الكشف عن مرض الكوفيد-١٩ باستخدام تقنيات الذكاء الاصطناعي والصور الطبية الشعاعية

ماهر الرحال و محمود رحال

قسم هندسة الحواسيب، كلية الهندسة الكهربائية والإلكترونية، جامعة حلب، حلب، سوريا

المستخلص. تهدف الدراسة إلى إلقاء الضوء على أهمية استخدام الذكاء الاصطناعي في الكشف عن مرض الكوفيد-١٩، من خلال تطبيقه على الصور الطبية الشعاعية (صور الأشعة السينية وصور الأشعة المقطعية للرئتين)، من خلال استخراج أشعة الميزات (السمات) من الصور وتصنيفها بمساعدة خوارزميات التصنيف الشهيرة، وأدخلنا مفهوم استرجاع الصور المعتمد على المحتوى لأهميته في تسهيل المقارنة والتشخيص. اقترحنا في هذه الدراسة طريقة جديدة لاستخراج السمات تجمع بين الطرق التقليدية والطرق الأتوماتيكية في استخراج السمات، لنحصل على نتائج أفضل من استخدام إحدى الطريقتين، وذلك من خلال دمج المستويات الثلاثة من استخراج السمات وهي، خوارزمية النمط الثنائي المحلية لاستخراج السمات ذات المستوى المنخفض، حقيبة الكلمات المرئية لاستخراج السمات ذات المستوى المتوسط، شبكة الأليكسنت التي تعتمد على التعلم العميق لاستخراج السمات عالية المستوى. في النهاية أسندنا أوزان لتلك السمات حسب أهميتها، واستخدمنا ما يعرف بتحليل المكون الرئيسي لتخفيض حجم السمات، وحصلنا على نتائج واعدة في هذا المجال.

كلمات مفتاحية: مرض الكوفيد-١٩، خوارزمية النمط الثنائي المحلية، حقيبة الكلمات المرئية، التعلم العميق، تصنيف الصور، استرجاع الصور.

١ - المقدمة

في الأشهر الأخيرة من عام ٢٠١٩، ظهر مرض الكوفيد-١٩ في الصين، وتحديداً من ووهان^[١]، وكانت الأعراض الشائعة لمرضى الكوفيد-١٩ هي الحمى والسعال والألم العضلي أو التعب، أما مضاعفات الكوفيد-١٩ فهي التهابات شديدة في الجهاز التنفسي، وإصابات قلبية حادة، والإصابات المتقدمة تؤدي إلى دخول وحدة الرعاية المركزية وقد تؤدي إلى الوفاة.

إحدى العقبات الرئيسية في السيطرة على انتشار هذا المرض هي نقص الاختبارات ومحدودية كفاءتها حيث تعتمد الاختبارات الحالية في الغالب على اختبار الـ (RT-PCR) والذي يستغرق من ٤ إلى ٦ ساعات للحصول على النتائج^[٢]. كما تعاني مجموعات اختبار الـ RT-PCR من نقص كبير وبالتالي عدم القدرة على إجراء الأعداد المطلوبة من الاختبارات اليومية، بالإضافة إلى ارتفاع تكاليف المواد التي يستخدمها، كما وتعتبر كفاءة هذا الاختبار محدودة^[٣] حيث أن دقته لا تتجاوز الـ ٧١٪.

لقد أظهرت الدراسات أن فحص الصدر بالأشعة السينية (X-Ray) يكشف التغيرات التي

تحدث على رئتة المريض بعد ٤-٥ أيام من بدء ظهور الأعراض^[٤]،^[٥] ويمتاز التصوير بالأشعة السينية بتكلفته المنخفضة بالإضافة إلى أن كمية الأشعة التي يتعرض لها المريض ليست كبيرة، إلا أن دقته أقل مقارنة مع التصوير المقطعي الذي يمتاز بقدرته على كشف التغيرات التي تحدث في رئتة المريض مع بدء ظهور الأعراض أو بعد يومين من بدء الأعراض^[٦]،^[٧]. وقد أدت هذه الدراسات إلى إجراء بحوث حول قدرة التصوير الشعاعي (بنوعيه التصوير بالأشعة السينية والتصوير بالأشعة المقطعية) على كشف الحالات المشتبه إصابتها بمرض الكوفيد-١٩^[٨]،^[٩] كما هو موضح في الجدول ١.

لذا كان من الضروري تقديم طريقة كشف أخرى تعتمد على الذكاء الاصطناعي ومعالجة الصور الشعاعية لتحديد الإصابة بالمرض، وهذه الطريقة لا تلغي اختبار الـ RT-PCR وإنما مكملته ومساعدة له؛ في حالات وجود أعراض للمرض، وبالتالي تحديد الإصابة لجزء مهم ممن يتم اختبار الإصابة لديهم بمدة زمنية قصيرة وبتكلفة متواضعة نسبياً، وبالتالي استبعاد تطبيق تحليل الـ RT-PCR عليهم، وهذا هو الدافع الأساسي لعملنا.

الكوفيد-١٩ سواءً باستخدام صور الأشعة السينية أو الأشعة المقطعية، مع ملاحظة أن اختيار نوع التصوير المستخدم للكشف عن الإصابة بالمرض يعتمد على عوامل متعددة، وخاصة: نوع أجهزة التصوير المتوفرة، وتوقيت ظهور الأعراض، والفحص السريري، ورأي الطبيب.

في هذه الدراسة تم تصميم نظام ذكي لتشخيص مرض الكوفيد-١٩ يعتمد على الذكاء الاصطناعي ومعالجة الصورة وتطبيق هذه التقنيات على الصور الشعاعية لتحديد الإصابة بالمرض المذكور وتمييزه عن الأمراض الالتهابية الأخرى التي تصيب الرئتين. كما تم تدريبه ليكون قادرًا على تشخيص مرض

جدول ١. تأثير مرض الكوفيد على رئتي المريض بواسطة التصوير بالأشعة السينية والأشعة المقطعية.

صورة أشعة مقطعية تظهر بقعًا بيضاء على الرئتين الأسفلين من الرئتين، يطلق عليها الأطباء اسم "عتامة الزجاج المطحون" (Ground-Glass Opacity)، وتدل على امتلاء جزئي للحويصلات الهوائية في الرئة.

صورة أشعة مقطعية تصور حالة الرئة بعد ٣ أيام من الأولى، حيث تظهر أن البقع البيضاء في ازدياد.

صور أشعة مقطعية لرئة سيدة مصابة بمرض الكوفيد-١٩، عمرها ٣٣ عام.

صورة أشعة سينية لصدر المريضة في اليوم ٨، تُظهر عتامة الزجاج المطحون الموجود في قاعدتي الرئة (الأسهم البيضاء). ويظهر التوحيد (Consolidation) أيضًا في محيط المناطق العلوية والمتوسطة اليسرى (الأسهم المحددة).

صورة أشعة سينية لصدر المريضة؛ وهي امرأة في السبعينيات من عمرها في المستشفى، مصابة بعدوى COVID-19 (اليوم الأول من دخولها المستشفى).

صور أشعة سينية لرئة سيدة مصابة بمرض الكوفيد-١٩، في السبعين من عمرها.

٢- الأعمال ذات الصلة

سنستعرض في هذا القسم مجموعة من الأبحاث التي استخدمت التعلم العميق (خوارزميات الشبكات العصبية) للكشف عن مرض الكوفيد-١٩، وهي مختزلة في الجدول ٢.

٣- المساهمات العلمية للبحث

كل الأبحاث التي وردت في الفقرة السابقة اعتمدت على استخراج السمات بواسطة الشبكات العصبية العميقة فقط، ولكن في عملنا هذا:

١- قمنا بالدمج بين الطرق الأتوماتيكية لاستخراج السمات باستخدام الشبكات العصبية العميقة والطرق التقليدية، وحصلنا على نتائج واعدة.

٢- تم بناء نظام ذكي يتعامل مع نوعي الصور الطبية الشعاعية (صور الأشعة السينية وصور الأشعة المقطعية) للكشف عن مرض الكوفيد-١٩.

٣- استخدمنا مفهوم استرجاع الصور المعتمد على المحتوى ل يتم استرجاع الحالات الأكثر تشابهاً للحالة التي يتم اختبارها لتساعد الطبيب وترشده أن هذه الحالة مشابهة جداً مع بعض الحالات التي قد راجعت المشفى في فترات سابقة، وهذا قد يساعده في اتباع نفس البروتوكول العلاجي الذي تم اتباعه على المرضى السابقين.

