

دراسة مقارنة ونموذج هجين (CNN+SIFT) للكشف عن أنماط الأمراض الصدرية في الصور الطبية

د. فادي متوج*

م. احمد قره علي**

(تاريخ الإيداع ٢٣/٩/٢٠٢٥ . قُبل للنشر في ٢٤/١١/٢٠٢٥)

□ ملخص □

لقد نجح التعلم العميق بشكل كبير في تشخيص العديد من الأمراض اعتماداً على الصور الطبية . حيث باتت تطبيقات التعلم العميق المختلفة والمستخدمه لتشخيص الأمراض بناءً على الصور الطبية - على اختلاف أنواعها - أحد النقاط البحثية الهامة في مجال الذكاء الاصطناعي والرؤية الحاسوبية. يجب أن تتميز نماذج الذكاء الاصطناعي المستخدمة في تشخيص الأمراض اعتماداً على الصور الرقمية بالدقة العالية والسرعة في تحليل النتائج ، بالإضافة إلى ذلك، من الضروري الأخذ بعين الاعتبار الخصوصية والتعقيد المتأصلين في التصوير الطبي. يهدف هذا البحث إلى إجراء اختبار وتقييم نماذج الشبكات العصبية التي يمكن استخدامها للتعرف على الأمراض في الصور الطبية، حيث تم إجراء دراسة نماذج الشبكات العصبية المتقدمة التي ظهرت في السنوات الأخيرة، وبصورة رئيسية نموذج الشبكة العصبية الالتفافية CNN(Convolutional Neural Network)، من أجل الكشف عن ثلاثة أمراض في الصور الطبية وهي السرطان، والسل ، والكورونا CoVID19. اعتمدت الدراسات السابقة على تحليل عدة نماذج من الشبكات العصبية من أجل تحسين سرعة ودقة البحث لأحد أنواع الأمراض الثلاثة. بالمقابل تعتمد الدراسة المقترحة على إجراء تقييم وتطوير بهدف لبناء نموذج شبكة عصبية قادر على كشف عدة أمراض في الصور الطبية بحيث يتمتع النموذج الناتج بالدقة العالية بالإضافة إلى السرعة في عملية التنبؤ وقد أظهر النموذج نتائج جيدة في تصنيف الصور. حيث بلغت دقة النموذج المستخدم في شبكة AlixNET بحدود ٨٨% وفي نموذج شبكة Resnet بلغت الدقة ٩٢,٨% وفي نموذج شبكة U-net كانت الدقة ٨٩% وفي نموذج الشبكة الهجين المقترح بعد استخدام خوارزمية SIFT كانت الدقة ٩٤%.

الكلمات المفتاحية: تشخيص طبي، الذكاء الاصطناعي، الصورة الطبية، الشبكة العصبية العميقة، التعلم العميق، كشف السرطان، صور شعاعية

* استاذ مساعد، قسم الميكاترونك، كلية الهندسة الميكانيكية والكهربائية، جامعة اللاذقية، سوريا . fadimotawej@latakia-univ.edu.sy

**طالب ماجستير، قسم الميكاترونك، كلية الهندسة الميكانيكية والكهربائية، جامعة اللاذقية، سوريا.

ahmad.qaraali311@latakia-univ.edu.sy

A comparative study and a hybrid model (CNN+SIFT) for detecting chest disease patterns in medical images

Dr. Fadi Motawej*
Ahmad Qara Ali**

(Received 23/9/2025 . Accepted 24/11/2025)

□ ABSTRACT □

Deep learning has been highly successful in diagnosing numerous image-based disease models. Various deep learning applications used to diagnose diseases based on various types of medical images have become a hotspot of research in the fields of artificial intelligence and computer vision. Due to the rapid development of deep learning methods, diagnosing disease models based on digital images requires extremely high accuracy and timeliness. Furthermore, it is necessary to consider the inherent privacy and complexity of medical imaging. This research aims to test and evaluate deep learning models and classical pre-trained models. Advanced neural network models that have emerged in recent years, primarily convolutional neural network models (CNN), were studied to detect three disease models in medical images: cancer, tuberculosis, and COVID-19. Each of these disease models has a specific distribution pattern within medical images. Studies have relied on analyzing multiple neural network models to improve the speed and accuracy of searching for one of the three disease models. The proposed study, in contrast, relies on an evaluation and development process to build a neural network model capable of detecting multiple disease patterns in medical images. The resulting model offers high accuracy and predictive speed.

The model has demonstrated good results in image classification. The model used in the AlixNET network succeeded with an accuracy of about 88%, in the Resnet network model it achieved an accuracy of 92.8%, in the U-net network model the accuracy was 89%, and in the proposed hybrid network model after using the SIFT algorithm the accuracy was 94%.

