



RESEARCH ARTICLE - MANAGEMENT

Compare Some Classification Methods for COVID-19 Identification with Application

Rusul Mustafa Ismaiel^{1*}, Waleed Abdullah Araheemah¹

¹ Technical College of management - Baghdad, Middle Technical University, Baghdad, Iraq.

* Corresponding author E-mail: rusulmustafa388@gmail.com

Article Info.	Abstract
<p>Article history:</p> <p>Received 01 July 2022</p> <p>Accepted 30 August 2022</p> <p>Publishing 31 December 2022</p>	<p>The continuous increase in new cases of COVID-19 worldwide and the potential for disease outbreaks require new tools to assist health professionals in early diagnosis and monitoring of patients. Suffer from sources of noise that you were exposed to during filming or treatment. This paper presents a technique for diagnosing the (Covid-19) virus through deep learning and the use of classification techniques and its use to treat and try to identify the infection or not. Where 2000 photos of infected and non-infected COVID-19 were taken and the (BRISK +HARRIS) Probability density function (PDF) method was applied for the purpose of extracting image features, finding and preserving image qualities pure to extract image features find and preservextract the affected from the unaffected, as well as exclude other relevant influences and the results can be compared using other methods such as large binary models and hybrid models.</p>

This is an open access article under the CC BY 4.0 license (<http://creativecommons.org/licenses/by/4.0/>)

Publisher : Middle Technical University

Keywords: Medical Image; COVID-19 Detection; BRISK; HARRIS; Imaging Features; Probability Density Function.

مقارنة بعض الطرائق التصنيفية لتشخيص الإصابة بـ COVID-19 مع التطبيق

رسل مصطفى اسماعيل^{1*}، وليد عبد الله ارحيمه¹

¹ كلية التقنية الادارية -الجامعة التقنية الوسطى – بغداد – العراق

* البريد الإلكتروني: rusulmustafa388@gmail.com

معلومات المقالة	الخلاصة
تاريخ الاستلام 01 تموز 2022	تتطلب الزيادة المستمرة في حالات الإصابة الجديدة بـ COVID-19 في أنحاء العالم جميعاً وإمكانية تفشي الأمراض إلى أدوات جديدة لمساعدة المهنيين الصحيين في التشخيص المبكر ومراقبة المرضى ومن المعروف أن مصدر الصور الطبية مثل الأشعة السينية، والأشعة المقطعية، والتصوير بالرنين المغناطيسي) عانت وما تزال تعاني من مصادر الضوضاء التي تعرضت لها أثناء التصوير أو العلاج. تقدم هذه الورقة تقنية لتشخيص فيروس (كوفيد-19) من خلال التعلم العميق واستخدام تقنيات التصنيف واستخدامها لمعالجة ومحاولة التعرف على الإصابة من عدمها ولهذا الموضوع تأثير مستقبلي الاعتماد عليه لوضع آلية الشفاء. إذ تم اخذ 2000 صورة مصابين وغير مصابين COVID-19 وتم تطبيق طريقة (BRISK) ، (PDF) (HARRIS) Probability density function لغرض استخلاص سمات الصورة وإيجاد والحفاظ على صفات الصورة نقيه واستبعاد الضوضاء.
تاريخ النشر 31 كانون الاول 2022	تظهر النتائج القدرة على تفسير واستخراج المصاب من غير المصاب، وكذلك استبعاد التأثيرات الأخرى ذات الصلة، ويمكن مقارنة النتائج باستخدام طرق أخرى مثل النماذج الثنائية الكبيرة والنماذج الهجينة.

الكلمات المفتاحية: صور الطبية؛ كشف عن COVID-19؛ طرق اكتشاف الحواف BRISK؛ HARRIS؛ مميزات الصور؛ دالة كثافة الاحتمالية.

1. المقدمة

أدى انتشار مرض COVID-19 إلى مشاكل الاقتصادية وصحية يؤدي إلى انقراض الجنس البشري ولعل أهم السبل المواجهة تكون من خلال تشخيص المبكر لحالات الإصابة وإعطاء العلاج المناسب وفي سبيل ذلك جاء هذا البحث لمحاولة لتصبح كل هذه مشاكل. تقنية استخلاص السمات الصورية لأنها تقدم مميزات صورية وتأثيرات الضوضاء المصاحبة لعمليات الالتقاط الصور أو بعض عمليات المعالجة وفي سبيل ذلك اجريت العديد من الدراسات والبحوث السابقة المتقدمة التي فيها في عام 2019 قام الباحث Jiangtao Feng واخرون باستخدام خوارزمية كشف عن زاوية هاريس لإكتشاف نقاط ميزة الصورة الثابتة، هناك بعض المشاكل مثل انخفاض دقة التحديد المواقع والكشف عن مواضع الزوايا بدون واصف مميز وقد تم اقتراح هذه الخوارزمية الجديدة التي تقوم بالفحص الصورة مرتين ثم يتم استخدام Harris Corner ويتم تحسين موضع الزاوية عن طريق الخوارزمية التكرارية واستخراج السريع لثابت الدوران واظهرت النتائج ان الخوارزمية المقترحة تتغلب بشكل فعال على خوارزمية هاريس.