٤- منهجية البحث

(أ) الفكرة العامة للنظام المقترح

يتكون النظام المقترح من مهمتين أساسيتين، كما هو موضح في الشكل ١:

المهمة الأولى: هي تصنيف الصور (تشخيص المرض)، أما **المهمة الثانية:** فهي استرجاع الصور المعتمد على المحتوى وهو ما يعرف بـ (Content Based Image Retrieval). وبشكل أكثر تفصيلاً، لدينا صورة الدخل (صورة أشعة السينية أو أشعة المقطعية لمنطقة الصدر)، والتي يتم استخراج شعاع السمات لها باستخدام الخوارزمية المقترحة، ليتم استخدامه في تصنيف الصورة (تشخيص المرض) بمساعدة إحدى المصنفات المدربة، وبالتالي فإن خرج هذه المهمة هو الصنف الذي تنتمي إليه صورة الدخل. كما أن شعاع السمات هو أساس مهمة استرجاع الصور المتشابهة والتي تعتمد على قياس نسبة التشابه بينه وبين قاعد السمات وخرج هذه المهمة هو الصور الأكثر تشابهاً لصورة الدخل.

• مهمة التصنيف

في مهمة التصنيف، قمنا بتقسيم قاعدة الصور إلى قاعدتين: إحداهما للتدريب والأخرى للاختبار، نسبة التقسيم هي ٨٠٪ من قاعدة الصور للتدريب و ٢٠٪ للاختبار. في مرحلة التدريب، يتم استخراج أشعة السمات لجميع صور قاعدة التدريب باستخدام الخوارزمية المقترحة لنستفيد منها مع تسميات الصور

بين شعاع سمات صورة الدخل وجميع أشعة السمات المخزنة في قاعدة السمات والتي تم الحصول عليها في مرحلة التدريب. بعد ذلك يتم ترتيب هذه المسافات بشكل تصاعدي (حيث أن المسافة الأصغر تعني أن التشابه أكبر) واسترجاع أول k صورة كخرج لمرحلة الاختبار.

(ب) المسافات المعيارية المستخدمة في قياس نسب التشابه

سوف نعتمد في قياس التشابه على المسافة الاقليدية (Euclidean Distance) ومسافة الستى بلوك (Cityblock) [١٧]

- المسافة الاقليدية يتم حسابها وفقاً للقانون (١):

$$(١) \dots \dots \dots D_{Euclid}(Q, DB) = \sqrt{\sum_{i=1}^L (f_{DB_{ji}} - f_{Q_i})^2}$$

- مسافة الستى بلوك يتم حسابها وفقاً للقانون رقم (٢):

$$(٢) \dots \dots \dots D_{cityblock}(Q, DB) = \sum_{i=1}^L |f_{DB_{ji}} - f_{Q_i}|$$

f_{Q_i} ترمز إلى شعاع السمات لصورة الدخل في الموقع i ؛ حيث أن الموقع i هو متحول يتحرك على مواقع الشعاع بدءاً من الموقع الأول وحتى الموقع الأخير من الشعاع f_Q .

لتدريب المصنف، وفي نهاية هذه المرحلة، سوف نحصل على مصنف مدرب وجاهز لتصنيف أي صورة من قاعدة الاختبار. أما مرحلة الاختبار فتبدأ بإدخال الصورة المراد معرفه الصنف الذي تنتمي إليه (تشخيص الصورة)، ليتم استخراج شعاع السمات لها باستخدام نفس الطريقة المقترحة والذي بدوره سيكون دخل المصنف (المدرّب في مرحلة التدريب) الذي سيصنفها إلى الصنف المناسب. استخدمنا في عملنا المقترح كل من خوارزمية (SVM-Support Vector Machine) وخوارزمية الجوار الأقرب (KNN-K Nearest Neighbors).

• مهمة استرجاع الصور

تتألف مهمة استرجاع الصور المعتمد على المحتوى (CBIR) من [١٦]: مرحلة التدريب لاستخراج السمات ويطلق عليها أحياناً مرحلة الـ Off-Line وذلك لكونها تحتاج إلى زمن كبير نسبياً (حيث أن هذا الزمن يعتمد على عدد الصور الموجودة في قاعدة الصور ويقاس بالدقائق)، ومرحلة الاختبار لاسترجاع الصور ويطلق عليها أحياناً مرحلة الـ On-Line وذلك لكونها لا تحتاج إلى زمن كبير (ويقاس بالثواني). في مرحلة التدريب، يقوم النظام باستخراج أشعة السمات لكل الصور الموجودة في قاعدة الصور وتخزينها في قاعدة السمات. أما مرحلة الاختبار، فيقوم المستخدم بإدخال صورة إلى هذا النظام كصورة استعلام (دخل)، والذي يقوم باستخراج شعاع السمات من هذه الصورة وقياس نسبة التشابه (باستخدام إحدى المسافات المعيارية)

(د) شبكة الـ AlexNet

تحتوي شبكة الـ AlexNet على ٦٠ مليون بارامتر و ٦٥٠ ألف خلية عصبية واستغرقت من خمسة إلى ستة أيام للتدريب على وحدتي معالجة GPX580 3GB، وتتكون بشكل عام من ٨ طبقات؛ خمس طبقات للالتفاف (Convolution Layers) وثلاث طبقات متصلة بالكامل (Full connected layers). وإذا أردنا التفصيل أكثر فإن شبكة الـ AlexNet تتكون من ٢٥ طبقة^[١٨]. يتم توزيع طبقات شبكة الـ AlexNet الخمس والعشرين بالطريقة التالية:

- طبقة الدخل حيث تستقبل هذه الطبقة الصور الملونة والتي حجمها هو (٢٢٧ × ٢٢٧).
- سبع طبقات من نوع ReLU.
- طبقتان من نوع "Norm".
- ثلاث طبقات من نوع "Pool".
- طبقتان من نوع "dropout".
- تسمى الطبقة التي تسبق الطبقة الأخيرة طبقة "Prob" أو "Softmax".
- طبقة الخرج التي تعطي الصنف الناتج عن عملية التصنيف.
- خمس طبقات "Conv" وثلاث طبقات من نوع "FC".

حيث تم تدريب شبكة الـ AlexNet على قاعدة الصور الطبية، لتصبح جاهزة لاستخدامها في استخراج

f_{DBji} ترمز إلى شعاع السمات للصورة z (المتحول z يشير ترتيب الصورة في قاعدة الصور) من قاعدة السمات في الموقع i من شعاع السمات.

L ترمز إلى طول شعاع السمات.

(ج) الخطوات الأساسية للخوارزمية المقترحة

تتألف الخوارزمية المقترحة من ست مراحل أساسية، كما هو موضح في الشكل ٢:

١- استخراج شعاع السمات الأول باستخدام شبكة الـ AlexNet (بعد تدريبها على قاعدة التدريب) وذلك من خرج الطبقة "drop7" (وحجمه ٤٠٩٦).

٢- استخراج شعاع السمات الثاني باستخدام حقيبة الكلمات المرئية Bag of Visual Word (وحجمه ٥٠٠).

٣- استخراج شعاع السمات الثالث باستخدام خوارزمية النمط الثنائي المحلي (وحجمه ٢٥٦).

٤ - تنظيم البيانات وتوحيد قيمها بين الصفر والواحد من خلال عملية تعرف بالـ Normalization وإعطاء كل شعاع من السمات وزن محدد وفقاً لأهميته.

٥- دمج هذه الأشعة لنحصل على شعاع سمات طويل نوعاً ما (وحجمه ٤٨٥٢).

٦- تقليص حجم شعاع السمات بتطبيق خوارزمية الـ PCA للحصول على شعاع قصير للسمات.

كل صورة في كل صنف باستخدام خوارزمية الميزات القوية السريعة (SURF-Speeded up Robust Features).

- الحفاظ على ٨٠٪ من أقوى الميزات لكل صنف.

- بناء قاموس مرئي باستخدام خوارزمية التجميع (K-Means) بحجم ٥٠٠ كلمة.

- استخدام مركز كل عنقود كمفردات القاموس المرئي (Visual Dictionary's Vocabularies).