Keywords: Medical diagnosis, artificial intelligence, medical images, deep neural networks, deep learning, cancer detection, radiological images

* Postgraduate student, Department of Mechatronics, Mechanical and electrical Faculty, Lattakia university, Syria. ahmad.qaraali311@latakia-univ.edu.sy

** Professor, Department of Mechatronics, Mechanical and electrical Faculty, Lattakia University, Syria fadimotawej@latakia-univ.edu.sy

١ - مقدمة:

في الوقت الحاضر، يعتمد تشخيص الأمراض الطبية بشكل رئيسي على التشخيص التصويري والتشخيص المرضي (السريري) [١,٢]. وفي هذه الحالة، يعد الاكتشاف المبكر هو المفتاح لتحسين معدل البقاء على قيد الحياة للمرضى [٣]؛ أصبح الفحص المبكر غير الجراحي والفعال موضوعاً بحثياً أساسياً. حيث تشمل تقنيات التصوير الموجات فوق الصوتية، والأشعة السينية، والتصوير المقطعي المحوسب (CT (Computed Tomography))، والتصوير بالرنين المغناطيسي (MRI (Magnetic Resonance Imaging))، وما إلى ذلك. [٤]. ومن خلال هذه التقنيات يمكن رؤية بعض الأعراض المرضية بالجسم. على سبيل المثال، يمكن الكشف عن الظل في الرئتين عن طريق التصوير المقطعي، والذي يمكن أن يحدد ما إذا كان من أعراض سرطان الرئة [٥,٦]. كما يمكن استخدام التصوير بالرنين المغناطيسي للمساعدة في تشخيص وتمييز سرطان البلعوم الأنفي، بالإضافة إلى أنه يمكن استخدامه أيضاً لتقييم مدى آفة السرطان: أي ما إذا كانت تشمل الأنسجة الرخوة والعظام المحيطة وما إذا كان هناك ورم خبيث في العقد الليمفاوية القريبة [٧]. يمكن العثور على عقيدات أو كتل بأحجام مختلفة في الغدة الدرقية من خلال فحص الموجات فوق الصوتية B ويمكن أيضاً ملاحظة حجم الورم وشكله وموقعه وحدوده بشكل مباشر في الغدة الدرقية من خلال الموجات فوق الصوتية B [٨]. في الوقت الحالي باتت أجهزة التصوير الطبية تستخدم في العديد من المجالات فاتحة المجال لكميات كبيرة من البيانات الطبية والحالات المرضية المقابلة لها، ولذلك، فإن تشخيص الأمراض اعتماداً على الصور الطبية له العديد من أوجه القصور، مثل عبء العمل الثقيل، وانخفاض الكفاءة، وارتفاع معدل التشخيص الخاطئ.

تتمتع الخوارزميات القائمة على التعلم العميق بمزايا أعلى مقارنة بالبشر في معالجة البيانات الكبيرة والبيانات المعقدة غير المؤكدة بالإضافة إلى التحليل المعمق في المعلومات المحتملة في البيانات [٩]. إن استخدام التعلم العميق لتفسير الصور الطبية يمكن أن يساعد الأطباء في تحديد مكان الآفات، والمساعدة في التشخيص، وتخفيف العبء على الأطباء، وتقليل الأحكام الطبية الخاطئة، وتحسين دقة وموثوقية التشخيص ونتائج التنبؤ. تم تطبيق تقنيات التعلم العميق بنجاح في مختلف المجالات من خلال الصور الطبية والإشارات الفيزيولوجية. أظهرت النماذج العميقة أداءً ممتازاً في العديد من المجالات، مثل تصنيف الصور الطبية وتقسيمها واكتشاف الآفات وتسجيلها [١٠,١١]. كما تم استخدام أنواع مختلفة من الصور الطبية، مثل صور الأشعة السينية والتصوير بالرنين المغناطيسي والتصوير المقطعي وما إلى ذلك، لتطوير نماذج تعلم عميق دقيقة وموثوقة لمساعدة الأطباء على تشخيص سرطان الرئة وسرطان المستقيم وسرطان البنكرياس وسرطان المعدة وسرطان البروستات وأورام المخ وأعراض السل والتيفوئيد وسرطان الثدي وغيرها من الأمراض التي يتم تصويرها طبيياً [١٢,١٣].

٢- أهمية البحث وأهدافه:

يهدف البحث إلى بناء نظام للتنبؤ بعدد من الأمراض الصدرية والتي يتم تحليلها وكشفها باستخدام الصور الطبية ، ركزت الدراسة البحثية المقدمة على ثلاثة أنواع من تلك الأمراض وهي السرطان، الكورونا، والسل . كما تكمن أهمية البحث بالقدرة على:

- ١- تخفيف الضغط على الأطباء في حالات التنبؤ بالأمراض من خلال الصور الطبية.
- ٢- تخفيض معدلات الخطأ في حالات التقييم الطبي.
- ٣- رفع سرعة التنبؤ بالنموذج المرضي الأمر الذي يمكن أن يساعد المريض والذي قد يكون معياراً أساسياً لإنقاذ حياته.

٣- طرائق البحث ومواده:

اعتمدت الدراسة المقترحة على اختبار ثلاثة نماذج من الشبكات العصبية نموذج الشبكات العصبية من نمط AlexNet والشبكات من نمط Resnet والشبكات من نمط UNET. وتقييم معايير الأداء لهذه الشبكات الثلاثة لاختيار الشبكات الأفضل، ومن ثم تقديم نموذج هجين عبر دمج خوارزمية SIFT مع الشبكات العصبية الالتفافية ومقارنتها مع الشبكات السابقة. تمت عملية المحاكاة على جهاز ذو معالج Core i5 من الجيل الثامن مع بطاقة إظهار منفصلة من نوع Nvidia GTX770M.

اعتمد البحث على إجراء الاختبارات على أربع مجموعات بيانات تتضمن حالات أمراض Covid-19 والسرطان والسل بالإضافة إلى الحالة السليمة. جميع الصور المستخدمة كانت صور X-Ray وصور أشعة مقطعية ذات أحجام مختلفة. بالإضافة إلى ذلك، فإن جميع الصور التي تم استخدامها كانت صور ذات تدرج رمادي. تم الحصول على مجموعات البيانات من قواعد بيانات عالمية موجودة على موقع Kaggle وقد بلغ مجموع الصور المستخدمة 6000 صورة موضحة في الجدول (١):

الجدول (١) نماذج الصور المستخدمة في الدراسة البحثية.