في عام 2019 قام الباحث Zhiyong Peng واخرون باستخدام خوارزمية كشف عن الحواف BRISK and ORB binary feature detection يتم الحصول على موقع الزاوية ويمكن الحصول على النقطة الزاوية الدقيقة وذلك من خلال اختبار (concise corner detection algorithm)CCDA مع خوارزمية الكشف عن الزوايا الكلاسيكية واظهرت النتيجة استخدام خوارزمية Brisk و CCDA لديها سرعة ودقة وقوة أفضل من خوارزمية HARRIS.

وفي عام 2021 قام Abolfazl Zargari Khuzani واخرون باستخدام التعلم الي لتشخيص الإصابة بمرض COVID-19 وان التشابه بين الميزات صور الأشعة السينية للمصاب بالمرض COVID.

Nomenclature			
BRISK	Binary Robust Invariant Scalable Keypoints	CNN	Convolutional neural network
ANN	Artificial neural networks	PDF	Probability density function

ومصاب بالمرض الالتهاب الرئوي يجعل التشخيص تأثر الأطباء صعباً لذلك استخدام المصنفات التعلم الآلي للتمييز الموثوق بين صور CXR بدقة عالية واستخراج المميزات الصورية وتصنيفها كل ميزة الى مجموعة بتقسيم مجموعة بيانات الصورة الأصلية عشوائياً إلى مجموعة تدريب (80)٪ ومجموعة اختبار (20) ٪. يشير إلى أن نموذج احتاج إلى وقت قصير يبلغ 15.4 ثانية لتعلم مجموعة التدريب و 2.03 ثانية للنتيجة للنتيجة اختبار واحدة.

1.1. مشكلة البحث

مشكلة البحث هناك ضوضاء مصاحبة للصورة الطبية، ومن الصعب الحكم على ما إذا كان الشخص مصاباً أم لا، وتتولد هذه الضوضاء نتيجة لتصوير أو التخزين أو المعالجة، مما يؤثر على ميزات الصورة المستخرجة، مما يتسبب في خطأ التشخيص أو تصنيف هذه الصورة للعودة إلى المصابين أو غير المصابين.

1.1. أهمية البحث

من المعلوم ان تشخيص الإصابة ب-covid-19 واستبعاد الضوضاء التي تصاحب الصورة من المواضيع المهمة لها اثر بالغ في تحديد العلاج الالتقاط الصورة والتشخيص الدقيق للإصابة.

1.3. هدف البحث

توظيف خوارزمية (BRISK،HARRIS) و PDF لاستخلاص بعض السمات الصورية وتصنيف هذه السمات من خلال استخدام الشبكات العصبية التي تساعد في تشخيص الإصابة واستبعاد الضوضاء المصاحبة عملية الالتقاط أو حتى عملية المعالجة.

2. الصور الرقمية (Digital Image) [5-1]

الصور الرقمية يتم تمثيل بياناتها كمصفوفة ثنائية الأبعاد إذ تتوافق كل بكسل مع قيمة سطوع الصورة عند نقطة محددة. إن كل عمود أو صف يسمى منتجاً واحداً وتكون الصورة أحادية اللون عادة ما تسمى بالصورة الأبيض والأسود ويوجد هناك أنواع عدة من بيانات الصورة التي يتم التعامل معها هي (1) ثنائية (2) الرمادي (3) الألوان (4) متعددة الاطراف.

2.1. صور الثنائية (Binary Images)

هي الصورة رقمية وتأخذ قيمتين لكل بكسل هما الأبيض 1 والأسود 0 يتم تمثيل عناصر الصورة الثنائية برقم ثنائي واحد (1 binary digit) مثال على هذا هو النصوص (text) وهي صور الكتابة في نظام ال-word.

2.2. الصور ذات التدرج الرمادي (gray scale image)

وهي صور تمثل الصور الأحادية اللون تتضمن الصور على معلومات عن اللعان فقط ولا تحتوي على معلومات عن اللون. تحدد مستويات اللعان على عدد البتات المخصصة لكل عناصر صورة. تتضمن الصور النموذجية لهذا النوع على 8 بتات لكل عنصر صورة الذي يعطينا 256 (0-255) مستوى مختلفاً من اللعان (gray levels).

2.3. الصور الملونة (color images)

يتمثل هذا النوع على شكل بيانات ثلاثة حزم أحادية اللون لكل حزمة لون. تمثل الصورة الملونة باستعمال ثلاثة حزم من الألوان هي الأحمر red، الأخضر green والأزرق blue التي تمتزج لتكون الصورة الملونة. إن كل عنصر صورة يكون مكوناً من 24 ثنائية (24 bits/pixels) (8 بت لكل حزمة لون الأحمر، الأخضر، والأزرق) وتسمى هذه الصور أحياناً بالصور ذات الألوان الحقيقية true images.