مرحلة الاختبار، وتتلخص بالتالي:

يتم إدخال صورة الدخل ليتم تحديد النقاط المفتاحية في الصورة، واستخراج الواصفات من هذه النقاط، ليتم تجميع الواصفات بواسطة خوارزمية العنقدة K-means، ثم بناء الهستغرام بطول (٥٠٠ قيمة) وذلك من خلال مقارنة نتيجة العنقدة لواصفات الصورة مع حقبة (قاموس) الكلمات المرئية الذي قمنا ببنائه في مرحلة التدريب والذي سيكون شعاع السمات الناتج عن تطبيق فكرة حقبة الكلمات المرئية.

(و) خوارزمية النمط الثنائي المحلي (Local Binary Pattern)

خوارزمية الـ LBP هي الخوارزمية المقترحة للصور البنيوية (Texture Images) ذات الملمس المتشابه [٢١، ٢٢، ٢٣، ٢٤]. وهي ميزة قوية لتصنيف واسترجاع هكذا نوع من الصور. يتم بناء شعاع السمات الخاص بخوارزمية الـ LBP بالطريقة التالية:

السمات، حيث ندخل صورة بحجم 227×227 إلى الشبكة لنحصل على شعاع السمات من خرج الشبكة وبالتحديد من طبقة "drop7".

(هـ) حقبة الكلمات المرئية (BoVW)

الفكرة العامة لحقبة الكلمات المرئية [١٩، ٢٠]:

هي تمثيل الصورة كمجموعة من الميزات (السمات) والتي تتكون من النقاط الرئيسية (KeyPoints) والوصف (Descriptors). النقاط الأساسية هي النقاط "البارزة والأكثر أهمية" في الصورة، لذلك بغض النظر عن تدوير الصورة أو تقليصها أو توسيعها، فإن نقاطها الرئيسية ستكون دائماً هي نفسها. أما الوصف فهو استخراج السمات من هذه النقاط، حيث يتم استخدام النقاط الرئيسية والواصفات لبناء المفردات (Words) ونمثل كل صورة كرسم بياني (Histogram) للميزات الموجودة في الصورة.

بالتالي فإن الـ BoVW تتكون بشكل أساسي من مرحلتين هما:

مرحلة التدريب، والتي تتلخص بالخطوات

التالية:

- تنظيم قاعدة الصور على شكل فئات (أصناف).

- من أجل كل صنف، نختار ٦٠٪ من الصور بشكل عشوائي.

- نحدد النقاط الرئيسية للصور KeyPoints، ونستخرج الواصفات من هذه النقاط الرئيسية من أجل

من أجل كل بكسل في الصورة:

- نقارن البكسل مع كل من جيرانه الثمانية (بدءً من بكسل اليسار العلوي ثم البكسل الذي يوافق اتجاه عقارب الساعة).

- عندما تكون قيمة البكسل المركزي أكبر من قيمة الجار، نستبدل قيمة الجار بـ "٠". خلاف ذلك، نستبدل قيمته بـ "١".

- هذا يعطي رقم ثنائي مكون من ٨ أرقام (والذي يتم تحويله إلى عدد عشري) وقيم هذه الأرقام بين ٠ و ٢٥٥.

- بناء الهستغرام (الرسم البياني) للصورة والذي سيكون بحجم ٢٥٦ قيمة.

(ز) السمات المرجحة والمعدلة

تعديل قيم شعاع السمات (أو ما تعرف بعملية الـ Normalization) يكون من خلال قسمة كل قيمة من قيم شعاع السمات على المعيار الإقليدي (Euclidean norm) لهذا الشعاع (أي على الجذر التربيعي لمجموع مربعات عناصر الشعاع)، وهذا يعني جعل قيم الشعاع بين الصفر والواحد ومجموعها يساوي ١. كما ذكرنا سابقاً، لدينا ثلاثة أشعة سمات مميزة في خوارزمتنا المقترحة:

١. شعاع السمات الأول الذي نحصل عليه من شبكة الـ AlexNet وحجمه ٤٠٩٦، وبعد التعديل سيشار له بـ (FV_1) .

٢. شعاع السمات الثاني الذي نحصل عليه من

الـ BoVW وحجمه ٥٠٠، وبعد التعديل سيشار له بـ (FV_2) .

٣. شعاع السمات الثالث الذي نحصل عليه

من الـ LBP وحجمه ٢٥٦، وبعد التعديل سيشار له بـ (FV_3) .

يعرف المعيار الإقليدي ^[١٧] لعناصر الشعاع

كما في المعادلة ٣:

$$\|v\| = \sqrt{\sum_{k=1}^N |v_k|^2} \quad (3)$$

v_k : تشير إلى قيمة الشعاع v في الموقع k .

بعد تعديل قيم السمات يتم ترجيحها وذلك بإسناد وزن لكل شعاع معدل حسب أهميته (أي أن الوزن المسند للشعاع المعدل والمستخرج بواسطة شبكة الـ AlexNet المدربة سيكون أكبر من الوزن المسند للشعاع المعدل والمستخرج بواسطة حقيبة الكلمات المرئية)، لنحصل على شعاع السمات النهائي كما في المعادلة ٤:

$$\text{Final feature vector} = \alpha \times FV_1 + \beta \times FV_2 + \gamma \times FV_3 \quad (4)$$

$$\alpha, \beta, \text{ and } \gamma \in [0,1]$$

In our work

$$\alpha = 1, \beta = 0.3, \text{ and } \gamma = 0.1$$

خوارزمية الـ SVM هو نموذج خطي لمشاكل التصنيف. وبشكل أكثر تبسيطاً فإن دخل خوارزمية الـ SVM هو البيانات المراد الفصل بينها، وخرجها هو الخط الفاصل بين الأصناف (الخرج هو خطأ، إذا كان البيانات تتألف من بعدين فقط ولكن في حال كانت البيانات أكثر من بعدين فيتم الفصل بينها بواسطة سطح مألّف من عدة أبعاد). في خوارزمية الـ SVM، يتم تمثيل كل عنصر (شعاع سمات) من عناصر البيانات في فضاء الأبعاد والذي يتألف من n بعد (حيث n هو طول شعاع السمات الذي لدينا)، حيث أن النقاط الأقرب إلى الخط الفاصل بين الأصناف، تسمى بناقلات الدعم (Support Vectors). أما المسافة بين الخط الفاصل وناقلات الدعم فتعرف بالهامش (margin)، وهدفنا هو زيادة هذا الهامش. وعندما نحصل على أكبر هامش ممكن نكون قد حصلنا على الفاصل الأمثل بين الأصناف.

• خوارزمية الجار الأقرب للتصنيف (K-NN) (Nearest Neighbors)

خوارزمية الجار الأقرب (KNN) هي إحدى أنواع خوارزمية التعلم الآلي الخاضعة للإشراف والتي يمكن استخدامها لحل مشاكل التصنيف. تستخدم خوارزمية الـ KNN خاصية "تشابه السمات" للتنبؤ بصنف البيانات الجديدة، مما يعني أنه سيتم تصنيف نقطة البيانات الجديدة (شعاع السمات) بناءً على مدى تشابهها مع النقاط الأقرب لها في مجموعة التدريب. تتكون خوارزمية الـ KNN من الخطوات التالية:

حيث إن إشارة الـ "+" في المعادلة رقم (٤) تدل على عملية الوصل (concatenating) وليس عملية الجمع الرياضي.

(أ) تقليل حجم شعاع السمات

استخدمنا خوارزمية تحليل المكونات الأساسية (PCA-Principal Component Analysis) [٢٥] لتقليل حجم شعاع السمات لكل صورة من ٤٨٥٢ إلى القيمة N والتي تختلف من قاعدة صور إلى أخرى وتمثل مجموع القيم الذاتية (eigenvalues) التي يجب أن تكون ٩٨٪ من مجموع كل القيم الذاتية. ومعنى ذلك أن شعاع السمات الجديد يحتوي على معلومات وتفاصيل تعادل ٩٨٪ من الشعاع الأساسي ذات الـ ٤٨٥٢ بعد. وبالتالي فإن قيمة N تتحكم في أبعاد الميزات (السمات) المراد الحصول عليها.

(ب) التصنيف

في عملنا هذا، استخدمنا الخوارزمية المقترحة بدون تخفيض حجم شعاع السمات تارة، وتارة أخرى مع تطبيق خوارزمية الـ PCA لتخفيض السمات مع مصنفات التعلم بإشراف، وهي كالتالي:

- خوارزمية الـ (Support Vector Machine) [٢٦].