العدد	الصورة
1200	Covid – 19 الكورونا
1300	Cancer السرطان
١٠٠٠	Tuberculosis السل
2500	Normal صور سليمة

يمكن الحصول على هذه البيانات من الروابط التالية:

Covid19 (<https://www.kaggle.com/datasets/tawsifurrahman/covid19-radiography-database>).

Normal (<https://www.kaggle.com/datasets/nih-chest-xrays/data>).

Tuberculosis (<https://www.kaggle.com/datasets/adityamahimkar/iqothncdd-lung-cancer-dataset>).


Cancer (<https://www.kaggle.com/datasets/quynhlecl/lung-cancer-x-ray>).

١-٣- نماذج الشبكات العصبية المستخدمة:

١-١-٣- شبكة Alex Net:

تقوم شبكة Alex Net بتعميق بنية الشبكة على أساس LeNet وهي قادرة على تحديد ميزات صور أكثر ثراءً وأعلى أبعاداً. بالمقارنة مع LeNet، تمتلك Alex Net بنية شبكة أعمق مكونة من خمس طبقات التفاضلية وثلاث طبقات متصلة بالكامل. يتم تغذية مخرجات الطبقة الأخيرة المتصلة بالكامل إلى SoftMax ذو ١٠٠٠ خرج والذي ينتج توزيعاً على ١٠٠٠ فئة خرج يتم التنبؤ بها (كأنواع وسائل النقل والأجهزة والحيوانات وغيرها) والتي يتم التعرف عليها [14].

يبين الشكل (١) البنية العامة لشبكة Alex Net



الشكل (١) بنية شبكة AlexNet

في Alex Net، يتم استخدام الوحدة الخطية المصححة (ReLU - Rectified Linear Unit) كوظيفة تنشيط لشبكة CNN والتي تحل بنجاح مشكلة التشتت المتدرج لتابع السيغمويد عندما تكون الشبكة عميقة [14]. بالإضافة إلى ذلك، يعد تابع ReLU أبسط من تابع السيغمويد كما أنها تتطلب حسابات أقل، مما يؤدي إلى تسريع عملية التدريب.

تم اقتراح طبقة تطبيع الاستجابة المحلية (LRN) لإنشاء آلية منافسة لنشاط الخلايا العصبية المحلية بحيث تصبح النتائج ذات الاستجابة الأكبر وذات أداء وفعالية أعلى نسبياً وتثبط الخلايا العصبية ذات ردود الفعل الأصغر [15]. كما تم أيضاً تعزيز قدرة التعرف العامة للنموذج. كما يتم استخدام التجميع المتداخل بنجاح وتظهر التجارب أن طبقات التجميع المتداخلة أقل عرضة لتراكم وتداخل نتائج بياناتها فيما بينها [15]. يتم عادة الاعتماد على تقنيات التوليد Augmentation من أجل زيادة كمية البيانات الخاصة بالتدريب والاختبار وبالتالي رفع فعالية النموذج، وتتضمن زيادة البيانات هذه طريقتين: إما إنشاء تحويلات للصور مثل الدوران والانعكاس الأفقي والعمودي والتكبير والتصغير، أو تغيير معدلات السطوع في قناة RGB ضمن صورة التدريب [15]. وتم إجراء تعديل في الشبكة لاستخدام ٤ مخارج فقط من أصل ١٠٠٠ مخرج متاح

شبكة ResNet : ٣-١-٢


تم اقتراح ResNet بواسطة He et al [16] في عام ٢٠١٥. إنها شبكة عصبية عميقة تتكون من تكديس العديد من الوحدات. قبل اقتراح ResNet، كانت جميع الشبكات العصبية تتكون من طبقات التفاضلية وطبقات تجميع. عند إجراء عمليات تراكب للطبقات التلافيفية وطبقات التجميع، لا يصبح تأثير التعلم أفضل فحسب، إلا أننا سنعاني من وجود مشكلتين: إحداهما هي التدرج المتلاشي والأخرى هي مشكلة تدهور الاداء مع ازدياد عدد الدورات. ومع زيادة عدد الطبقات، يصبح تأثير التنبؤ أسوأ.

تعمل ResNet على حل مشكلة تلاشي أو انفجار التدرجات من خلال المعالجة المسبقة للبيانات واستخدام طبقة تطبيع دفع المجالات (Batch Normalization) في الشبكة. يتم استخدام البنية المتبقية للسماح بشكل مصطنع لبعض طبقات الشبكة العصبية بتخطي اتصال الخلايا العصبية في الطبقة التالية من خلال طبقة تسمى Dropout والتي تهدف لتنظيم عملية التعلم وعدم دخول الشبكة ضمن نموذج تدريب ثابت.

يستخدم الهيكل الخاص بحساب البواقي ضمن الشبكة طريقة اتصال مختصرة، ويتخطى طبقة واحدة أو أكثر، وينفذ تعييناً بسيطاً للنماذج التي تم التعرف عليها، الأمر الذي يحل مشكلة إضافة أي معلمات إضافية ولا يزيد من التعقيد الحسابي، وبالطبع يكون من الممكن تدريب الشبكة بالكامل من طرف إلى طرف باستخدام خوارزمية التدرج العشوائي المنسوب SGD

(Stochastic Gradient Descent) والانتشار العكسي، يوضح الشكل (٢) نموذج حساب البواقي من

أجل تجاوز اختفاء التدرجات [16].



