن العدد الكلي من الحالات الخاضعة للاختبار، أي هي نسبة العدد الكلي للتنبؤات الصحيحة للمصنف، وتحسب من القانون الآتي:

$$Accuracy = \frac{(TP + TN)}{(TP + TN + FN + FP)} \quad (5 - 6)$$

5.1.6.6 F-score:

$$F - score = \frac{2 * TP}{(2 * TP + FP + FN)} \quad (6 - 6)$$


2.6.6 منحنى (ROC) Receiver Operating Characteristic curve:

منحنى ROC هو منحنٍ بياني يستخدم كمقياس لجودة نظام التصنيف، حيث يتم توضيح نتائج النظام وقدرته باستخدام العلاقة بين الحساسية (Sensitivity) والخصوصية (Specificity) التي يظهرها منحنى (ROC) والذي يُعدّ الأكثر استخداماً في الأنظمة المساعدة لاتخاذ القرار.

تمتد محاوره على المجال [0,1]، ويمثل هذا الرسم البياني إظهاراً لمعدل الحالات الموجبة الحقيقية (Sensitivity) على المحور الرأسي مقابل معدل الحالات الموجبة الكاذبة على المحور الأفقي والتي تساوي

(1-Specificity) الشكل (6-10).

المصنف المثالي يعطي نقاطاً في الزاوية العليا اليسرى من المخطط وهذا ما يعني 100% حساسية و 100% خصوصية، أي كلما اتجه المنحني نحو اليسار والأعلى باتجاه النقطة (1,0) من المخطط كان عدد الحالات الموجبة الكاذبة أقل، وهو أمر ذو أهمية كبيرة ويدل على جودة التصنيف.



الشكل (6-10) منحني ROC

تمثل النقطة (1,0) المصنف المثالي (Perfect classifier) والذي يصنف كل الحالات الموجبة والحالات السالبة بصورة صحيحة، وهذه النقطة تمثل المصنف المثالي لأن معدل الحالات الموجبة الكاذبة هو صفر ومعدل الحالات الموجبة الحقيقية هو 1. تمثل النقطة (0,0) مصنفاً يتنبأ بكل الحالات بأنها سالبة، في حين أن النقطة (1,1) تمثل مصنفاً يتنبأ بكل حالة بأنها موجبة، أما النقطة (0,1) فهي تمثل المصنف الذي يعطي نتائج غير صحيحة من أجل كل الحالات.

من أجل كل فئة من الفئات تُطبّق عتبات متعددة عبر المجال [1,0] ومن أجل كل عتبة تُحسب قيمتان هما معدل الحالات الموجبة الحقيقية (عدد حالات الخرج التي أكبر أو تساوي العتبة مقسماً على عدد الحالات الهدف) ومعدل الحالات الموجبة الكاذبة (عدد حالات الخرج الأقل من العتبة) [75].

3.6.6 المساحة الواقعة تحت منحنى ROC (Area Under Curve (AUC):

يعطي منحنى ROC تصوراً ثنائي الأبعاد لأداء المصنف، قد نرغب في تمثيل أداء ROC بقيمة عددية واحدة تمثل الأداء المتوقع. حيث تتمثل إحدى الطرق الشائعة في حساب AUC، وهي المنطقة الواقعة تحت منحنى خصائص التشغيل ROC. نظراً لأن AUC يمثل جزءاً من مساحة مربع الوحدة، فستكون قيمته دائماً بين 0 و 1. وتمثل AUC درجة أو مقياس قابلية الفصل بين الفئات. وتخبّر عن مدى قدرة النموذج على التمييز بين الفئات، وكلما اقترب من 1 كان أداء المصنف أفضل. ويبين الجدول (3-6) القاعدة الأساسية لتفسير قيمة AUC [76].

الجدول (3-6)

AUC=0.5	لا يوجد تمييز (No discrimination)
$0.6 \geq AUC > 0.5$	تمييز ضعيف (Poor discrimination)
$0.7 \geq AUC > 0.6$	تمييز مقبول (Acceptable discrimination)
$0.8 \geq AUC > 0.7$	تمييز ممتاز (Excellent discrimination)
$AUC > 0.9$	تمييز بارز (Outstanding discrimination)

7.6 البرنامج المستخدم في البحث:

استخدمنا لغة برمجة بايثون لتنفيذ الخوارزمية المقترحة وتقييمها في البحث. وأيضاً تم استخدام خدمة Colab Google السحابية استناداً إلى Jupyter's Notebooks، والذي يسمح بالاستخدام المجاني لوحدة معالجة الرسومات (GPUs) أو TPUs من Google، مع مكتبات Scikit-Learn و PyTorch و TensorFlow و Keras و OpenCV.