- خوارزمية تصنيف الجار الأقرب (K-NN) (Nearest Neighbors) [٢٧].

• خوارزمية الـ (Support Vector Machine)

- COVID-19 أي أن الشخص مصاب بمرض الكوفيد-١٩، وتحتوي على ٢٠٠ صورة متوفرة في [٢٨].

- NORMAL أي أن الشخص سليم، وتحتوي على ٤٠٠ صورة تم اختيارها بشكل عشوائي من [٢٩].

- PNEUMONIA BACTERIA أي أن الشخص مصاب بالتهاب رئوي جرثومي، وتحتوي على ٤٠٠ صورة تم اختيارها بشكل عشوائي من [٢٩].

- PNEUMONIA VIRUS أي أن الشخص مصاب بالتهاب رئوي فيروسي، وتحتوي أيضًا على ٤٠٠ صورة تم اختيارها بشكل عشوائي من [٢٩].

ب. قاعدة صور الأشعة المقطعية

فيما يتعلق بقاعدة صور الأشعة المقطعية فإنها تتألف من صنفين أساسيين لمنطقة الصدر وهما إما أن الشخص مصاب بمرض الكوفيد-١٩ أو أن الشخص غير مصاب. وبالتالي لدينا صنفين هما:

- COVID-19 وتحتوي على ٣٠٠ صورة.
- NONCOVID-19 وتحتوي على ٢٠٠ صورة.
تم اختيار هذه الصور بشكل عشوائي من موقع GitHub مفتوح المصدر المشار إليه في المرجع [٣٠].

ملاحظة

الصور في قواعد الصور اختيرت بشكل عشوائي من قواعد الصور المشار إليها في المراجع

الخطوة ١: تقسيم قاعدة البيانات إلى جزئين: قاعدة للتدريب والأخرى للاختبار.

الخطوة ٢: بعد ذلك، يتم اختيار قيمة الـ K (والتي تعبر عن عدد النقاط الأقرب التي سيتم الأخذ بعين الاعتبار فيها)، حيث أن K هو عدد طبيعي.

الخطوة ٣: من أجل كل نقطة في بيانات الاختبار، نقوم بما يلي:

- حساب المسافة الإقليدية بين العينة (شعاع السمات) المراد تصنيفها وكل نقاط التدريب من أجل كل صنف.

- ترتيب المسافات بشكل تصاعدي.

- اختيار أول K قيمة من المصفوفة المرتبة.

- تعيين صنف عينة الاختبار بناءً على الصنف الأكثر تكرارًا.

الخطوة ٤: النهاية.

٥- قواعد بيانات الصور المستخدمة

بالنسبة لمهام تصنيف واسترجاع الصور، استخدمنا نوعين من قواعد الصور الطبية وهما قاعدة صور الأشعة السينية، وقاعدة صور الأشعة المقطعية.

أ. قاعدة صور الأشعة السينية

فيما يتعلق بقاعدة صور الأشعة السينية فإنها تتألف من أربع أصناف رئيسية لمنطقة الصدر وهي كالتالي:

أنها ليست كوفيد-١٩، وهي في الواقع الكوفيد-١٩، وهذا يعرف بالخطأ من النوع الثاني).

يمكن اشتقاق خمس معايير هامة من مصفوفة قياس الموثوقية، ومن أجل جميع هذه المعايير فإن القيمة الأكبر هي القيمة الأفضل. وهذه المعايير هي:

- حساسية المصنف (Sensitivity) وتعرف أيضًا بـ Recall) وتحسب وفقا للقانون رقم (٥).

$$Recall = \frac{TP}{TP + FN} \dots \dots \dots (٥)$$

- نوعية المصنف (Specificity) وتحسب وفقًا للقانون رقم (٦).

$$Specificity = \frac{TN}{TN + FP} \dots \dots \dots (٦)$$

- نقاوة المصنف (Precision) وتحسب وفقًا للقانون رقم (٧).

$$Precision = \frac{TP}{TP + FP} \dots \dots \dots (٧)$$

- دقة المصنف (Accuracy) وتحسب وفقًا للقانون رقم (٨).

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \dots \dots \dots (٨)$$

- مقياس F (F-measure) ويحسب وفقًا للقانون رقم (٩).

$$F - measure = \frac{2 \times Recall \times Precision}{Recall + Precision} \dots \dots \dots (٩)$$

[٣٠-٣٨]، وتم رفع قواعد الصور التي تعاملنا معها في الرابط المشار إليه في المرجع [٣١].

٦- النتائج

أ. مهمة التصنيف

من أهم مقاييس الأداء الرئيسية [٣٢-٣٤] في مهمة التصنيف هي: مصفوفة قياس الموثوقية (أو ما تعرف بـ Confusion Matrix) وهي عبارة عن مصفوفة تحوي أربعة مكونات أساسية من القيم المتوقعة والفعلية. سنشرح هذه المكونات وفقًا لبحثنا هذا بالشكل التالي:

- المكون الصحيح الإيجابي (TP-True Positive): أي أن الصورة قد تم تصنيفها على أنها كوفيد-١٩ وهذا ما يعرف بالقيمة المتوقعة (Predicted value)، وهي فعلاً كوفيد-١٩، وهو ما يعرف بالقيمة الفعلية (Actual Value).

- المكون الصحيح السلبي (TN-True Negative): وهذا يعني أن القيمة الفعلية للصورة ليست كوفيد-١٩، ومصنفة (أي القيمة المتوقعة لها) على أنها ليست كوفيد-١٩.

- المكون الخاطئ الإيجابي (FP-False Positive): هذا يعني أن الصورة قد تم تصنيفها على أنها كوفيد-١٩، وهي في الواقع ليست كوفيد-١٩، وهذا يعرف بالخطأ من النوع الأول).

- المكون الخاطئ السلبي (FN-False Negative): هذا يعني أن الصورة قد تم تصنيفها على

فيما يخص تصنيف صور الأشعة السينية باستخدام مصنف الـ KNN:

- قمنا بحساب الدقة الكلية ودقة كل صنف، وحصلنا على دقة ٩٣,٩٢٪ للخوارزمية المقترحة و ٩١,٠٧٪ للخوارزمية المقترحة المعتمدة على تخفيض السمات، وهذه النتائج أفضل من الطرق الأخرى كما هو موضح في الجدول ٣-أ.

- نلاحظ أن الخوارزمية (دون استخدام الـ PCA) تعطي نتائج أفضل لأنها تحتوي على التفاصيل الكاملة للصورة مقارنة مع تخفيض السمات والتي تحتوي على ٩٨٪ من تفاصيل الصورة.

- يوضح الشكل ٣-أ: مصفوفة قياس الموثوقية للخوارزمية المقترحة مع مصنف الـ KNN.

- أما الشكل ٣-ب: فيوضح مصفوفة قياس الموثوقية للخوارزمية المقترحة المعتمدة على الـ PCA مع مصنف الـ KNN.

فيما يخص تصنيف صور الأشعة السينية باستخدام مصنف الـ SVM:

- قمنا أيضًا بحساب الدقة الإجمالية ودقة كل صنف، وحصلنا على دقة ٩٥,٧١٪ بدون تقليل أبعاد السمات و ٩٣,٢١٪ مع تقليل أبعاد السمات باستخدام الـ PCA، وهذه النتائج أفضل من الطرق الأخرى كما هو موضح في الجدول ٣-ب.

- يوضح الشكل ٣-ت: مصفوفة قياس الموثوقية للخوارزمية المقترحة مع مصنف الـ SVM.

بالنسبة لتصنيف الأشعة السينية والأشعة المقطعية، استخدمنا نوعين من المصنفات، آلة ناقل الدعم (SVM) والجار الأقرب (KNN). قمنا بمقارنة الخوارزمية المقترحة بدون استخدام الـ PCA تارة، وتارة أخرى مع الـ PCA مع:

- خوارزمية النمط الثنائي المحلي (LBP): والتي تعتبر خوارزمية غير ذكية (low-level) لاستخراج السمات لأنها تعمل على قيم البكسلات بشكل مباشر.

- خوارزمية حقيقية الكلمات المرئية (BoVW): والتي تعتبر خوارزمية نصف ذكية (mid-level) لأنها تستخلص بذكاء النقاط الهامة من الصورة وتحتوي في أحد مراحلها على خوارزمية التجميع والتي تعتبر أحد فروع الذكاء الاصطناعي.