الشكل (٢) نموذج حساب البواقي

في بنية الشبكة المتبقية، بافتراض أن الإدخال هو x ، تتم الإشارة إلى السمة المستفاد منها بمحول $P(x)$ ، ويُشار إلى المجال المتبقي الذي يمكن تعلمه بعد عملية حساب الأوزان الرئيسية بالقيمة $Z(x)$ ؛ ومن ثم، فإن السمات الأصلية التي تم تعلمها هي $P(x) = Z(x) + x$. عندما يكون المجال المتبقي $Z(x) = 0$ ، فإن الطبقة المكسدة هنا تقوم فقط بتعيين الهوية ويكون الهدف من التعلم اللاحق هو الاقتراب من المتبقي إلى الصفر [16]. أكبر فرق بين الشبكة العصبية الالتفافية العادية المتصلة مباشرة و ResNet هو أن ResNet لديها العديد من الفروع الالتفافية التي تربط المدخلات مباشرة بالطبقة الأخيرة بحيث يمكن للطبقة الأخيرة أن تتعلم مباشرة من البيانات المدخلة [16]. تسمح ResNet بتغذية معلومات الإدخال الأولية مباشرة في الطبقات الأخيرة.


تتألف الشبكة الأولى المقترحة في هذا البحث من نمط ResNet من ١٧٧ طبقة تتوزع بين طبقات التفاضل وانتخاب بالإضافة إلى طبقات ضبط القطاعات Batch Normalization. وطبقة كاملة الارتباط. يتم المرور

عبر كل مرحلة ضمن طبقة اسقاط Dropout لعدد من العصبونات ليتم رفع دقة الشبكة وعدم ابقائها على نموذج تدريب ثابت.

شبكة Unet - ٣-١-٣

تتمثل مخرجات العديد من الشبكات العصبية بكونها الناتج النهائي لعمليات التصنيف، ولكن في العديد في الحالات، على سبيل المثال معالجة الصور الطبية، لا يرغب العاملون في المجال الطبي في معرفة فئة الصورة فحسب، بل يريدون أيضاً معرفة توزيع موقع الأنسجة المختلفة في الصورة. يمكن لـ U-net تحقيق التعرف على موضع وحدات بكسل الصورة ذات الأهمية. تقوم الشبكة بتصنيف كل بكسل في الصورة ويكون الإخراج النهائي عبارة عن صورة مجزأة وفقاً لفئة البكسل المدروس.

تم اقتراح U-net بواسطة Ronneberger et al [17] في عام ٢٠١٥.



الشكل (٣) نموذج عام لبنية شبكة Unet

كانت الشبكة في البداية عبارة عن شبكة عصبية التلافيفية بالكامل مصممة خصيصاً لتجزئة الصور الطبية. ومع تقدم الوقت والتحسين في أداء الشبكة فقد تم استخدامها الآن على نطاق واسع كأداة رئيسية لمهام تجزئة الصور الطبية وقد حققت نتائج جيدة. تتميز شبكة U-net بكونها صغيرة الحجم مقارنة بالعديد من شبكات التجزئة الدلالية الأخرى، لذلك يمكن استخدامها أيضاً في بعض المهام التي يتطلب تنفيذها إجراء مهام في الزمن الحقيقي. تعتمد بنية U-net على بنية شبكة FCN حيث تتكون بنيتها من مسارين رئيسيين، الأول يسمى مسار التعاقد والذي يهدف لالتقاط السياق العام ضمن الصور والثاني هو مسار التوسع المتماثل للضبط الدقيق لعمليات التدريب. يتكون مسار التعاقد، أو مسار التشفير أو مسار التحليل، من عدة طبقات التلافيفية والتي تهدف إلى تجميع وأخذ عينات من الصور، وعلى غرار الشبكات التلافيفية العادية، يمكن لهذا المسار إعطاء الكثير من معلومات التصنيف. في حين يجمع المسار الموسع، المعروف أيضاً باسم وحدة فك التشفير أو مسار التوليف، بين السمات عالية الدقة من المسار السابق مع مخرجات العينة الأعلى تقارباً لاستعادة شكل الصورة الأصلية،

مما يوفر تنبؤاً لكل بكسل. تضيف مرحلة أخذ العينات الأعلى Up sampling في بنية U-net الكثير من قنوات الميزات والسمات، مما يسمح بنشر المزيد من معلومات نسيج الصورة الأصلية في طبقات عالية الدقة. لا تحتوي شبكة U-net على طبقات متصلة بالكامل وهي صالحة للاستخدام في عملية الالتفاف طوال الوقت. أي أن خريطة التجزئة تحتوي فقط على وحدات بكسل بحيث يمكن ضمان اسناد نتائج التجزئة حتى في حال عدم وجود ميزات سمات مفقودة ضمن الصورة، وبالتالي فإن أحجام صور الإدخال والإخراج ليست كبيرة جدًا.

٣-٢ معايير تقييم أداء الشبكات:

عند بناء أي نموذج ذكاء صناعي سواء باستخدام التعلم العميق أو تعلم الآلة على اختلاف أنواعها فإن الهدف الرئيسي الناتج عن أي من هذه النماذج هو الوصول إلى أعلى قيمة دقة للمصنف. لا يعتبر معيار الدقة وحده كافٍ لتقييم أداء النظام ككل وإنما سنكون بحاجة معايير أخرى تسمح بتقييم النظام بصورة أفضل.