تمتلك خدمة Google Colaboratory (CPU) المستخدمة المواصفات الآتية:

Up to Tesla K80 with 12 GB of GDDR5 VRAM, Intel Xeon Processor with two cores @ 2.20 GHz and 13 GB RA

الفصل السابع

النتائج والمناقشة

Results and Discussion


1.7 تمهيد:

يستعرض هذا الفصل النتائج التي حصلنا عليها من تدريب الخوارزمية المقترحة على كل من قاعدة البيانات 1 (COVID-CT dataset) وقاعدة البيانات 2 (SARS-CoV-2 CT-scan dataset) وقاعدة البيانات 3 (Mwasa dataset) التي حصلنا عليها من مشفى المواساة، بالإضافة إلى تقييم أداء الخوارزمية المقترحة عن طريق مقارنتها مع دراسات سابقة.

2.7 نتائج تدريب الخوارزمية المقترحة على قاعدة البيانات 1:


تتألف قاعدة البيانات 1 من 746 صورة CT قُسمت إلى 596 صورة استخدمت لتدريب خوارزمية التصنيف و 150 صورة استخدمت لاختبار الخوارزمية.

يظهر الشكلان (1-7) و (2-7) منحنيات الخسارة والدقة لمرحلة التدريب والاختبار التي تم الحصول عليها في أثناء عملية التدريب.



الشكل (1-7) منحنى الخسارة لمرحلة التدريب والاختبار لقاعدة البيانات 1

كما هو متوقع، تبدأ الخسارة بقيمة عالية وتتناقص تدريجياً لتصل خسارة التدريب إلى 0.0398 وخسارة الاختبار إلى 0.0527 عند نهاية عملية التدريب على قاعدة البيانات 1.




الشكل (7-2) منحنى الدقة لمرحلة التدريب والاختبار لقاعدة البيانات 1

تبدأ الدقة في الازدياد بازدياد عدد مرات التدريب وعند نهاية مرحلة التدريب تصل الدقة بالنسبة لبيانات التدريب إلى 0.999 وبيانات الاختبار الى 0.986.

1.2.7 مصفوفة الارتباك:

اختُبرت خوارزمية التصنيف المقترحة على 71 صورة CT لأشخاص مصابين ب COVID-19، وقد نجحت الخوارزمية بكشف 69 صورة منها. وأيضاً اختُبرت الخوارزمية على 79 صورة CT لأشخاص سليمين وقد نجحت الخوارزمية بتصنيف جميع الصور بصورة صحيحة.

يظهر الشكل (7-3) مصفوفة الارتباك لمجموعة الاختبار لقاعدة البيانات 1. تمثل أعمدة هذه المصفوفة الفئات المنتبأ بها (Predicted Label)، أما أسطرها فتمثل الفئات الحقيقية (True Label).



الشكل (7-3) مصفوفة الارتباك لمجموعة الاختبار لقاعدة البيانات 1

(TP) عدد الصور المصنفة بصورة صحيحة التي تحتوي على COVID-19 = 69.

(FP) عدد الصور السليمة المصنفة بصورة خاطئة على أنها مصابة بـ COVID-19 = 0.

(TN) عدد الصور السليمة المصنفة بصورة صحيحة = 79.

(FN) عدد الصور المصابة بـ COVID-19 المصنفة بصورة خاطئة على أنها صور سليمة = 2.

استخدمت قيم مصفوفة الارتباك التي حصلنا عليها في حساب كل من الدقة (Accuracy)، الحساسية

(Sensitivity)، والخصوصية (Specificity)، والإحكام (Precision) و F-score التي حققتها خوارزمية


التصنيف المقترحة الجدول (7-1).

الجدول (7-1) مقاييس أداء خوارزمية التصنيف لقاعدة البيانات 1

Accuracy	Sensitivity	Specificity	Precision	F-score
%98.66	%97.18	%100	%100	%98.57

2.2.7 منحنى خصائص التشغيل (ROC):

يظهر الشكل (4-7) منحنى ROC لمجموعة الاختبار للخوارزمية المقترحة، وكما هو ملاحظ فإن المنحنى يتجه أعلى و يسار المخطط أي باتجاه النقطة (1,0). ومقياس AUC (المساحة تحت المنحنى) أعطى قيمة 0.986 وهذا يدل على جودة عالية لخوارزمية التصنيف المقترحة.




الشكل (4-7) منحنى ROC لبيانات الاختبار لقاعدة البيانات 1

3.7 نتائج تدريب الخوارزمية المقترحة على قاعدة البيانات 2:


تتألف قاعدة البيانات 2 من 2482 صورة CT قُسمت إلى 1985 صورة استخدمت لتدريب خوارزمية التصنيف و 497 صورة استخدمت لاختبار الخوارزمية.

يظهر الشكلان (5-7) و (6-7) منحنيات الخسارة والدقة لمرحلة التدريب والاختبار التي تم الحصول عليها في أثناء عملية التدريب لقاعدة البيانات 2.



الشكل (5-7) منحنى الخسارة لمرحلة التدريب والاختبار لقاعدة البيانات 2

تبدأ الخسارة بقيمة عالية وتتناقص تدريجياً لتصل خسارة التدريب إلى 0.0319 وخسارة الاختبار إلى 0.0434 عند نهاية عملية التدريب لقاعدة البيانات 2.