- خوارزمية التعلم العميق بواسطة شبكة الأليكسنت (AlexNet): والتي تعتبر خوارزمية ذكية (high-level) لأنها تستخدم الشبكات العصبية العميقة والتي تحاكي في عملها عمل الخلايا العصبية في الدماغ.

- الخوارزمية الناتجة عن الدمج بين الخوارزمية الغير ذكية والخوارزمية الذكية (AlexNet + LBP).

- الخوارزمية الناتجة عن الدمج بين الخوارزمية نصف ذكية والخوارزمية الذكية (AlexNet + BoVW).

• تصنيف صور الأشعة السينية باستخدام

خوارزمية الـ KNN وخوارزمية الـ SVM

- قمنا بحساب الدقة الكلية والدقة لكل صنف،
وقمنا أيضاً بحساب المعايير الخمسة المشتقة من
مصفوفة قياس الموثوقية.

- حصلنا على دقة ٩٤ ٪ للخوارزمية المقترحة
و٩٣٪ للخوارزمية المقترحة المعتمدة على تقليل أبعاد
السمات باستخدام الـ PCA، وهذه النتائج أفضل من
الطرق الأخرى كما هو موضح في الجدول ٣-ث.

- أيضاً إن الخوارزمية المقترحة (دون استخدام
الـ PCA) تعطي نتائج أفضل لأنها تحتوي على
التفاصيل الكاملة للصورة مقارنة مع الخوارزمية
المعتمدة على تقليل أبعاد السمات.

- يوضح الشكل ٣-د: مصفوفة قياس
الموثوقية للخوارزمية المقترحة مع مصنف الـ KNN.
- أما الشكل ٣-د: فيوضح مصفوفة قياس
الموثوقية للخوارزمية المقترحة المعتمدة على الـ PCA
مع مصنف الـ KNN.

الخلاصة

بالنسبة للنتائج التي حصلنا عليها فهي تثبت
فعالية الدمج بين استخدام الطرق الأتوماتيكية والطرق
التقليدية لاستخراج السمات من الصور متنوعة
بالمصنفات التقليدية، وقد أثبتت فعاليتها أيضاً عند
مقارنتها مع دقة الخوارزميات التي اعتمدت على
شبكات التعلم العميق فقط كما هو موضح في الجدول

٤.

- أما الشكل ٣-ث: فيوضح مصفوفة قياس
الموثوقية للخوارزمية المقترحة المعتمدة على الـ PCA
مع مصنف الـ SVM.

• تصنيف صور الأشعة المقطعية باستخدام خوارزمية الـ KNN وخوارزمية الـ SVM

فيما يخص تصنيف صور الأشعة المقطعية
باستخدام مصنف الـ KNN:

- قمنا بحساب الدقة الكلية والدقة لكل صنف.
- ولأن هذا التصنيف هو تصنيف ثنائي، فقد
قمنا بحساب حساسية ونوعية ونقاوة ودقة المصنف
ومقياس F.

- حصلنا على دقة ٩٦ ٪ للخوارزمية المقترحة
و٩١٪ للخوارزمية المقترحة المعتمدة على تقليل أبعاد
السمات باستخدام الـ PCA، وهذه النتائج أفضل من
الطرق الأخرى كما هو موضح في الجدول ٣-ت.

- يوضح الشكل ٣-ج: مصفوفة قياس
الموثوقية للخوارزمية المقترحة مع مصنف الـ KNN.

- أما الشكل ٣-د: فيوضح مصفوفة قياس
الموثوقية للخوارزمية المقترحة المعتمدة على الـ PCA
مع مصنف الـ KNN.

فيما يخص تصنيف صور الأشعة المقطعية
باستخدام مصنف الـ SVM:

ملاحظة

تحليل المكونات الأساسية والتي أثبتت فعاليتها كما أوضحت النتائج السابقة.

ثانيًا: السبب في كون قاعدة الصور صغيرة نسبيًا هو حداثة الموضوع المعالج، وكان الهدف من هذه الدراسة بناء نموذج ذكي للكشف عن مرض الكوفيد-١٩، وتدريبه على الصور المتاحة لدينا، وحصلنا على نتائج واعدة في هذا المجال، وفي حال توفر قاعدة صور أكبر وأشمل يمكن إعادة تدريب النموذج المقترح.

ب. مهمة استرجاع الصور

تأتي أهمية استرجاع الصور بكونها تسترجع الصور الأكثر تشابهًا بناءً على قياس نسبة التشابه بواسطة المسافات المعيارية، وبذلك تكون منفصلة تمامًا عن نسبة الخطأ الموجودة في المصنف، فإذا أخطأ المصنف في تصنيف الصور فإن الصور المسترجعة بناءً على السمات المستخرجة من الصور وقياس نسبة التشابه لا تخطئ بالمطلق، فمثلاً إذا استرجعنا الصور العشر الأكثر تشابهًا من قاعدة الصور فإن غالبية الصور المسترجعة ستكون من صنف الصورة المختبرة وبذلك نستطيع التحقق من عمل المصنف في كونه صنف الصورة بطريقة صحيحة أم لا. علاوة على ذلك، فإن نفترض أن كل صورة مخزنة في قاعدة الصور تكون مرتبطة بالتقرير الطبي المرافق لهذه الحالة، وهذا يساعدنا في تشخيص الحالة المدروسة.

أولاً: الفكرة من استخدام ثلاث خوارزميات يكمن بكون شبكات التعلم العميق منفردة تحتاج إلى عدد كبير من الصور وهذا غير متوفر في موضوع دراستنا بسبب حداثة المرض، ولكن نعلم أيضًا أن شبكات التعلم العميق تفوق الخوارزميات التقليدية في التصنيف، ولذلك استفدنا من الشبكات التعلم العميق من خلال الـ Transfer learning لشبكة الـ AlexNet وذلك من خلال الحصول على السمات من الطبقة رقم ٢٣ (drop7) وذلك بعد تدريب الشبكة على قاعدة الصور المتوفرة، ولكن لم تكن النتائج مرضية بشكل كاف، وبسبب حساسية الموضوع المدروس استفدنا من مزايا الخوارزميات التقليدية التي لا تعتمد على عدد كبير من الصور، حيث أننا استخدمنا خوارزمية النمط الثنائي المحلي والتي تعالج قيم البكسلات والكثافة اللونية في الصور، وهذا يساعدنا بشكل كبير لأن مرض الكوفيد-١٩ يؤثر على الصور بما يعرف بـ عتامة الزجاج المطحون. كما أن خوارزمية حقيقية الكلمات المرئية تعتمد على تحديد النقاط الأساسية في الصورة واستخراج السمات وبالتالي شعاع السمات لن يتأثر بعمليات الجيومترية (الدوران، التكبير، التصغير). وبعد عمليات الدمج وتنظيم قيم البيانات واسناد الأوزان لها فإن حجم شعاع السمات يصبح كبيرًا بعض الشيء، وللتغلب على هذه المشكلة لجأنا إلى تقليص حجم شعاع السمات بواسطة خوارزمية

قارنا عملنا مع كلاً من:

- خوارزمية النمط المحلي الثاني (LBP-) (Local Binary Pattern).

- خوارزمية حقبة الكلمات المرئية (BoVW-) (Bag of Visual Words).

- خوارزمية التعلم العميق باستخدام شبكة الأليكسنت (AlexNet).

- الخوارزمية الناتجة عن الدمج بين (AlexNet + LBP).

- الخوارزمية الناتجة عن الدمج بين (AlexNet + BoVW).