Confusion Matrix: ١-٢-٣ مصفوفة الارتباك

تمثل هذه المصفوفة مصفوفة مربعة عدد أسطرها وأعمدتها يساوي عدد الأصناف ضمنها حيث

ان :

- الصفوف تمثل القيم الحقيقية .
 - الأعمدة هي القيم المتوقعة من النموذج.
 - كل خلية تحوي عدد العينات التي وقعت في هذا المزيج (حقيقي X ، متوقع Y).
- تقوم هذه المصفوفة بتقسيم البيانات المدروسة إلى أربعة أقسام وهي:
- عينات صحيحة إيجابية (TP) True Positive: وهي العينات التي كان تصنيفها أصلاً Positive وقد توقعها النموذج بصورة صحيحة على أنها Positive.
 - عينات صحيحة سلبية (TN) True Negative: وهي العينات التي كان تصنيفها أصلاً Negative وقد توقعها النموذج بصورة صحيحة على أنها Negative.
 - عينات خاطئة سلبية (FN) False Negative: وهي العينات التي كان تصنيفها في الاصل Positive وقد توقعها النموذج Negative.
 - عينات خاطئة إيجابية (FP) False Positive: وهي العينات التي كان تصنيفها في الاصل Negative وقد توقعها النموذج Positive.

٣-٢-٢ معيار الدقة Accuracy

والذي يمكن حسابه اعتماداً على العلاقة (١) التالية

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

3-2-3 معيار Recall:

وهو معيار آخر من معايير التقييم حيث يعتمد على تحديد مقدار البيانات التي تم استعادتها كقيم Positive من البيانات التي هي بالفعل Positive ويعطى بالعلاقة (2):

$$Recall = \frac{\text{true positives}}{\text{actual positives}} = \frac{TP}{TP + FN} \quad (2)$$

٣-٢-٤ معيار الدقة Precision

وهو معيار آخر من معايير التصنيف الرئيسية، يحدد هذا المعيار مقدار البيانات Positive والتي قام المصنف بالتعرف عليها على أنها Positive بصورة صحيحة وتظهر العلاقة (٣) طريقة حساب معيار Precision

$$Precision = \frac{\text{true positives}}{\text{predicated positives}} = \frac{TP}{TP + FP} \quad (3)$$

٣-٢-٥ معيار F1-Score:

وهو معيار يهدف إلى الجمع بين معياري precision, recall ويستخدم بكثرة في حالات قواعد البيانات غير المتوازنة ويعطى بالعلاقة (٤) :

$$F1 - score = 2 * \frac{Precision * recall}{Precision + recall} \quad (4)$$

٤- النتائج والمناقشة:

تم إجراء الاختبارات على ثلاثة أنماط من الشبكات العصبية وهي ResNet, AlexNet, Unet. وقد تم التركيز على معياري الدقة والسرعة كمعيارين أساسيين خلال تقييم النتائج و بينت النتائج أن الشبكة من نمط (ResNet) أعطت قيم دقة اعلى من غيرها وان الشبكة من نمط AlexNet بالرغم من ان الدقة كانت اقل لكن زمن اسرع مقارنة مع الشبكات من النموذج الوصفي Unet وهذا يعود إلى طريقة تحليل تلك الشبكات للصور المقدمة وعمليات معالجة الأجزاء Batches. في حين تعتمد الشبكات الوصفية على عمليات تكبير الصورة upscaling مما يتسبب بزيادة كميات البيكسلات عن طريق خوارزميات تنبؤ الأمر الذي يسبب بإضافة مقاطع إلى الصورة الأمر الذي يمكن أن يتسبب بالمزيد من الخطأ في عمليات التنبؤ.

٤-١- نتائج شبكة ResNet

يوضح الشكل (٤) مصفوفة confusion Matrix الناتجة عن الشبكة العصبية من نمط ResNet حيث يمثل القطر الرئيسي في هذه المصفوفة العينات التي تم التنبؤ بها بصورة صحيحة، في حين تمثل باقي البيانات في كل سطر أن العينة المستخدمة قد تم التنبؤ بها عل أنها عينة لصنف آخر.

		ResNet			
		Cancer	Covid-19	Normal	TB
True class	Cancer	240	8	2	10
	Covid-19	10	220	5	5
	Normal	4	7	479	10
	TB	6	5	14	175
		Predicted class			
		Cancer	Covid-19	Normal	TB

ResNet. الناتجة عن اختبار الشبكة من نمط Confusion الشكل (٤) مصفوفة

وقد بينت النتائج ان شبكة ResNet تمكنت الشبكة من الوصول إلى دقة عالية خلال عدد دورات أقل حيث بلغت دقة التنبؤ في الشبكة على بيانات الاختبار ٩٢,٨% السبب في هذه الدقة كون الشبكة مصممة مسبقاً للتصنيف من أجل ١٠٠٠ صنف محدد مسبقاً حيث تم إجراء بسيط على الشبكة من حيث إزالة الطبقة الأخيرة التي تقوم بعمليات التصنيف في حين تم الحفاظ على طبقة الدخل واعتماد حجم الدخل الافتراضي 3*224*224 حيث تم إعادة بناء الصور ذات التدرج الرمادي (طبقة واحدة) إلى بنى ذات ٣ طبقات.