2.4. الصور ذات الطيف المتعدد (Multiscale images)

الصور ذات الطيف المتعدد يتضمن هذا النوع بيانات تحت الحمراء (infrared) والفرق البنفسجية (ultraviolet) وأشعة (x-ray) والبيانات الصوتية (acoustic) والرادارية. وهذه هي ليست صور حقيقية لا يمكن إدراكها تأثير الإنسان ولا توجد صيغة لمعلوماتها.

3. الضوضاء [6-8] (Noise)


هي معلومات غير مرغوب بها تحدث في قيم البكسل وتكون الضوضاء نتيجة انخفاض جودة الصورة وذلك بحدوث تأثيرات على الحواف غير واقعية والزوايا والخطوط غير مرئية. لتقليل الضوضاء غير المرغوب بها أو معالجتها وذلك بالتعلم المسبق لنماذج الضوضاء. نستخدم لتصميم وتوصيف نماذج الضوضاء وظيفة كثافة الاحتمال (pdf) سننكلم عن بعض نماذج الضوضاء منها:

3.1. نموذج ضوضاء غاوس (Gaussian Noise Model)

سميت الضوضاء الالكترونية لأنها تنشأ من مكبرات الصوت واجهزة كشف ضوضاء غاوس ناتجة من مصادر طبيعية مثل الاهتزاز الحراري للذرات الطبيعية المنفصلة لاشعاع الجسم الدافئ ضوضاء غاوس لها دالة كثافة احتمالية وتكرار معياري موضحة بالشكل (1).


$$p(a) = \sqrt{\frac{1}{2\pi\sigma^2}} e^{-\frac{(a-\mu)^2}{2\sigma^2}} \quad (1)$$

إذ إن a = قيمة gray
 μ = هي متوسط القيمة gray
 σ = هي الانحراف المعياري
 σ^2 = تباين لقيمة gray



الشكل (1) دالة الكثافة الاحتمالية للضوضاء (Gaussian) [8]

سبب هذه العشوائية المتساوية، يبدو منحني الضوضاء الغاوسي الطبيعي في شكل جرس. هذا أن قيم البكسل الصاخبة من 70 إلى 90٪ للصورة المتدهورة بينهما $(\mu-\sigma)$ و $(\mu+\sigma)$ شكل الرسم البياني الطبيعي هو نفسه تقريباً في المجال الطبيعي. يفترض غالباً بشكل خطأ أن ضوضاء غاوس هي ضوضاء البيضاء وذلك لأن يتم توزيع القيم غاوس لأنها تشير الى طريقة الرمادية، بينما تشير ضوضاء البيضاء الى عدم وجود ارتباط بين قيم البكسل. كمية العشوائية هذه تؤدي الى وجود الترددات جميعاً في الوقت نفسه اي يكون طيف الطاقة المسطحة كما موضحة بالشكل (2).




شكل (2) يمثل ضوضاء كاوس وضوضاء كاوس مع اضافة المرشح المعدل

3.2. ضوضاء الفوتون (Photon Noise (Poisson Noise))

ضوضاء الفوتون، والمعروفة أيضاً باسم ضوضاء بواسون، هي شكل أساس من عدم اليقين المرتبط بقياس الضوء، متأصل في الطبيعة الكمية للضوء واستقلال الكشف عن الفوتونات حجمها المتوقع يعتمد على الإشارة ويشكل المصدر المهيمن لضوضاء الصورة باستثناء الإضاءة المنخفضة. يتعامل مع اكتشافات الفوتون الفردية على انها احداث مستقلة تتبع توزيعاً زمنياً عشوائياً نتيجة لذلك يعد الفوتون شكل من اشكال poisson الكلاسيكية العملية وعدد الفوتونات يقاس بعنصر المستشعر معين خلال مدة زمنية خلال التوزيع الاحتمالي المنفصل وتخضع لتوزيع بواسون شكل (3) يوضح تأثير الضوضاء فوتون على الصور الطبية.


$$(k) = \frac{\lambda^k e^{-\lambda}}{k!} p(f_{(pi)}) \quad (2)$$



شكل (3) يمثل تأثير ضوضاء فوتون على الصور الطبية

3.3 ضوضاء الملح والفلفل Salt and pepper noise/Impulse noise

تسمى ضوضاء الملح والفلفل ضوضاء الاندفاع أو الضوضاء الموزعة. يتشكل في الصورة عند التقاط الصورة تظهر في الصورة أثناء التحويل من التناظرية إلى الرقمية. ربما نظراً لقيود الأجهزة، سيكون هناك تأخير في المعالجة وضوضاء في الكاميرا. صغيرة وحادة بالأسود والأبيض تتشكل النقاط في الصورة، والمعروفة باسم ضوضاء الملح والفلفل. الصورة مع ضوضاء الملح والفلفل ستكون بكسلات قاتمة في المناطق الساطعة التي تحتوي على القيمة 0 منخفضة جداً، وتحتوي وحدات البكسل الساطعة في المناطق المظلمة على قيمة 1 عالية جداً. تظهر الضوضاء في الصورة ناتجة عن تغيرات حادة ومفاجئة في إشارة الصورة كما موضح في الشكل (4). القيم النموذجية لضوضاء الفلفل هي 0 وضوضاء الملح 255 للصور ذات 8 بت.