الشكل (6-7) منحنى الدقة لمرحلة التدريب والاختبار لقاعدة البيانات 2

تبدأ الدقة في الازدياد بازدياد عدد مرات التدريب، حتى تصل الدقة لبيانات التدريب 0.9985 والدقة لبيانات الاختبار إلى 0.9920 عند نهاية عملية التدريب.

1.3.7 مصفوفة الارتباك:

اختُبرت خوارزمية التصنيف المقترحة على 233 صورة CT لأشخاص مصابين بـ COVID-19، وقد نجحت الخوارزمية بكشف 230 صورة منها. وأيضاً اختُبرت الخوارزمية على 264 صورة CT لأشخاص سليمين وقد نجحت الخوارزمية بكشف 263 صورة بشكل صحيح.

يظهر الشكل (7-7) مصفوفة الارتباك لمجموعة الاختبار لقاعدة البيانات 2.



الشكل (7-7) مصفوفة الارتباك لمجموعة الاختبار لقاعدة البيانات 2

(TP) عدد الصور المصنفة بصورة صحيحة التي تحتوي على COVID-19 = 230.

(FP) عدد الصور السليمة المصنفة بصورة خاطئة على أنها مصابة بـ COVID-19 = 1.

(TN) عدد الصور السليمة المصنفة بصورة صحيحة = 263.

(FN) عدد الصور المصابة بـ COVID-19 المصنفة بصورة خاطئة على أنها صور سليمة = 3.

يظهر الجدول (2-7) كل من الدقة (Accuracy)، الحساسية (Sensitivity)، والخصوصية

(Specificity)، والإحكام (Precision) و F-score التي حققتها خوارزمية التصنيف من أجل قاعدة


البيانات 2.

الجدول (2-7) مقاييس أداء خوارزمية التصنيف لقاعدة البيانات 2

Accuracy	Sensitivity	Specificity	Precision	F-score
%99.19	%98.71	%99.62	%99.56	%99.13

2.3.7 منحنى خصائص التشغيل (ROC):

يظهر الشكل (7-8) منحنى ROC لمجموعة الاختبار للخوارزمية المقترحة، وكما هو ملاحظ، فإن المنحنى يتجه أعلى و يسار المخطط أي باتجاه النقطة (1,0). ومقياس AUC (المساحة تحت المنحنى) أعطى قيمة 0.992، وهذا يدل أيضاً على جودة عالية لخوارزمية التصنيف المقترحة عند اختبارها على قاعدة البيانات 2.




الشكل (7-8) منحنى ROC لبيانات الإختبار لقاعدة البيانات 2

4.7 نتائج تدريب الخوارزمية المقترحة على قاعدة البيانات 3:


تتألف قاعدة البيانات 3 من 536 صورة CT قُسمت إلى 428 صورة استخدمت لتدريب خوارزمية التصنيف و 108 صورة استخدمت لاختبار الخوارزمية.

يظهر الشكلان (9-7) و (10-7) منحنيات الخسارة والدقة لمرحلة التدريب والاختبار التي تم الحصول عليها في أثناء عملية التدريب لقاعدة البيانات 3.



الشكل (9-7) منحنى الخسارة لمرحلة التدريب والاختبار لقاعدة البيانات 3

تبدأ الخسارة بقيم عالية وتتناقص تدريجياً لتصل خسارة التدريب إلى 0.0158 وخسارة الاختبار إلى 0.0634 عند نهاية عملية التدريب لقاعدة البيانات 3.




الشكل (10-7) منحنى الدقة لمرحلة التدريب والاختبار لقاعدة البيانات 3

تبدأ الدقة في الازدياد بازدياد عدد مرات التدريب، حتى تصل الدقة لبيانات التدريب إلى 1.0000 والدقة لبيانات الاختبار إلى 0.9907 عند نهاية عملية التدريب.

1.4.7 مصفوفة الارتباك:

اختُبرت خوارزمية التصنيف المقترحة على 60 صورة CT لأشخاص مصابين بـ COVID-19، وقد نجحت الخوارزمية بكشف 59 صورة منها. وأيضاً اختُبرت الخوارزمية على 48 صورة CT لأشخاص سليمين وقد نجحت الخوارزمية بتصنيف جميع الصور بصورة صحيحة. يظهر الشكل (7-11) مصفوفة الارتباك لمجموعة الاختبار لقاعدة البيانات 3.



الشكل (7-11) مصفوفة الارتباك لمجموعة الاختبار لقاعدة البيانات 3

(TP) عدد الصور المصنفة بصورة صحيحة التي تحتوي على COVID-19 = 59.

(FP) عدد الصور السليمة المصنفة بصورة خاطئة على أنها مصابة بـ COVID-19 = 0.

(TN) عدد الصور السليمة المصنفة بصورة صحيحة = 48.

(FN) عدد الصور المصابة بـ COVID-19 المصنفة بصورة خاطئة على أنها صور سليمة = 1.