٤-٢- نتائج شبكة AlexNet

تتألف الشبكة AlexNet التي تم استخدامها في الدراسة من ٢٥ طبقة، وبالتالي فهي أقل حجماً من شبكة Resnet كما أنها تتطلب مجال ذاكرة أقل، وظهر ذلك واضحاً على دقة النتائج وسرعة عملية التدريب حيث كان الزمن اللازم لتدريب شبكة AlexNet اقل من غيرها ولكن الدقة التي حصلنا عليها خلال عملية الاختبار كانت ٨٨% وهي اقل مقارنة مع باقي الشبكات.

يوضح الشكل (٥) الأتي مصفوفة Confusion Matrix الناتجة عن اختبار الشبكة من نمط Alexnet:

		AlexNet			
		Cancer	Covid-19	Normal	TB
True class	Cancer	225	12	9	14
	Covid-19	15	210	7	8
	Normal	11	10	461	18
	TB	9	8	23	160
		Predicted class			

AlexNet الناتجة عن اختبار الشبكة من نمط Confusion Matrix الشكل (٥) مصفوفة

٣-٤- نتائج شبكة U-Net:

بينت عملية الاختبار على شبكة UNet الافتراضية أن العمل على نموذج هذه الشبكة لم يعطي نتائج الدقة المرغوبة إضافة إلى زمن طويل لإنهاء عملية التدريب وذلك يعود إلى البنية التصميمية الخاصة لهذه الشبكة واستخدامها طبقات تحتوي على عمليات رفع وزيادة عدد البيكسلات Upscaling مما قد يسبب وجود بيكسلات متتبا بها تسبب المزيد من الأخطاء أثناء عملية التدريب.

كما يوضح الشكل (٦) الآتي مصفوفة Confusion Matrix الناتجة عن اختبار الشبكة من نمط U-NET:

حيث بلغت دقة التنبؤ بالأمراض باستخدام هذه الشبكة نحو ٩٠% وهي دقة منخفضة مقارنة مع نماذج الشبكات السابقة التي تم استخدامها في هذه الدراسة.

		UNet			
		Cancer	Covid-19	Normal	TB
True class	Cancer	230	10	8	12
	Covid-19	12	215	6	7
	Normal	10	8	471	11
	TB	8	7	15	170
		Predicted class			

U-NET الناتجة عن اختبار الشبكة من نمط Confusion Matrix الشكل (٦) مصفوفة

ونلاحظ مما سبق فقد تبين أن شبكة U-NET ليست الخيار المثالي للتصنيف الخام، لكن هذا النموذج يعتبر جيد إذا دمجتنا segmentation + classification . في حين تميل شبكات AlexNet إلى أداء جيد لكن ليس الأفضل مع الصور الطبية المعقدة. وتعطي شبكات ResNet الأداء المقبول عند معالجة الصور الطبية. يوضح الجدول (٢) معايير تقييم الأداء الأساسية للنماذج الثلاثة المستخدمة في الدراسة وهي: F1-score , Recall , Precision , Accuracy .

الجدول (2) معايير تقييم الأداء في الدراسة المقترحة.

Model	Accuracy	Precision	Recall	F1-score
“ResNet”	0.92	0.91819	0.91819	0.91819
“AlexNet”	0.88	0.8656	0.8656	0.8656
“UNet”	0.905	0.89311	0.89311	0.89311

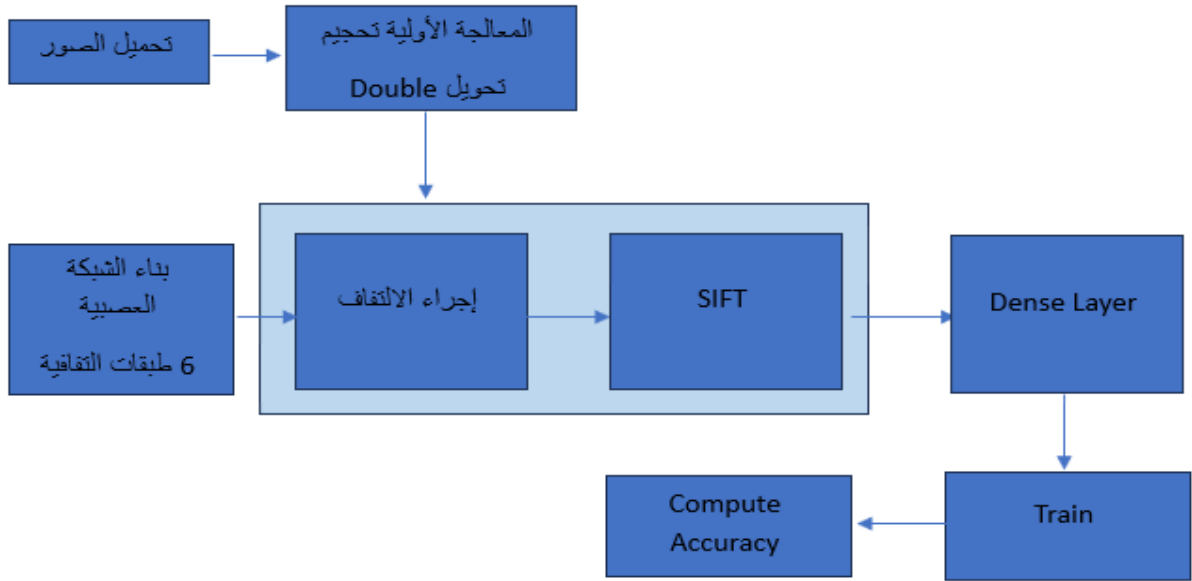
ومقارنة مع دراسات كانت قد أجريت سابقاً نلاحظ انه عندما تم استخدام خوارزمية ResNet للكشف عن مرض الكورونا اعطى دقة تصل إلى ٦١,٧% فقط وذلك بسبب قلة عدد البيانات [18] . اما عندما تم استخدام شبكة VGG16 والتي تعتبر نسخة مطورة من شبكة AlexNet لتمييز مرض السل لوحده بلغت الدقة ٩٨% وفي المقابل حققت خوارزمية U-Net دقة تصل إلى ٩١% عندما تم استخدامها للكشف عن مرض الكورونا لوحده [19-20] وعليه نجد ان هناك عاملين أساسيين يؤثران في أداء الشبكات العصبية الأول هو حجم قاعدة البيانات والثاني هو عدد المتغيرات (الامراض) التي نريد من الشبكة تمييزها في وقت واحد فعندما كان يتم استخدام الشبكات لتمييز نوع واحد من الامراض كانت تعطي قيم عالية جدا للدقة بينما عندما يتم تصميم الشبكة لتمييز عدة أنواع من الامراض في وقت واحد سوف تنخفض هذه الدقة