شكل (4) يمثل تأثير الصور الطبيه بوضواء الملح والفلفل

4. استخراج الميزات [12-9] Feature extraction

وهي عملية التوصيف والتمثيل للصورة الأصلية على شكل مبسط لتسهيل عملية اتخاذ القرار واكتشاف انماط وتصنيف الصورة. ويمثل الحصول على الميزات الموثوقة واستخراجها امرا مهما وضروريا من اجل التعرف على الصور ورؤية الحاسوب، سنتكلم عن بعض الميزات منها:

4.1. كاشف زاوية هاريس The Corner Detector

هو كاشف للزوايا يستخدم بشكل شائع في خوارزميات رؤية الحاسوب لاستخراج الميزات الصورة يعمل الكاشف تحديد المنطقة المسطحة او الحافة او زاوية اذا تم العثور على زاوية فسيكون هناك تغيير كبير بالشدة في الاتجاهات جميعاً واذا كانت حافة فلن يظهر اي تغيير في الشدة. واكتشاف النقاط المهمة ويكتشف المزيد من ميزاتها ثبات الدوران ومقياس المتغيير واختلاف الاضاءة وضوء الصورة ويعتمد الكاشف على قياس وظيفة الارتباط التلقائي للمتغيرات الزوايا البارزة والمهمة ويمكن وصفها بالمعادلة ادناه:

$$E(u,v) = \sum_{x,y} w(x,y) [I(x+u,y+v)I(x,y)]^2 \quad (3)$$

E = هو الفرق بين النافذة الأصلية والنافذة المنقولة.

u = هي إزاحة النافذة في اتجاه x.

v = هي إزاحة النافذة في الاتجاه y.

w(x,y) = هي النافذة الموجودة في الموضع (x,y). التأكد من استخدام النافذة المطلوبة فقط.


I = هو شدة الصورة في موضع (x,y).

I(x+u,y+v) = هي شدة النافذة المتحركة.

I(x,y) = هي شدة الأصل.

4.2 BRISK (Binary Robust Invariant Scalable Keypoints)

هي خوارزمية لاكتشاف النقاط ووصفها مع ثوابت النطاق وثبات الدوران تتضمن خوارزمية BRISK ثلاث وحدات رئيسية: الكشف عن نقطة المفاتيح، ووصف النقطة الأساسية ومطابقة الواصف. أولاً، تم بناء مقياس الهرم الفضائي، والنقاط المتطرفة المستقرة من دقة البكسل الفرعي في مساحة المقياس المستمر يتم استخلاصها بواسطة AGAST (الزاوية التكيفية عامل الكشف) بعد ذلك، يتم إنشاء واصف الميزة الثنائية للصورة المحلية باستخدام علاقة المقياس الرمادي لأزواج نقطة العينة العشوائية في جوار الصورة المحلية. أخيراً، يتم استخدام مسافة هامنج لمطابقة الميزة. لذا اقترحت (BRISK) للعمل بهذه المنهجية. الشكل (5) يوضح مفاتيح نقاط التوضيح لخوارزمية (BRISK) على وفق اسلوب معاينة.



الشكل (5) مفاتيح نقاط التوضيح لخوارزمية (BRISK) [16]

4.3. Probability density function [13]

دالة كثافة الاحتمال (PDF) هي تعبير إحصائي يحدد التوزيع الاحتمالي (احتمالية وجود نتيجة) لمتغير عشوائي منفصل بدلاً من متغير عشوائي مستمر.

4.3.1 Extreme value distribution

يتكون توزيع من معلمات ووصف نموذج وبيانات نموذجية لتوزيع احتمالية القيمة القصوى. يعد توزيع القيمة القصوى مناسباً لنمذجة أصغر قيمة من التوزيع الذي تتحلل أطرافه بسرعة كبيرة، على سبيل المثال، التوزيع الطبيعي. يمكنه أيضاً نمذجة أكبر قيمة من التوزيع، مثل التوزيعات العادية أو الأسية، باستخدام القيمة السالبة للقيم الأصلية. كما موضح في الشكل (6).

μ: تمثل معلمة الموقع (location parameter)

β: تمثل معلمات القياس (Scale Parameters)

$$f(x) = \frac{1}{\beta} * e^{\frac{x-\mu}{\beta}} * e^{-e^{\frac{x-\mu}{\beta}}} \quad (4)$$


4.4. توزيع الاسي (Exponential distribution)

توزيع احتمالي مستمر يشتق اسمه من الدالة الأسية. يستخدم هذا التوزيع لتقدير الفاصل الزمني بين الأحداث في عملية بواسون، غالباً ما تستخدم التوزيعات الأسية في مشاكل الزمن، ويعمل على التجانس الصور وتعديلها. يوضح شكل (7) التوزيع الاسي