يظهر الجدول (7-3) كل من الدقة (Accuracy)، الحساسية (Sensitivity)، والخصوصية

(Specificity)، والإحكام (Precision) و F-score التي حققتها خوارزمية التصنيف من أجل قاعدة


البيانات 3.

الجدول (3-7) مقاييس أداء خوارزمية التصنيف لقاعدة البيانات 3

Accuracy	Sensitivity	Specificity	Precision	F-score
%99.07	%98.33	%100	%100	%99.15

2.4.7 منحنى خصائص التشغيل (ROC):

يظهر الشكل (7-12) منحنى ROC لمجموعة الاختبار للخوارزمية المقترحة، وكما هو ملاحظ، فإن المنحنى يتجه أعلى و يسار المخطط أي باتجاه النقطة (1,0). ومقياس AUC أعطى قيمة 0.992، وهذا يدل أيضاً على جودة عالية لخوارزمية التصنيف المقترحة عند اختبارها على قاعدة البيانات 3.



الشكل (7-12) منحنى ROC لبيانات الإختبار لقاعدة البيانات 3

5.7 تقييم أداء الخوارزمية المقترحة:

جرى مقارنة خوارزمية التصنيف المقترحة مع الأبحاث السابقة التي أجريت مؤخراً لتشخيص فيروس COVID-19، والتي اعتمدت قاعدة البيانات (COVID-CT dataset) لاختبار طرائق التصنيف عليها. وجرى المقارنة من حيث كل من الدقة (ACC)، والحساسية (SEN)، والخصوصية (SPE)، والإحكام (PRE) و F-score الجدول (7-4).

الجدول (4-7) مقارنة الخوارزمية المقترحة مع الدراسات السابقة التي استخدمت قاعدة البيانات

(COVID-CT dataset)

طريقة التصنيف	F-score	SPE	PRE	SEN	ACC	الباحث
التعلم متعدد المهام و التعلم تحت الإشراف الذاتي	%85	-	-	-	%83	Zhao et al (2020)[7]
شبكة ResNet50	-	%87.62	-	%77.66	%82.91	Loey et al (2020) [8]
اختيار ميزات هجينة	%75	-	%75	%74	%96	Shaban et al (2020)[9]
استخدم نهج التعلم تحت الإشراف الذاتي مع تقنية نقل التعلم وشبكة DenseNet-121	%85	-	-	-	%86	He et al (2020)[12]
شبكة VGG-19	-	-	-	-	%94.52	Shah et al (2021)[15]
استراتيجية تعلم مشتركة وتطبيع منفصل للميزات	%78.83	-	%78.02	%79.71	%78.69	Wang et al (2020)[18]
استخدم مجموعة مكعدة تتضمن أربع شبكات CNN مدربة مسبقاً	%86	-	%78	%95	%85	Jangam et al (2021) [19]
استخدم مزيج من شبكات VGG19 و ResNet50 و DenseNet201 المدربة مسبقاً.	%94.93	-	%95.37	%95.28	%95.05	Mouhafid et al (2022) [20]
ResNet50 معدلة	%98.57	%100	%100	%97.18	%98.66	الخوارزمية المقترحة

وأيضاً تمت مقارنة خوارزمية التصنيف المقترحة مع الأبحاث السابقة التي أجريت مؤخراً لتشخيص فيروس COVID-19، والتي اعتمدت قاعدة البيانات (SARS-CoV-2 CT-scan dataset) الجدول (5-7).

الجدول (5-7) مقارنة الخوارزمية المقترحة مع الدراسات السابقة التي استخدمت قاعدة البيانات
(SARS-CoV-2 CT-scan dataset)

طريقة التصنيف	F-score	SPE	PRE	SEN	ACC	الباحث
CNN-LSTM	%99	-	%99	%99	%98.94	Naeem et al (2021) [17]
استراتيجية تعلم مشتركة وتطبيع منفصل للميزات	%90.87	-	%95.75	%85.89	%90.83	Wang et al (2020)[18]
استخدم مجموعة مكدسة تتضمن أربع شبكات CNN مدربة مسبقاً	%94	-	%90	%98	%94	Jangam et al (2021) [19]
استخدم مزيج من شبكات VGG19 و ResNet50 و DenseNet201 المدربة مسبقاً.	%98.65	-	%98.82	%99.22	%98.59	Mouhafid et al (2022) [20]
ResNet50 معدلة	%99.13	%99.62	%99.56	%98.71	%99.19	الخوارزمية المقترحة

خاتمة البحث

مع استمرار انتشار فيروس COVID-19 بسرعة في جميع أنحاء العالم، أصبح التصوير المقطعي المحوسب CT مهماً بصورة كبيرة للتشخيص السريع، وبالتالي فإن من الضروري تطوير خوارزميات تصنيف دقيقة لمساعدة الأطباء على تحديد المرضى المصابين بـ COVID-19 من خلال الصور المقطعية المحوسبة CT.