١- نتائج استرجاع الصور من أجل قاعدة صور الأشعة السينية باستخدام المسافة الإقليدية ومسافة سيتي بلوك Cityblock

في الجدول ٥-أ نلاحظ أن الدقة Precision والاستدعاء Recall ومتوسط الدقة mAP للخوارزمية المقترحة هم الأفضل، حيث تحسنت قيمة الدقة Precision من ٨٨,٥٣٪ لخوارزمية (AlexNet + BoVW) إلى ٩١,٢١٪ في خوارزمتنا المقترحة، وتحسنت قيمة الاستدعاء Recall من ٨١,٠٤٪ لخوارزمية (AlexNet + BoVW) إلى ٨٢,٩١٪، كما تحسنت قيمة mAP من ٨٣,٨٤٪ لخوارزمية (AlexNet + BoVW) إلى ٨٦,٩٧٪. ونلاحظ أيضًا في الشكل ٤-أ: منحنيات الدقة Precision Curves باعتبار خرج عملية استرجاع الصور هو ١٠، ٢٠،

لتقييم عملنا في استرجاع الصور استخدمنا

معايير الدقة (Precision) والاستدعاء (Recall) ومتوسط الدقة (mean Average Precision) [٣٢]. يمكن حساب الدقة والاستدعاء ومتوسط الدقة كما في المعادلات ١٠-١٢:

$$(١٠) \dots \dots \dots Precision = \frac{No. of retrieved relevant images}{No. of relevant images}$$

$$(١١) \dots \dots \dots Recall = \frac{No. of retrieved relevant images}{No. of retrieved images}$$

$$(١٢) \dots \dots \dots mAP = \frac{1}{N} \sum_{i=1}^N Average\ precision_i$$

من أجل كلٍ من قاعد صور الأشعة السينية وقاعدة صور الأشعة المقطعية:

- نحسب الدقة Precision (والتي نحصل عليها عندما نسترجع ١٠ صور فقط)، والاستدعاء Recall (والذي نحصل عليه عندما نسترجع ١٠٠ صور فقط) ومتوسط الدقة mAP التي تحسب على النحو التالي:

من أجل كل صورة في قاعدة الصور، نحسب الدقة عندما يكون الخرج فقط ١٠ صور، ٢٠ صورة، ٣٠ صورة، وحتى الـ ١٠٠ صورة، ثم نأخذ المتوسط ونكرر هذا الإجراء لجميع الصور في قاعدة الصور.

- من أجل قياس التشابه فإننا استخدمنا مقياسين مختلفين للتشابه وهما المسافة الإقليدية Euclidean ومسافة سيتي بلوك Cityblock.

وحتى ١٠٠ للخوارزمية المقترحة مع الخوارزميات الخمس السابقة باستخدام المسافة الإقليدية.

في الجدول ٥-ب نلاحظ أن الدقة Precision والاستدعاء Recall ومتوسط الدقة mAP للخوارزمية المقترحة هم الأفضل، حيث تحسنت قيمة الدقة Precision من ٨٨,٣٥٪ لخوارزمية (AlexNet + BoVW) إلى ٩٠,٢١٪ في خوارزمتنا المقترحة، وتحسنت قيمة الاستدعاء Recall من ٧٩,٢٩٪ لخوارزمية (AlexNet + BoVW) إلى ٨١٪، كما تحسنت قيمة mAP من ٨٢,٨٤٪ لخوارزمية (AlexNet + BoVW) إلى ٨٤,٩٧٪. ونلاحظ أيضًا في الشكل ٤-ب: منحنيات الدقة Precision Curves للخوارزمية المقترحة مع الخوارزميات الخمس السابقة باستخدام مسافة سيتي بلوك.

٢- نتائج استرجاع الصور من أجل قاعدة صور الأشعة المقطعية باستخدام المسافة الإقليدية

ومسافة سيتي بلوك Cityblock

في الجدول ٥-ت نلاحظ أن الدقة Precision والاستدعاء Recall ومتوسط الدقة mAP للخوارزمية المقترحة هم الأفضل، حيث تحسنت قيمة الدقة Precision من ٨٠,٠٦٪ لخوارزمية (AlexNet +

BoVW) إلى ٨٦,٢١٪ في خوارزمتنا المقترحة، وتحسنت قيمة الاستدعاء Recall من ٦٦,٤٠٪ لخوارزمية (AlexNet + BoVW) إلى ٧٠,١٢٪، كما تحسنت قيمة mAP من ٧١,٢٨٪ لخوارزمية (AlexNet + BoVW) إلى ٧٨,٨٤٪. ونلاحظ أيضًا في الشكل ٤-ت: منحنيات الدقة Precision Curves للخوارزمية المقترحة مع الخوارزميات الخمس السابقة باستخدام المسافة الإقليدية.

في الجدول ٥-ث نلاحظ أن الدقة Precision والاستدعاء Recall ومتوسط الدقة mAP للخوارزمية المقترحة هم الأفضل، حيث تحسنت قيمة الدقة Precision من ٧٩,١٤٪ لخوارزمية (AlexNet + BoVW) إلى ٨٤,٢١٪ في خوارزمتنا المقترحة، وتحسنت قيمة الاستدعاء Recall من ٦٣,٩٤٪ لخوارزمية (AlexNet + BoVW) إلى ٧٠٪، كما تحسنت قيمة mAP من ٦٩,١٩٪ لخوارزمية (AlexNet + BoVW) إلى ٧٧,٣٣٪. ونلاحظ أيضًا في الشكل ٤-ث: منحنيات الدقة Precision Curves للخوارزمية المقترحة مع الخوارزميات الخمس السابقة باستخدام مسافة سيتي بلوك.

جدول ٢. بعض الدراسات المرجعية التي ناقشت الكشف عن مرض الكوفيد-١٩ باستخدام التعلم العميق.

البحث	نوع قاعدة الصور	تفاصيل قاعدة الصور (نوع الصنف، عدد الصور في الصنف)	نسبة التقسيم	الطريقة المستخدمة	الدقة
Xiaowei et al [10].	صور الأشعة المقطعية وعددها ٦١٨ صورة	كوفيد-١٩، ٢١٩	نستخدم ٨٥٪ للتدريب	استخدم شبكة الـ ResNet-18 لاستخراج السمات وتابع البيزيان (Bayesian function) من أجل تصنيف الصور	الدقة ٨٥,٤٪
		التهاب رئوي، ٢٢٤			
		سليم، ١٧٥	والباقي للاختبار		
Jinyu et al.[2]	صور الأشعة المقطعية وعددها ٤٧٠ صورة	كوفيد-١٩، ٢٧٥	نستخدم ٧٥٪ للتدريب	استخدم شبكة الـ DeseNet لاستخراج السمات وتصنيف الصور	الدقة ٨٤,٧٪
			و ١٠٪ للتحقق		
		سليم، ١٩٥	والباقي للاختبار		
Wang et al.[11]	صور الأشعة المقطعية وعددها ٤٥٣ صورة	كوفيد-١٩، ١٩٥	نستخدم ٧٠٪ للتدريب	استخدم شبكة الـ M-Inception لاستخراج السمات وأشجار القرار (tree) للتصنيف	الدقة ٨٩,٥٪
		سليم، ٢٥٨	والباقي للاختبار		
Ying et al.[12]	صور الأشعة المقطعية وعددها ٢٧٥ صورة	كوفيد-١٩، ٨٨	نستخدم ٦٠٪ للتدريب	استخدم شبكة الـ DRE-Net لاستخراج السمات والتصنيف	الدقة ٨٦٪
		التهاب رئوي فيروسي، ١٠١	و ١٠٪ للتحقق		
		(سليم، ٨٦)	والباقي للاختبار		
Zheng et al.[13]	صور الأشعة المقطعية وعددها ٥٤٢ صورة	كوفيد-١٩، ٣١٣	نستخدم ٨٠٪ للتدريب	استخدم شبكة الـ DeCoVNet لاستخراج السمات والتصنيف	الدقة ٩٠,٨٪
		سليم، ٢٢٩	والباقي للاختبار		
Lin Li et al.[14]	صور الأشعة المقطعية وعددها ٤٣٥٦ صورة	كوفيد-١٩، ١٢٩٦	نستخدم ٩٠٪ للتدريب	استخدم شبكة الـ CovNet لاستخراج السمات والتصنيف	الدقة ٩٠٪
		التهاب رئوي، ١٧٣٥			
		سليم، ١٣٢٥	والباقي للاختبار		
Narin et al.[15]	صور الأشعة السينية وعدها ١٠٠ صورة	كوفيد-١٩، ٥٠	نستخدم ٨٠٪ للتدريب	استخدم شبكة الـ Inception-ResNetV2 لاستخراج السمات والتصنيف	الدقة ٨٧٪
		سليم، ٥٠	والباقي للاختبار

شكل ١. المخطط التدفقي للبحث والذي يتألف من مهمتين أساسيتين: هما تصنيف الصور واسترجاع الصور.

شكل ٢. المخطط التدفقي لخوارزمية استخراج السمات المقترحة والتي هي المرحلة الأهم في مهمني تصنيف واسترجاع الصور.

جدول ٣. دقة التصنيف للخوارزمية المقترحة مقارنة مع الطرق الأخرى باستخدام: أ. مصنف الجار الأقرب (KNN)، ب: مصنف ال-SVM، ت: مصنف الجار الأقرب (KNN)، ث: مصنف ال-SVM، من أجل قاعدة صور الأشعة المقطعية.