X: يمثل المتغير العشوائي

$$f(x; \lambda) = \lambda e^{-\lambda x} \quad (5)$$

إذ إن $\lambda > 0$ وهو ثابت التوزيع



شكل (6) يمثل توزيع القيمة القصوى Extreme value distribution [2]



شكل (7) يمثل توزيع الاسي Exponential distribution [2]

5. مرشحات الصورة [14-15] Spatial Image Filters

وهي عملية يمكننا من خلالها تغيير خصائص الصورة الضوئية عن طريق إزالة انتقائية لبعض الترددات المكانية التي تشكل كائنًا، على سبيل المثال، تصفية بيانات الفيديو الواردة من الأقماع الصناعية والمسابر الفضائية، أو إزالة البيانات النقطية من الصور التلفزيونية أو الصور الممسوحة ضوئيًا.

5.1. مرشح وينر Wiener Filter

مرشح Wiener هو مرشح يستخدم لإنتاج تقدير لعملية عشوائية مرغوبة أو مستهدفة عن طريق ترشيح خطي ثابت للوقت (LTI) لعملية ضوضاء ملحوظة، بافتراض إشارة ثابتة معروفة وأطياف ضوضاء، وضوضاء إضافية. يقلل مرشح Wiener متوسط الخطأ التربيعي بين العملية العشوائية المقدرّة والعملية المطلوبة. تتكون إشارة الإدخال $x(n)$ ، ضوضاء $v(n)$.

$$x(n) = d(n) + v(n)$$

(5)

الهدف من مرشح وينر هو التصفية الضوضاء التي أفسدت إشارة. لأنه يقوم على النهج الإحصائي. تم تصميم المرشحات النموذجية لاستجابة التردد المطلوب. مرشح وينر منهجه التصفية من زاوية مختلفة. هو من المفترض أن يكون لديك معرفة بالخصائص الطيفية لإشارة الأصلي والضوضاء، تصفية الإخراج الذي سيأتي أقرب إلى الأصل إشارة ممكنة. تتميز مرشحات وينر من خلال ما يلي:

- الافتراض: الإشارة والضوضاء (المضافة) ثابتة العمليات العشوائية الخطية مع الطيفية المعروفة الخصائص.
- المتطلبات: يجب أن يكون المرشح قابلاً للتحقيق فعليًا، أي السببية (يمكن إسقاط هذا الشرط، مما أدى في حل غير سببي).
- معايير الأداء: الحد الأدنى لخطأ متوسط مربع.

5.2. مرشح الوسط Mean filtering

يعد الترشيح المتوسط طريقة بسيطة وبديهية وسهلة التنفيذ لتنعيم الصور، أي تقليل مقدار تباين الكثافة بين بكسل واحد والآخر، غالبًا ما يستخدم لتقليل التشويش في الصور. فكرة التصفية المتوسطة هي ببساطة استبدال كل قيمة بكسل في الصورة بمتوسط ("mean") قيمة جيرانها، بما في ذلك نفسها. هذا له تأثير القضاء على قيم البكسل التي لا تمثل محيطها. يعد الترشيح الوسيط عمومًا مرشحًا جانبيًا. مثل التلافيفات الأخرى، فهي تعتمد على النواة، التي تمثل شكل وحجم المتجاورات المراد أخذ عينات منه عند حساب المتوسط. عادةً ما يتم استخدام قلب مربع 3×3 ، كما هو موضح في الشكل (8)، ولكن يمكن استخدام خرز أكبر (مثل مربع 5×5) للحصول على تجانس أكثر حدة. (لاحظ أنه يمكن تطبيق النواة الصغيرة مرات عدة للحصول على تأثير مماثل، ولكن ليس التأثير نفسه، على مسار واحد للنواة الكبيرة).

$\frac{1}{9}$	$\frac{1}{9}$	$\frac{1}{9}$
$\frac{1}{9}$	$\frac{1}{9}$	$\frac{1}{9}$
$\frac{1}{9}$	$\frac{1}{9}$	$\frac{1}{9}$


شكل (8) يمثل مصفوفة Mean filtering

6. الشبكات العصبية الاصطناعية [20-16]

هي تقنية حاسوبية تهدف إلى محاكاة الطريقة التي يؤدي بها الدماغ البشري مهامًا محددة باستخدام التوزيع المستمر على نطاق واسع لوحدة المعالجة التي تتكون من وحدات معالجة بسيطة. هذه الوحدات عبارة عن عناصر حسابية تسمى الخلايا العصبية، العقد، التي لها خصائص عصبية لتخزين المعرفة العلمية والمعلومات التجريبية، وإتاحتها للمستخدمين عن طريق ضبط الأوزان. تتكون الشبكة العصبية الاصطناعية (ANN) من طبقات من العقد، بما في ذلك طبقة الإدخال وطبقة مخفية واحدة أو أكثر وطبقة إخراج. كل عقدة أو خلية عصبية اصطناعية متصلة بعقدة أخرى ولها حمل واحد مرتبط بها. إذا كان ناتج أي عقدة مفردة أعلى من حد معين، يتم تنشيط تلك العقدة، وإرسال البيانات إلى الطبقة التالية من الشبكة. خلاف ذلك، لن يتم تمرير أي بيانات إلى الطبقة التالية من الشبكة. شكل (9) يمثل طبقات الشبكة العصبية.