١-٥- الدمج مع خوارزمية SIFT:

تعتبر خوارزمية SIFT (Scale-Invariant Feature Transform) إحدى الخوارزميات المعتمدة لاستخراج نقاط وميزات مهمة (features) من الصور وتتضمن هذه السمات:

- Scale-invariant تكتشف النقاط المميزة حتى لو تم تكبير/تصغير الصورة.
- Rotation-invariant تظل تعمل حتى لو الصورة دارت بزواوية.
- تبحث عن نقاط محلية (keypoints) مثل زوايا، حواف واضحة، تغييرات شدة.
- لكل نقطة مميزة، تولد وصف (descriptor) يصف المنطقة حولها بشكل عددي (عادة متجه أبعاد ١٢٨).

وبالتالي تُمثل الصورة كسلسلة من السمات بدلاً من البكسلات خام، وهذا يجعلها مفيدة للمقارنة، المطابقة، والتعرف على الأشياء. تم اعتماد طريقتين من أجل استخدام خوارزمية SIFT مع الشبكات العصبية، حيث تمثلت الأولى بتمرير الصورة المستخدمة في البداية إلى الخوارزمية واستخلاص السمات ومن ثم تمريرها إلى الشبكة العصبية. انخفضت الدقة في هذه الطريقة لمعدل كبير نظراً لتجاهل العديد من السمات الموجودة في الصورة الرئيسية نظراً لمحدودية عدد السمات التي يتم استخلاصها في SIFT (تم اختياره ٩ سمات لتسريع عملية المعالجة). في الحالة المعدلة تم تطبيق خوارزمية SIFT بعد كل مرحلة من مراحل الالتفاف في الشبكة الالتفافية. ويوضح المخطط الصندوقي في الشكل (٧) نموذج الخوارزمية المقترحة:



الشكل (٧) نموذج الخوارزمية المقترحة

- يجب أن نأخذ بعين الاعتبار أنه في الصور الطبية (مثل الأشعة السينية أو الرنين):
- الاهتمام عادة يكون بالمناطق التي تحمل علامات المرض (أورام، بقع، آفات).
 - خوارزمية SIFT قادرة على استخراج مميزات محلية قوية من هذه المناطق.
 - بالتالي، يمكن استخدامها قبل تدريب الشبكات العصبية لتحسين عملية التصنيف أو التجزئة.
- تعطي الشبكات العصبية بعد مرحلة الالتفاف ثلاث سمات أساسية وهي ثلاث نماذج من الصور ذات الدقة المختلفة يمكن توضيحها كما يلي:
- المستوى المنخفض : ويعطي نموذج التوزيع اللوني ضمن الصورة، وتظهر الصورة هنا على شكل توزيع طمس لوني للنموذج العام للصورة.
 - المستوى المتوسط: حيث تبدأ بعض العناصر بالوضوح بشكل مشابه وقريب من الصورة الأصلية.
 - المستوى العالي: ويتضمن الحواف في الصورة أو ما يعرف بالعناصر ذات التردد العالي حيث يتم تمييز المناطق على شكل مناطق معزولة بحوافها المجاورة.
 - تم تمرير نواتج المراحل الثلاث إلى SIFT واستخلاص أشعة السمات وتميرها للطبقة كاملة الارتباط.
- بعد إجراء عملية التدريب وإدخال أشعة SIFT إلى نماذج الشبكات العصبية، تبين لنا ارتفاع الدقة في التنبؤ بنموذج المرض بالإضافة إلى تحسن واضح في الزمن المطلوب خلال التدريب والتنبؤ كما هو موضح في الجدول (3) الآتي:

الجدول (2) معايير تقييم الأداء في الدراسة المقترحة

النموذج	الدقة	الزمن
SIFT+CNN	94%	29 min
AlexNet	88%	37 min
ResNet	92.8%	149 min
UNet	90%	113 min

٢-٥- الاستنتاجات والتوصيات:

بعد اختبار نماذج متعددة من الشبكات العصبية الالتفافية للتعقب بالأمراض في الصور الطبية، فقد تبين أن نموذج الشبكات الالتفافية من نمط ResNet أعطت قيم الدقة الأعلى مقارنة مع نمودجي Unet و AlexNet مع نسبة تعرف عالية. إلا أن هذه الشبكات تحتاج إلى فترة زمنية كبيرة خلال عملية التدريب للوصول إلى قيم أوزان جيدة من أجل التعرف على نموذج المرض ضمن الصورة. وبسبب البنية الخاصة بالصور الطبية فقد سمح استخدام خوارزمية SIFT بزيادة سرعة عمليات التدريب والاختبار مع المحافظة على دقة عالية في اكتشاف الأمراض .