قمنا في هذا البحث بتطبيق خوارزمية لتصنيف الصور المقطعية المحوسبة وهي صور رقمية عالية التمييزية باستخدام الشبكات العصبونية المتبقية، واختبرت خوارزمية التصنيف على ثلاث قواعد بيانات، وقُسمت قواعد البيانات إلى مجموعة تدريب ومجموعة اختبار، واستخدمت مجموعة التدريب لضبط معاملات خوارزمية التصنيف، ومجموعة الاختبار لتقييم أداء الخوارزمية المقترحة. وتم التغلب على محدودية البيانات المستخدمة باستخدام تقنيات التسرب ونقل التعلم وزيادة البيانات.

لأجل تقييم أداء خوارزمية التصنيف المقترحة في البحث قمنا بحساب بعض المقاييس الشائعة اعتماداً على مصفوفة الارتباك، وهي الدقة والحساسية والخصوصية والإحكام و F-score، وقمنا بمقارنة هذه القيم مع المصنفات الأخرى في الأبحاث السابقة التي أجريها مؤخراً لتشخيص COVID-19.

أظهرت النتائج دقة النظام المقترح وموثوقيته، إذ بلغت الدقة والحساسية والخصوصية والإحكام و F-score 98.66%، 97.18%، 100%، 100%، 98.57% على الترتيب من أجل قاعدة البيانات الأولى و 99.19%، 98.71%، 99.62%، 99.56%، 99.13% على الترتيب من أجل قاعدة البيانات الثانية. و 99.07%، 98.33%، 100%، 100%، 99.15% على الترتيب من أجل قاعدة البيانات الثالثة.

وبالتالي فإن خوارزمية التصنيف المقترحة تتيح دقة عالية في تشخيص فيروس COVID-19.

التوصيات والمقترحات

بعد إنجاز هذا البحث يمكن التنويه إلى أن أبرز المشكلات التي تواجه تصنيف الصور المقطعية المحوسبة لتشخيص فيروس COVID-19 هي محدودية البيانات، فعدد صور CT التي اختُبرت خوارزمية التصنيف عليها في هذا البحث هي 150 من أجل قاعدة البيانات 1 و 497 من أجل قاعدة البيانات 2 و 108 من أجل قاعدة البيانات 3 التي تم الحصول عليها من مشفى المواساة. لذلك يوصى بزيادة عدد البيانات لتطوير البحث في المستقبل والحصول على صور CT من مستشفيات عدة في سورية لتعميم نتائج الخوارزمية المقترحة.

وأيضاً نقترح تطوير الخوارزمية لاستخدامها في تصنيف الصور المقطعية المحوسبة للصدر لأمراض عدة، مثل الالتهاب الرئوي والمكورات العنقودية بالإضافة إلى كوفيد 19.

ويمكن تطوير الخوارزمية لتصبح من مرحلتين: المرحلة الأولى اكتشاف المريض إذا كان مصاباً بـ COVID19 أو لا. والمرحلة الثانية اكتشاف خطورة COVID-19 للكشف عن حالة المريض، بما في ذلك الحالات الشديدة والمتوسطة والمنخفضة الخطورة.

المراجع

- [1] Kaur, M., & Singh, D. (2020). **Fusion of medical images using deep belief networks**. *Cluster Computing*, 23(2), 1439-1453.
- [2] Shukla, P. K., Shukla, P. K., Sharma, P., Rawat, P., Samar, J., Moriwal, R., & Kaur, M. (2020). **Efficient prediction of drug–drug interaction using deep learning models**. *IET Systems Biology*, 14(4), 211-216.
- [3] Xu, X., Jiang, X., Ma, C., Du, P., Li, X., Lv, S., ... & Li, L. (2020). **Deep Learning System to Screen Coronavirus Disease 2019 Pneumonia**. *Engineering*. 6(10). 1122-1129.
- [4] Pan, F., Ye, T., Sun, P., Gui, S., Liang, B., Li, L., ... & Zheng, C. (2020). **Time course of lung changes at chest CT during recovery from coronavirus disease 2019 (COVID-19)**. *Radiology*, 295(3), 715-721.
- [5] Ai, T., Yang, Z., Hou, H., Zhan, C., Chen, C., Lv, W., ... & Xia, L. (2020). **Correlation of chest CT and RT-PCR testing for coronavirus disease 2019 (COVID-19) in China: a report of 1014 cases**. *Radiology*, 296(2), E32-E40.
- [6] Xu, X., Jiang, X., Ma, C., Du, P., Li, X., Lv, S., ... & Li, L. (2020). **A deep learning system to screen novel coronavirus disease 2019 pneumonia**. *Engineering*, 6(10), 1122-1129.
- [7] Zhao, J., Zhang, Y., He, X., & Xie, P. (2020). **Covid-ct-dataset: a ct scan dataset about covid-19**. *arXiv preprint arXiv:2003.13865*, 490.
- [8] Loey, M., Manogaran, G., & Khalifa, N. E. M. (2020). **A deep transfer learning model with classical data augmentation and CGAN to detect COVID-19 from chest CT radiography digital images**. *Neural Computing and Applications*, 1-13.
- [9] Shaban, W. M., Rabie, A. H., Saleh, A. I., & Abo-Elsoud, M. A. (2020). **A new COVID-19 Patients Detection Strategy (CPDS) based on hybrid feature selection and enhanced KNN classifier**. *Knowledge-Based Systems*, 205, 106270.
- [10] Auliasari, K. (2021). **FEATURE EXTRACTION AND K-MEANS CLUSTERING APPROACH TO CLASSIFY THE COVID-19 LUNG CT-SCAN IMAGE**. *IJISCS (International Journal of Information System and Computer Science)*, 5(3), 171-183.
- [11] Öztürk, Ş., Özkaya, U., & Barstuğan, M. (2020). **Classification of Coronavirus (COVID-19) from X-ray and CT images using shrunken features**. *International Journal of Imaging Systems and Technology*, 31(1), 5-15.