يتكون العصبون في الشبكة العصبية الاصطناعية من:

1. اشارات ادخال (input): $x_1, x_2, x_3, x_4, \dots, x_p$.
2. قوى الاوزان (Weights): $w_{k1}, w_{k2}, w_{k3}, w_{k4}, \dots, w_{kp}$ إذ يعبر الوزن عن شدة الترابط بين عنصر قبله وعنصر بعده.
3. عنصر المعالجة (Processing Element):
وهذا العنصر ينقسم الى قسمين:
أ. الجامع (Adder): لجمع الاشارات في المدخلات الموزونة.
ب. تابع النقل او تابع التفعيل (Activation Function):
وهذا التابع يحد من اخراج العصبون اي يجعل الاخراج بين مجال محدد لذا يسمى تابع التخميد (Squashing) إذ يجعل الاخراج ضمن المجال [1, 0] او [1, -1] وله ثلاثة أنواع هي (تابع الخطوة، التابع الخطي، التابع الاسي).
4. الاخراج (output): y_k .



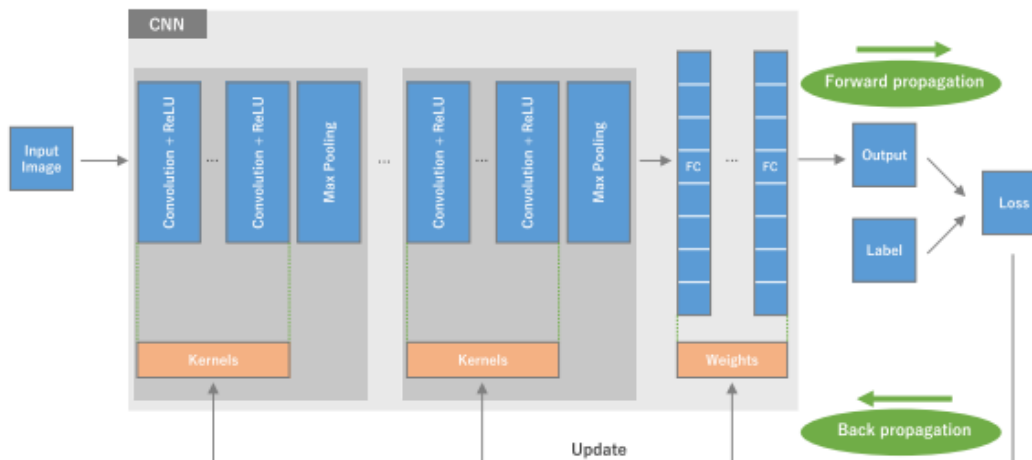
شكل (9) يمثل مكونات العصبون [19]

6.1 الشبكة العصبية التلافيفية (CNN) Convolutional neural network

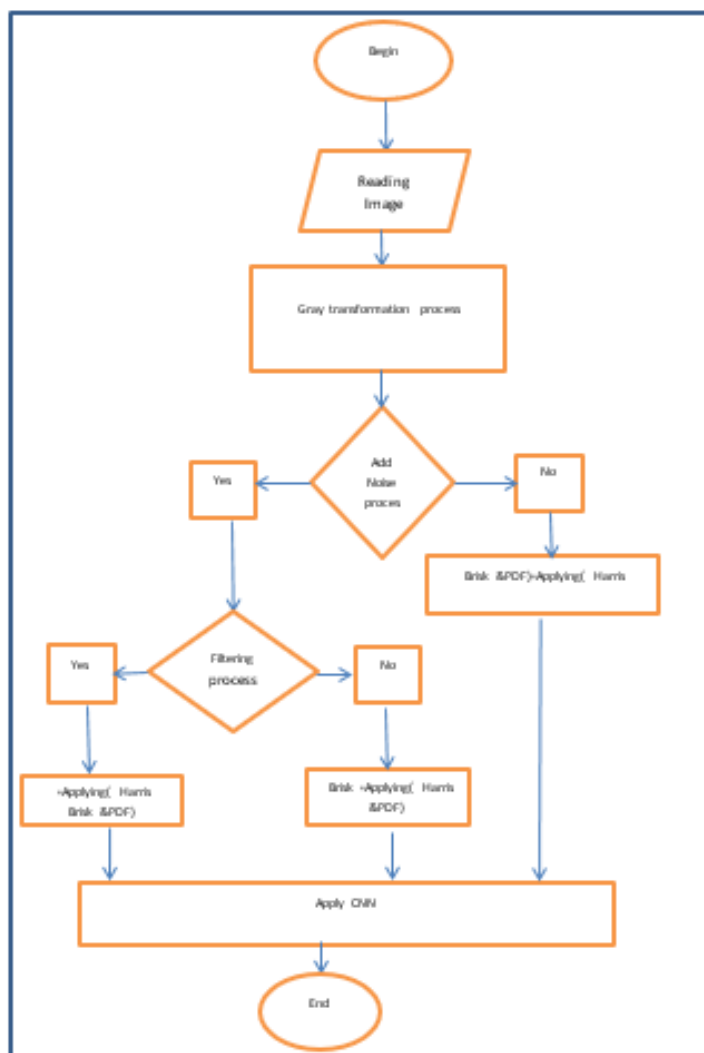
وهي فئة من الشبكات العصبية الاصطناعية التي أصبحت مهيمنة في رؤية الكمبيوتر المختلفة المهام، تجذب الاهتمام عبر مجموعة متنوعة من المجالات، بما في ذلك الأشعة. تم تصميم CNN بشكل تلقائي وقابل للتكيف تعلم التسلسل الهرمي المكاني للميزات من خلال الانتشار العكسي باستخدام كتل بناء متعددة، مثل طبقات الالتفاف، طبقات التجميع والطبقات المتصلة بالكامل. تقدم مقالة المراجعة هذه وجهة نظر حول المفاهيم الأساسية لشبكة CNN و CNN تطبيق على المهام الإشعاعية المختلفة، وناقش تحدياتها والتوجهات المستقبلية في مجال الأشعة. اثنين ستم أيضًا تغطية التحديات في تطبيق CNN على المهام الإشعاعية ومجموعة البيانات الصغيرة والتجهيز الزائد في هذه المقالة، فضلًا عن تقنيات لتقليلها. التعرف على المفاهيم والمزايا، وكذلك القيود، من CNN أمر ضروري الاستفادة من إمكاناتها في الأشعة التشخيصية، بهدف زيادة أداء أطباء الأشعة وتحسين رعاية المريض وشكل (10) يوضح عمل الشبكة العصبية التلافيفية.