<i>X-Ray KNN</i>	<i>Accuracy</i>	<i>COVID-19</i>	<i>NORMAL</i>	<i>BACTERIA</i>	<i>VIRUS</i>
<i>LBP</i>	70.00	72.50	83.75	65.00	60.00
<i>BoVW</i>	79.28	85.00	93.75	81.25	60.00
<i>AlexNet</i>	84.64	92.50	93.75	90.00	66.25
<i>AlexNet+LBP</i>	87.14	100.00	100.00	85.00	70.00
<i>AlexNet+BoVW</i>	87.85	100.00	100.00	87.50	70.00
<i>Proposed</i>	93.92	100.00	100.00	92.50	86.25
<i>PCA-Proposed</i>	91.07	97.50	100.00	91.25	78.75

ب

<i>X-Ray SVM</i>	<i>Accuracy</i>	<i>COVID-19</i>	<i>NORMAL</i>	<i>BACTERIA</i>	<i>VIRUS</i>
<i>LBP</i>	73.21	85.00	86.25	63.75	63.75
<i>BoVW</i>	81.78	80.00	96.25	80.00	70.00
<i>AlexNet</i>	87.85	95.00	93.75	86.25	80.00
<i>AlexNet+LBP</i>	89.28	95.00	97.50	83.75	83.75
<i>AlexNet+BoVW</i>	90.00	97.50	96.25	86.25	83.75
<i>Proposed</i>	95.71	100.00	97.50	95.00	92.50
<i>PCA-Proposed</i>	93.21	97.50	100.00	88.75	88.75

ت

<i>CT SCAN KNN</i>	<i>Accuracy</i>	<i>COVID-19</i>	<i>NOTCOVID-19</i>	<i>Sensitivity</i>	<i>Specificity</i>	<i>Precision</i>	<i>F-measure</i>
<i>LBP</i>	73.00	76.66	67.50	77.97	65.85	76.67	77.31
<i>BoVW</i>	77.00	76.66	77.50	83.64	68.89	76.67	80.00
<i>AlexNet</i>	85.00	93.33	72.50	83.58	87.88	93.33	88.19
<i>AlexNet+LBP</i>	87.00	95.00	75.00	85.07	90.91	95.00	89.76
<i>AlexNet+BoVW</i>	89.00	90.00	87.50	91.53	85.37	90.00	90.76
<i>Proposed</i>	96.00	98.33	92.50	95.16	97.37	98.33	96.72
<i>PCA-Proposed</i>	91.00	95.00	85.00	90.48	91.89	95.00	92.68

ث

<i>CT SCAN SVM</i>	<i>Accuracy</i>	<i>COVID-19</i>	<i>NOTCOVID-19</i>	<i>Sensitivity</i>	<i>Specificity</i>	<i>Precision</i>	<i>F-measure</i>
<i>LBP</i>	73.00	76.66	67.50	77.97	65.85	76.67	77.31
<i>BoVW</i>	75.00	80.00	67.50	78.69	69.23	80.00	79.34
<i>AlexNet</i>	85.00	95.00	70.00	82.61	90.32	95.00	88.37
<i>AlexNet+LBP</i>	87.00	93.33	77.50	86.15	88.57	93.33	89.60
<i>AlexNet+BoVW</i>	92.00	91.66	92.50	94.83	88.10	91.67	93.22
<i>Proposed</i>	94.00	96.66	90.00	93.55	94.74	96.67	95.08
<i>PCA-Proposed</i>	93.00	96.66	87.50	92.06	94.59	96.67	94.31

جدول ٤. يوضح دقة التصنيف (**Accuracy**) للخوارزمية المقترحة مقارنة مع الطرق الأخرى المعتمدة على التعلم العميق من أجل قاعدة صور الأشعة السينية وقاعدة صور الأشعة المقطعية.

Method	X-RAY DB	CT DB
Xiaowei et al [10]	88.40	87.30
Narin et al [15]	90.50	89.60
Proposed +KNN	93.92	96.00
Proposed +SVM	95.71	94.00

شكل ٣. أ: مصفوفة قياس الموثوقية للخوارزمية: أ: المقترحة مع مصنف KNN. ب: المقترحة المعتمدة على الـ PCA مع مصنف KNN. ت: المقترحة مع مصنف SVM. ث: المقترحة المعتمدة على الـ PCA مع مصنف SVM. ج: المقترحة مع مصنف KNN. د: المقترحة المعتمدة على الـ PCA مع مصنف KNN. ذ: المقترحة مع مصنف SVM. د: المقترحة المعتمدة على الـ PCA مع مصنف SVM لقاعدة صور الأشعة المقطعية.

جدول ٥. الدقة Precision والاستدعاء Recall ومتوسط الدقة mAP للخوارزمية المقترحة والطرق الأخرى باستخدام: أ.

المسافة الإقليدية وقاعة صور الأشعة السينية. ب. مسافة سيتي بلوك وقاعة صور الأشعة السينية. ت: المسافة

الإقليدية وقاعة صور الأشعة المقطعية. ث: مسافة سيتي بلوك وقاعة صور الأشعة المقطعية.

أ

X-Ray EUC	Precision	Recall	mAP
LBP	65.42%	47.66%	55.02%
BoVW	75.16%	55.83%	62.81%
AlexNet	86.06%	74.78%	79.05%
AlexNet+LBP	88.49%	79.90%	83.26%
AlexNet+BoVW	88.53%	81.04%	83.84%
Proposed	91.21%	82.91%	86.97%

ب

X-RAY CITY	Precision	Recall	mAP
LBP	71.50%	53.36%	59.36%
BoVW	79.74%	60.82%	67.87%
AlexNet	85.15%	72.79%	77.27%
AlexNet+LBP	87.89%	79.36%	82.79%
AlexNet+BoVW	88.35%	79.29%	82.84%
Proposed	90.21%	81.00%	84.97%

ت

CT EUC	Precision	Recall	mAP
LBP	69.80%	54.73%	58.67%
BoVW	71.22%	57.65%	61.64%
AlexNet	74.02%	59.91%	61.46%
AlexNet+LBP	79.08%	63.79%	69.09%
AlexNet+BoVW	80.06%	66.40%	71.28%
Proposed	86.21%	70.12%	78.84%

ث

CT CITY	Precision	Recall	mAP
LBP	71.58%	55.22%	59.37%
BoVW	72.98%	57.89%	62.42%
AlexNet	70.68%	59.61%	63.24%
AlexNet+LBP	77.40%	62.30%	67.41%
AlexNet+BoVW	79.14%	63.94%	69.19%
Proposed	84.21%	70.00%	77.33%

شكل ٤. منحى الدقة للخوارزمية المقترحة والطرق الأخرى باستخدام: أ. المسافة الإقليدية وقاعة صور الأشعة السينية. ب:

مسافة سيتي بلوك وقاعة صور الأشعة السينية. ت: المسافة الإقليدية وقاعة صور الأشعة المقطعية. ث: مسافة

السيتي بلوك وقاعة صور الأشعة المقطعية.