- [12] He, Xuai, Xingyi Yang. (2020). **Sample-Efficient Deep Learning for COVID-19 Diagnosis Based on CT.** *IEEE transactions on medical imaging*.
- [13] Alshazly, H., Linse, C., Abdalla, M., Barth, E., & Martinetz, T. (2021). **COVID-Nets: deep CNN architectures for detecting COVID-19 using chest CT scans.** *PeerJ Computer Science*, 7, e655.
- [14] Perumal,V., Narayanan, V., & Rajasekar, S. J. S. (2021). **Predction of COVID-19 with Computed Tomography Images using Hybrid Learning Techniques.** *Disease Markers*, 2021.
- [15] Shah, V. Keniya, R., Shridharani, A., Punjabi, M., Shah, J., & Mehendale, N. (2021). **Diagnosis of COVID-19 using CT scan images and deep learning techniques.** *Emergency radiology*, 28(3), 497-505.
- [16] Song, Y., Zheng, S., Li, L., Zhang, X., Zhang, X., Huang, Z., ... & Yang, Y. (2021). **Deep Learning Enables Accurate Diagnosis of Novel Coronavirus (COVID-19) with CT Images.** *IEEE/ACM transactions on computational biology and bioinformatics*. 18(6). 2775-2780
- [17] Naeem, H., & Bin-Salem, A. A. (2021). **A CNN-LSTM network with multi-level feature extraction-based approach for automated detection of coronavirus from CT scan and X-ray images.** *Applied Soft Computing*, 113, 107918.
- [18] Wang, Z., Liu, Q., & Dou, Q. (2020). **Contrastive cross-site learning with redesigned net for COVID-19 CT classification.** *IEEE Journal of Biomedical and Health Informatics*, 24(10), 2806-2813.
- [19] Jangam, E., & Annavarapu, C. S. R. (2021). **A stacked ensemble for the detection of COVID-19 with high recall and accuracy.** *Computers in Biology and Medicine*, 135, 104608.
- [20]Mouhafid, M., Salah, M., Yue, C., & Xia, K. (2022). **Deep Ensemble Learning-Based Models for Diagnosis of COVID-19 from Chest CT Images.** *Healthcare* 2022, 10, 166.
- [21] Helgason, S., & Helgason, S. (1999). **The radon transform** (Vol. 2). Boston: Birkhäuser.
- [22] Hsieh, J. (2009, November). **Computed tomography: principles, design, artifacts, and recent advances** . Bellingham, WA: SPIE.
- [23] Romans, L. (2018). **Computed tomography for technologists: a comprehensive text.** Lippincott Williams & Wilkins.

[24] [24] عمار، معن.(2016). **معالجة الصور الطبية.** ط: 2، دمشق: سوريا. ص:691.