7. العمل المقترح The Suggested Work

تضمن البحث عملاً مقترحاً لتصنيف الصور الرقمية إلى مصابة وغير مصابة عن طريق إدخال صورة وتحويلها إلى مقياس رمادي، ثم إضافة ضوضاء وإجراء عملية تصفية للصورة الناتجة وتطبيق طريقة (Harris and Brisk) واستخدام (Probability density function) على كل من الصورة العادية والصورة بالضوضاء والصورة بالفلتر كل ما سبق يطبق على الصور للبحث وتطبيق طريقة التعلم العميق لغرض تصنيف الصور واستخراج متوسط المربعات لخطأ التصنيف. كما الموضح في الشكل (11).




شكل (10) يوضح عمل الشبكة العصبية التلافيفية [20]



شكل (11) يوضح العمل المقترح

7.1. بيانات البحث

تمثلت بيانات بعدد من الصور الطبية للمفراز الحلزوني لعدد (2000) صورة مصاب مرض covid-19 وغير مصاب لمنطقة الصدر والشكل (12) يوضح عينة من صور البحث كل صورة مكونة تصل الى (224 × 224) عنصرًا بيانيًا.



شكل (12) يمثل صور للمصابين وغير المصابين
مصاب غير مصاب

8. تحليل النتائج

تم إجراء العديد من التجارب لتقييم التقنية المقترحة. في التجارب جميعاً، قدم النظام مجموعة بيانات من الصور التي تم إجراؤها في التدريب، عن طريق أخذ 80% عشوائياً للتدريب و 20% للاختبار.

في التجربة الأولى، بحسب الدقة بدون استخدام المرشحات وبدون اضافة ضوضاء. يتم عرض نتائج هذه التجربة في الجدول 1. ويمكن ملاحظة أن التقنية المقترحة حققت معدل تمييز عالي (98%) في التجربة الثانية، تم اضافة الضوضاء واستخدام الفلاتر في مرحلة المعالجة المسبقة وتم حساب الدقة لطرق مختلفة عدة وكانت تجربة باستخدام التوزيع الاسي وهارس وبريسك اقل بمعدل (0.97) و (0.95) و (0.96) وقد أشارت هذه النتائج إلى أن استخدام المرشح الوسط في حالة اضافة ضوضاء فوتون حقق معدل دقة عالية مما يؤدي إلى زيادة سرعة التقنية المقترحة. يمكن ان تكون الدقة مقارنة عند استخدام ضوضاء كاوس، وعند استخدام مرشح وينر تتأثر الدقة بشكل طفيف بينما في حالة اضافة ضوضاء الملح والفلل عند استخدام المرشحين الوسط ومرشح وينر تتأثر الدقة بدرجة ملحوظة و، وذلك لأنه في ضوضاء الملح والفلل تكون لها تاكثير على الصورة تكون إشارة الصورة ضعيفة للغاية. كما موضح بالجدول (1).