يمكن أن يتم تطوير النموذج مستقبلاً بحيث يمكن استخلاص سمات أساسية من الصور المدروسة وتدريب الشبكات عليها بحيث يتم زيادة سرعة التعرف نظراً لعدم الحاجة لتحليل كامل بيكسلات الصورة وإنما أشعة السمات الناتجة عن مرحلة معالجة أولية.

المراجع:

- [1] Masayu Norman et. al, “Statistical Approach in Determination of Tuberculosis Spatial Pattern”, Proceeding of the 2011 IEEE International Conference on Space Science and Communication (IconSpace) 12-13 July 2011, Penang, Malaysia
- [2] NorlizaMohd. Noor et. al. “A Statistical Interpretation of the Chest Radiograph for the Detection of Pulmonary Tuberculosis”, 2010 IEEE EMBS Conference on Biomedical Engineering & Sciences (IECBES 2010), Kuala Lumpur, Malaysia, 30th November 2010.
- [3] Shafeena Basheeret. al, “Computer Assisted X-Ray Analysis System for Detection of Onset of Tuberculosis”, International Journal of Scientific & Engineering Research, Volume 4, Issue 9, 2013.
- [4] Stefan Jaeger et. al. “Detecting Tuberculosis in Radiographs Using Combined Lung Masks”, 34th Annual International Conference of the IEEE EMBS San Diego, California USA, 28 August – 1 September, 2012.
- [5] A. D. Orjuela-Cañón, Fuzzy-ART Neural Networks for Triage in Pleural Tuberculosis, 2013 PAN AMERICAN HEALTH CARE EXCHANGES (PAHCE). CONFERENCE, 2013.
- [6] RuiShenet. al. “A Hybrid Knowledge-Guided Detection Technique for Screening of Infectious Pulmonary Tuberculosis From Chest Radiographs”, IEEE TRANSACTIONS ON BIOMEDICAL ENGINEERING, VOL. 57, NO. 11, NOVEMBER 2010.

- [7] RatnasariNurRohmahLung, “*Tuberculosis Identification Based on Statistical Feature of Thoracic X ray*”, IEEE, 2013.
- [8] PATIL S.A. “*Texture Analysis of TB X-ray Images Using Image Processing Techniques*”, Journal of Biomedical and Bioengineering, Volume 3, Issue 1, 2012.
- [9] Mrs. J. ShyamalaDev ,”*A Study on Improving the Conspicuity of Lung Nodules by use of Virtual Dual-Energy” Radiography,*” 4th National Conference on Advanced Computing, Applications & Technologies, May 2014
- [10] WHO Global Tuberculosis Report 2013, *World Health Organization*, 2013.
- [11] “*Smear-Negative Multidrug-Resistant Tuberculosis a Significance Hidden Problem for MDR-TB Control: An Analysis of Real World Data*”,Journal of Tuberculosis Research, 2014.
- [12] Tan JH, Acharya UR, Tan C, et al. “*Computer-assisted diagnosis of tuberculosis: a first order statistical approach to chest radiograph.*” J Med Syst 2012;36:2751-9, 2017.
- [13] Tao Xu, Irene Cheng, Richard Long and Mrinal Mandal, “*Novel coarse-to-fine dual scale technique for tuberculosis cavity detection in chest radiographs*”, EURASIP Journal on Image and Video Processing , 2013.
- [14] Wenhao Tang, Junding Sun, Shuihua Wang, Yudong Zhang, “*Review of AlexNet for Medical Image Classification* ”, Vol. 9 (2023): EAI Endorsed Transactions on e-Learning , 2023.
- [15] C. Garbin, X. Zhu, and O. Marques, “*Dropout vs. batch normalization: an empirical study of their impact to deep learning,*” Multimedia Tools and Applications, vol. 79, pp. 12777-12815, 2020.
- [16] Wannu Xu, You-Lei Fu, Dongmei Zhu, “*ResNet and Its Application to Medical Image Processing: Research Progress and Challenges*”, Computer Methods and Programs in Biomedicine 240(9), June 2023.
- [17] Jervis Anthony Saldanha, “*Medical Image Segmentation and Its Real-World Applications: UNet and Beyond*”, URL: <https://medium.com/@jervisaldanha/medical-image-segmentation-and-its-real-world-applications-unet-and-beyond-9cd06eeebcb6>, [online, 2023].
- [18] Ioannis Kontopoulos “*COVID-19 detection from chest X-Ray images using Deep Learning and Convolutional Neural Networks*” September 2020.
- [19] Adnan Saood and Iyad Hatem “*COVID-19 lung CT image segmentation using deep learning methods: U-Net versus SegNet*” <https://doi.org/10.1186/s12880-020-00529-5> [2021]
- [20] Suci Aulia, Sugondo Hadiyoso “*Tuberculosis Detection in X-Ray Image Using Deep Learning Approach with VGG-16 Architecture*” / Jurnal Ilmiah Teknik Elektro Komputer dan Informatika (JITEKI) Vol. 8, No. 2, June 2022