- [25] Kimpe, T., & Tuytschaever, T. (2007). **Increasing the number of gray shades in medical display systems—how much is enough?**. *Journal of digital imaging*, 20(4), 422-432.
- [26] Fang, Y., Zhang, H., Xie, J., Lin, M., Ying, L., Pang, P., & Ji, W. (2020). **Sensitivity of chest CT for COVID-19: comparison to RT-PCR.** *Radiology*.
- [27] **<https://github.com/UCSD-AI4H/COVID-CT> 2020.**
- [28]Rathi, V. P., & Palani, S. (2012). **Brain tumor MRI image classification with feature selection and extraction using linear discriminant analysis.** *arXiv preprint arXiv:1208.2128*.
- [29]Karahaliou, A., Skiadopoulos, S., Boniatis, I., Sakellaropoulos, P., Likaki, E., Panayiotakis, G., & Costaridou, L. (2007). **Texture analysis of tissue surrounding microcalcifications on mammograms for breast cancer diagnosis.** *The British journal of radiology*, 80(956), 648-656.
- [30] Materka, A., & Strzelecki, M. (1998). **Texture analysis methods—a review.** *Technical university of lodz, institute of electronics, COST B11 report, Brussels*, 10(1.97), 4968.
- [31] Clausi, D. A. (2002). **An analysis of co-occurrence texture statistics as a function of grey level quantization.** *Canadian Journal of remote sensing*, 28(1), 45-62.
- [32] Huang, D., Shan, C., Ardabilian, M., Wang, Y., & Chen, L. (2011). **Local binary patterns and its application to facial image analysis:** a survey. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 41(6), 765-781.
- [33]Öztürk, Ş., & Akdemir, B. (2018). **Application of feature extraction and classification methods for histopathological image using GLCM, LBP, LBGLCM, GLRLM and SFTA.** *Procedia computer science*, 132, 40-46.
- [34]Albregtsen, F., Nielsen, B., & Danielsen, H. E. (2000, September). **Adaptive gray level run length features from class distance matrices.** In *Proceedings 15th International Conference on Pattern Recognition. ICPR-2000* (Vol. 3, pp. 738-741). IEEE.
- [35] Haralick, R. M., Shanmugam, K., & Dinstein, I. H. (1973). **Textural features for image classification.** *IEEE Transactions on systems, man, and cybernetics*, (6), 610-621.
- [36] Hsu, C. W., Chang, C. C., & Lin, C. J. (2003). **A practical guide to support vector classification.** *Department of Computer Science and Information Engineering, National Taiwan University, Taipei, Taiwan* (www.csie.ntu.edu.tw/~cjlin/papers/guide/guide.Pdf)

- [37] Fan, J., Lee, J., & Lee, Y. (2021). **A Transfer Learning Architecture Based on a Support Vector Machine for Histopathology Image Classification.** *Applied Sciences*, 11(14), 6380
- [38] Taunk, K., De, S., Verma, S., & Swetapadma, A. (2019, May). **A brief review of nearest neighbor algorithm for learning and classification.** In *2019 International Conference on Intelligent Computing and Control Systems (ICCS)* (pp. 1255-1260). IEEE.
- [39] J. Mahesh Kumar, & Rupalin Nanda. (2020). **Image Segmentation using K-means Clustering.** *International Journal of Advanced Science and Technology* Vol. 29, No. 6s, (2020), pp. 3700 – 3704
- [40] He, K., Zhang, X., Ren, S., & Sun, J. (2015). **Delving deep into rectifiers: Surpassing human-level performance on imagenet classification.** In *Proceedings of the IEEE international conference on computer vision* (pp. 1026-1034).
- [41] Baćanin Džakula, N. (2019). **Convolutional neural network layers and architectures.** In *Sinteza 2019-International Scientific Conference on Information Technology and Data Related Research* (pp. 445-451). Singidunum University
- [42] Wu, J. (2017). **Introduction to convolutional neural networks.** *National Key Lab for Novel Software Technology. Nanjing University. China*, 5(23), 495.
- [43] Sultana, F., Sufian, A., & Dutta, P. (2018, November). **Advancements in image classification using convolutional neural network.** In *2018 Fourth International Conference on Research in Computational Intelligence and Communication Networks (ICRCICN)* (pp. 122-129). IEEE.
- [44] Olah, C., & Carter, S. (2016). **Attention and augmented recurrent neural networks.** *Distill*, 1(9), e1.
- [45] Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). **Imagenet classification with deep convolutional neural networks.** *Advances in neural information processing systems*, 25.
- [46] Simonyan, K., & Zisserman, A. (2014). **Very deep convolutional networks for large-scale image recognition.** *arXiv preprint arXiv:1409.1556*.
- [47] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., ... & Rabinovich, A. (2015). **Going deeper with convolutions.** In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1-9).
- [48] Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). **Densely connected convolutional networks.** In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4700-4708).