الجدول (1) يمثل الدقة بعد استخدام دالة الكثافة الاحتمالية وطريقتي Brisk و Harris

البيانات	توزيع القيمة القصوى Extreme value	توزيع الاسي Exponential	طريقة Harris	طريقة Brisk	
الصور الطبيعية	0.98	0.97	0.95	0.96	
ضوضاء فوتون	مرشح الوسط	0.95	0.94	0.95	0.97
	مرشح وينر	0.92	0.91	0.92	0.89
ضوضاء كاوس	مرشح الوسط	0.94	0.91	0.94	0.90
	مرشح وينر	0.91	0.90	0.91	0.86
ضوضاء الملح والفلل	مرشح الوسط	0.89	0.89	0.93	0.86
	مرشح وينر	0.92	0.89	0.92	0.89

8. الاستنتاجات والاقتراحات

- عند تطبيق العمل المقترح على بيانات البحث الخاصة بصور الطبية عدد من الاستنتاجات والاقتراحات مثل:
- تأثرت عمليات التصنيف بنماذج الضوضاء ونوع مرشح الصورة المستخدم، وكانت أفضل عمليات التصنيف للبيانات الطبيعية تنخفض دقة كل من هارس وبريسك في حالة وجود ضوضاء في حين تكون طريقة (pdf) ذات تأثير بسيط جداً.
 - تباين نتائج التحسين من ناحية المرشحات والمعروفة بتفوق مرشح الوسط على باقي المرشحات لتقدمه نتائج أفضل من البقية.
 - للصور الطبيعية أظهرت النتائج تفوق طريقة (pdf) (Extreme value).
 - هنالك تقارب بين النتائج (pdf) لكل من التوزيع الاسي وتوزيع القيم القصوى.
 - استخدام نماذج (pdf) اخرى (Gumbol) الاعظم والاقبل ومقارنة النتائج التصنيف النهائي.
 - دراسة تغيير حجم الصورة وذلك لزيادة او نقصان الحجم وتأثير ذلك على الدقة تصنيف للمرض.
 - زيادة عدد الصور المعتمدة وملاحظة مدى تأثير نتائج التصنيف عند زيادة الاعداد الصور وصولاً للاستقرار للنتائج.

References

- [1] L. Shapiro, Computer vision and image processing. Academic Press, 1992.
- [2] R. Jain, R. Kasturi, and B. G. Schunck, Machine vision. McGraw-hill New York, 1995.
- [3] R. C. González, "REW Digital Image Processing," ed: Prentice Hall, 2008.
- [4] W. Burger, M. J. Burge, M. J. Burge, and M. J. Burge, Principles of digital image processing. Springer, 2009.
- [5] W. Burger and M. J. Burge, "Digital images," in Digital Image Processing: Springer, 2016, pp. 1-21.
- [6] G. Dougherty "Digital Image Processing for Medical Applications," second ed., Cambridge university press, (2010)
- [7] Hasinoff, Samuel W. "Photon, Poisson Noise." (2014): 608-610.
- [8] Kassam, Saleem A. Signal detection in non-Gaussian noise. Springer Science & Business Media, 2012.
- [9] Leutenegger, Stefan, Margarita Chli, and Roland Y. Siegwart. "BRISK: Binary robust invariant scalable keypoints." 2011 International conference on computer vision. Ieee, 2011.
- [10] E Heba Ahmed, Nourhan Mohamed Zayed, and Mahmoud Abdelmoneim Fakhreldein. "Feature extraction techniques: fundamental concepts and survey." Handbook of research on emerging perspectives in intelligent pattern recognition, analysis, and image processing. IGI Global, 2016. 264-294

- [11] Kale, Pranoti, and K. R. Singh. "A Technical Analysis of Image Stitching Algorithm Using Different Corner Detection Method." *International Journal of Innovative Research in Computer and Communication Engineering* 3.4.(2015)
- [12] Derpanis, Konstantinos G. "The harris corner detector." *York University* 2 (2004).
- [13] M. William, Robert J. Beaver, and Barbara M. Beaver. *Introduction to probability and statistics*. Cengage Learning, 2012.
- [14] Kumar, Suresh, et al. "Performance comparison of median and wiener filter in image de-noising." *International Journal of Computer Applications* 12.4 (2010): 27-31.
- [15] Forshult, Stig E. "Magnetic Resonance Imaging–MRI–An Overview." (2007).
- [16] A. D., Dongare, R. R. Kharde, and Amit D. Kachare. "Introduction to the artificial neural network." *International Journal of Engineering and Innovative Technology (IJEIT)* 2.1 (2012): 189-194.
- [17] Yuwono, Bambang. "Image Smoothing Menggunakan Mean Filtering, Median Filtering, Modus Filtering dan Gaussian Filtering." *Telematika: Jurnal Informatika dan Teknologi Informasi* 7.1 (2015).
- [18] Peng, Zhiyong, Jun Wu, and Guoliang Fan. "CCDA: a concise corner detection algorithm." *Machine Vision and Applications* 30.6 (2019): 1029-1040.
- [19] Kukreja, Harsh, et al. "An introduction to the artificial neural network." *Int J Adv Res Innov Ideas Educ* 1 (2016): 27-30.
- [20] Yamashita, Rikiya, et al. "Convolutional neural networks: an overview and application in radiology." *Insights into imaging* 9.4 (2018): 611-629.