- [49] He, K., Zhang, X., Ren, S., & Sun, J. (2016). **Deep residual learning for image recognition.** In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- [50] He, K., Zhang, X., Ren, S., & Sun, J. (2016). **Identity Mappings in Deep Residual Networks.** *arXiv preprint arXiv:1603.05027*.
- [51] Wu, J. (2017). **Introduction to convolutional neural networks.** *National Key Lab for Novel Software Technology. Nanjing University. China*, 5(23), 495.
- [52]Zafra, J. E., Moreno, R. J., & Hernández, R. D. (2017). **Comparison between Backpropagation and CNN for the Recognition of Traffic Signs.** *International Journal of Applied Engineering Research*, 12(17), 6814-6820.
- [53] Han, J. H., Choi, D. J., Park, S. U., & Hong, S. K. (2020). **Hyperparameter optimization using a genetic algorithm considering verification time in a convolutional neural network.** *Journal of Electrical Engineering & Technology*, 15(2), 721-726.
- [54]Tuba, E., Baćanin, N., Strumberger, I., & Tuba, M. (2021). **Convolutional Neural Networks Hyperparameters Tuning.** In *Artificial Intelligence: Theory and Applications* (pp. 65-84). Springer, Cham.
- [55] Zeiler, M. D. (2012). **Adadelta: an adaptive learning rate method.** *arXiv preprint arXiv:1212.5701*.
- [56] An, W., Wang, H., Zhang, Y., & Dai, Q. (2017, December). **Exponential decay sine wave learning rate for fast deep neural network training.** In *2017 IEEE Visual Communications and Image Processing (VCIP)* (pp. 1-4). IEEE.
- [57] Kanada, Y. (2016, July). **Optimizing neural-network learning rate by using a genetic algorithm with per-epoch mutations.** In *2016 International Joint Conference on Neural Networks (IJCNN)* (pp. 1472-1479). IEEE.
- [58] Bilbao, I., & Bilbao, J. (2017, December). **Overfitting problem and the over-training in the era of data: Particularly for Artificial Neural Networks.** In *2017 eighth international conference on intelligent computing and information systems (ICICIS)* (pp. 173-177). IEEE.
- [59]Tuba, E., Baćanin, N., Strumberger, I., & Tuba, M. (2021). **Convolutional Neural Networks Hyperparameters Tuning.** In *Artificial Intelligence: Theory and Applications* (pp. 65-84). Springer, Cham.
- [60] Bera, Somenath, and Vimal K. Shrivastava. **"Analysis of various optimizers on deep convolutional neural network model in the application of hyperspectral remote sensing image classification."** *International Journal of Remote Sensing* 41.7 (2020): 2664-2683.

- [61] Qian, N. (1999). **On the momentum term in gradient descent learning algorithms.** *Neural networks*, 12(1), 145-151.
- [62] Nesterov, Y. (1983). **A method for unconstrained convex minimization problem with the rate of convergence $O(1/k^2)$.** In *Doklady an ussr* (Vol. 269, pp. 543-547).
- [63] Duchi, J., Hazan, E., & Singer, Y. (2011). **Adaptive subgradient methods for online learning and stochastic optimization.** *Journal of machine learning research*, 12(7).
- [64] Li, P. (2017). **Optimization algorithms for deep learning.** Department of Systems Engineering and Engineering Management, The Chinese University of Hong Kong.
- [65] Kingma, D. P., & Ba, J. (2014). **Adam: A method for stochastic optimization.** *arXiv preprint arXiv:1412.6980*.
- [66] **<https://.kaggle.com/pla meneduardo/sarscov2-ctscan-datase>.**
- [67] Ying, X. (2019, February). **An overview of overfitting and its solutions.** In *Journal of Physics: Conference Series* (Vol. 1168, No. 2, p. 022022). IOP Publishing.
- [68] Hinton, G. E., Srivastava, N., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. R. (2012). **Improving neural networks by preventing co-adaptation of feature detectors.** *arXiv preprint arXiv:1207.0580*.
- [69] Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). **Dropout: a simple way to prevent neural networks from overfitting.** *The journal of machine learning research*, 15(1), 1929-1958.
- [70] Huynh, B. Q., Li, H., & Giger, M. L. (2016). **Digital mammographic tumor classification using transfer learning from deep convolutional neural networks.** *Journal of Medical Imaging*, 3(3), 034501.
- [71] Deng, J., Dong, W., Socher, R., Li, L. J., Li, K., & Fei-Fei, L. (2009, June). **Imagenet: A large-scale hierarchical image database.** In *2009 IEEE conference on computer vision and pattern recognition* (pp. 248-255). Ieee.
- [72] Hernández-García, A., & König, P. (2019). **Further advantages of data augmentation on convolutional neural networks.** In *International Conference on Artificial Neural Networks* (pp. 95-103). Springer, Cham.
- [73] Mikołajczyk, A., & Grochowski, M. (2018, May). **Data augmentation for improving deep learning in image classification problem.** In *2018 international interdisciplinary PhD workshop (IIPhDW)* (pp. 117-122). IEEE.

- [74] Özkaya, U., Öztürk, Ş., & Barstugan, M. (2020). **Coronavirus (COVID-19) classification using deep features fusion and ranking technique**. In *Big Data Analytics and Artificial Intelligence Against COVID-19: Innovation Vision and Approach* (pp. 281-295). Springer, Cham.
- [75] Fawcett, T. (2004). **ROC graphs: Notes and practical considerations for researchers**. *Machine learning*, 31(1), 1-38.
- [76] Yang, S., & Berdine, G. (2017). **The receiver operating characteristic (ROC) curve**. *The Southwest Respiratory and Critical Care Chronicles*, 5(19), 34-36

Syrian Arab Republic

Ministry of Higher Education and Scientific Research

Damascus University

Faculty of Mechanical and Electrical Engineering

Department of Electronics and Communication

Engineering



Developing of High Resolution Digital Image Classification Algorithm

A dissertation submitted in partial fulfillment of the requirements for the degree of Master in Applied Electronics Engineering

By

Eng. Iman Kabel

Supervised by

Dr. Eng. Talal Hamoud

Assistant Professor in the Department of Electronics and Communications Engineering

2021-2022