المراجع

- [1] **Li, Q. et al.**, "Early Transmission Dynamics in Wuhan, China, of Novel Coronavirus-Infected Pneumonia", *New England Journal of Medicine*, **382** (13): 1199-1207, 2020. Available: 10.1056/nejmoa2001316.
- [2] **Yang, X., He, X., Zhao, J., Zhang, Y., Zhang, S. and Xie, P.**, "COVID-CT-Dataset: A CT Image Dataset about COVID-19", *arXiv: 2003.13865*, 2020.
- [3] **Ai, T. et al.**, "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, 2020. Available: 10.1148/radiol.2020200642.
- [4] **Samsami, M., Bagherpour, J., Nematihonar, B. and Tahmasbi, H.**, "COVID-19 Pneumonia in Asymptomatic Trauma Patients; Report of 8 Cases", *Archives of Academic Emergency Medicine*, **8**(1), 2020.
- [5] "Diagnostic Imaging in COVID-19 Chest X-ray and CT", *European Society of Cardiology*, 2020.
- [6] **Xu, X. et al.**, "Imaging and clinical features of patients with 2019 novel coronavirus SARS-CoV-2", *European Journal of Nuclear Medicine and Molecular Imaging*, **47** (5): 1275-1280, 2020. Available: 10.1007/s00259-020-04735-9.
- [7] **Lin, C. et al.**, "Asymptomatic novel coronavirus pneumonia patient outside Wuhan: The value of CT images in the course of the disease", *Clinical Imaging*, **63**: 7-9, 2020. Available: 10.1016/j.clinimag.2020.02.008.
- [8] **Yang, W. et al.**, "The role of imaging in 2019 novel coronavirus pneumonia (COVID-19)", *European Radiology*, **30** (9): 4874-4882, 2020. Available: 10.1007/s00330-020-06827-4.
- [9] **Cozzi, D. et al.**, "Chest X-ray in new Coronavirus Disease 2019 (COVID-19) infection: findings and correlation with clinical outcome", *La radiologia medica*, **125** (8): 730-737, 2020. Available: 10.1007/s11547-020-01232-9.
- [10] **Xu, X. et al.**, "A Deep Learning System to Screen Novel Coronavirus Disease 2019 Pneumonia", *Engineering*, **6** (10): 1122-1129, 2020. Available: 10.1016/j.eng.2020.04.010.
- [11] **Wang, S. et al.**, "A deep learning algorithm using CT images to screen for Corona Virus Disease (COVID-19)", 2020. Available: 10.1101/2020.02.14.20023028.
- [12] **Ying, S. et al.**, "Deep learning Enables Accurate Diagnosis of Novel Coronavirus (COVID-19) with CT images", 2020. Available: 10.1101/2020.02.23.20026930.
- [13] **Zheng, C. et al.**, "Deep Learning-based Detection for COVID-19 from Chest CT using Weak Label", 2020. Available: 10.1101/2020.03.12.

٧- الخاتمة والأعمال المستقبلية

في هذا العمل قمنا ببناء نموذج أولي ذكي للكشف عن مرض الكوفيد-١٩ بالاعتماد على الذكاء الصناعي لتصنيف الصور الطبية واسترجاع الصور المتشابهة اعتماداً على المحتوى، واقترحنا طريقة جديدة لاستخراج السمات من خلال دمج ثلاثة أنواع من مستويات استخراج الميزات وقد اعتمدنا على خوارزمية تحليل المكون الرئيسي لتقليل أبعاد السمات، وقد حصلنا على نتائج واعدة في هذا المجال. في المستقبل، سنعمل على تطوير النظام المبني من خلال تدريبه على قواعد صور طبية أكبر وأشمل ليصبح قادراً على تحديد توقيت الإصابة بالمرض عند إجراء التصوير الشعاعي (الأسبوع الأول مثلاً أم الثاني وهكذا)، واستخدامه في مراقبة تطور أو انحسار المرض، بالإضافة إلى تدريب شبكات عصبونية عميقة قادرة على تحديد موقع الإصابة في الصور الشعاعية.

لابد أيضاً من ذكر أن النظام الذكي الذي تم اقتراحه يستخدم لتشخيص وكشف مرض الكوفيد-١٩ للحالات المشتبه فيها، أما الحالات التي نقل لها العدوى ولم تظهر أي أعراض المرض على الشخص المصاب، فإن بحثنا هذا مازال قاصراً على كشف مثل هذه الحالات حيث أن المرض لم يصل إلى الرئة بعد ولم يحدث أي تغييرات فيها.

- [24] **Ojala, T., Pietikäinen, M. and Harwood, D.,** "A comparative study of texture measures with classification based on featured distributions", *Pattern Recognition*,. **29** (1): 51-59, 1996. Available: 10.1016/0031-3203(95)00067-4.
- [25] **Jolliffe, I. and Cadima, J.,** "Principal component analysis: a review and recent developments", *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, **374** (2065): 20150202, 2016. Available: 10.1098/rsta.2015.0202.
- [26] **Smola, A. and Schölkopf, B.,** "A tutorial on support vector regression", *Statistics and Computing*, vol. 14, no. 3, pp. 199-222, 2004. Available: 10.1023/b:stco.0000035301.49549.88.
- [27] **Kuhn, M. and Johnson, K.,** "Applied Predictive Modeling", 2013. Available: 10.1007/978-1-4614-6849-3.
- [28] "Covid-19 Radiography Database", Kaggle.com, 2020. [Online]. Available: <https://www.kaggle.com/tawsifurrahman/Covid-19-radiography-database>.
- [29] "Chest X-Ray Images (Pneumonia)", Kaggle.com, 2020. [Online]. Available: <https://www.kaggle.com/paultimothymooney/chest-xray-pneumonia>.
- [30] "UCSD-AI4H/COVID-CT", GitHub, 2020. [Online]. Available: <https://github.com/UCSD-AI4H/COVID-CT>.
- [31] "Database for COVID-19 – Google Drive", Drive.google.com, 2020. Available: https://drive.google.com/drive/folders/15AsaS3KUKS1ciQsXtGSakhnLa0M9b_p7
- [32] **Powers, D.,** "Evaluation: from precision, recall and f-measure to roc, informedness, markedness & correlation", *Journal of Machine Learning Technologies*, **2** (1): 37-63, 2020. Available: 10.9735/2229-3981.
- [33] **Altman, D. and Bland, J.,** "Statistics Notes: Diagnostic tests 1: sensitivity and specificity", *BMJ*, **308** (6943): 1552-1552, 1994. Available: 10.1136/bmj.308.6943.1552.
- [34] **Fawcett, T.,** "An introduction to ROC analysis", *Pattern Recognition Letters*, **27** (8): 861-874, 2006. Available: 10.1016/j.patrec.2005.10.010.
- [14] **Li, L. et al.,** "Using Artificial Intelligence to Detect COVID-19 and Community-acquired Pneumonia Based on Pulmonary CT: Evaluation of the Diagnostic Accuracy", *Radiology*, **296** (2): E65-E71, 2020. Available: 10.1148/radiol.2020200905.
- [15] **Narin, A., Kaya, C. and Z. Pamuk,** "Automatic Detection of Coronavirus Disease (COVID-19) Using X-ray Images and Deep Convolutional Neural Networks", *arXiv:2003.10849*, 2020.
- [16] **Alrahhah, M. and Supreethi, K.,** "Content-Based Image Retrieval using Local Patterns and Supervised Machine Learning Techniques", *2019 Amity International Conference on Artificial Intelligence (AICAI)*, 2019. Available: 10.1109/aicai.2019.8701255.
- [17] **Alrahhah, M. and Supreethi, K.P.,** "Multimedia Image Retrieval System by Combining CNN With Handcraft Features in Three Different Similarity Measures", *International Journal of Computer Vision and Image Processing*, **10**(1): 1-23, 2020. Available: 10.4018/ijcvip.2020010101.
- [18] **Krizhevsky, A., Sutskever, I. and Hinton, G.,** "ImageNet classification with deep convolutional neural networks", *Communications of the ACM*, **60** (6): 84-90, 2017. Available: 10.1145/3065386.
- [19] **Bay, H., Ess, A., Tuytelaars, T. and Van Gool, L.,** "Speeded-Up Robust Features (SURF)", *Computer Vision and Image Understanding*, **110** (3): 346-359, 2008. Available: 10.1016/j.cviu.2007.09.014.
- [20] **Csurka, G., Dance, C., R. Fan, L., Willamowski, J. and Bray, C.,** "Visual Categorization with Bags of Keypoints", *Workshop on Statistical Learning in Computer Vision*, pp. 1-22, 2004.
- [21] **He, Dong-chen and Wang, Li,** "Texture Unit, Texture Spectrum, And Texture Analysis", *IEEE Transactions on Geoscience and Remote Sensing*, **28** (4): 509-512, 1990. Available: 10.1109/tgrs.1990.572934.
- [22] **Wang, L. and He, D.,** "Texture classification using texture spectrum", *Pattern Recognition*, **23** (8): 905-910, 1990. Available: 10.1016/0031-3203(90)90135-8.
- [23] **Ojala, T., Pietikainen, M. and Harwood, D.,** "Performance evaluation of texture measures with classification based on Kullback discrimination of distributions", *Proceedings of 12th International Conference on Pattern Recognition*. Available: 10.1109/icpr.1994.576366.

Detection of COVID-19 Disease Using Artificial Intelligence Techniques and Radiographic Medical Images

Maher Alrahhal and Mahmoud Rahhal

Computer Science department, Faculty of Electrical and Electronic Engineering, Aleppo University, Aleppo, Syria

Abstract. This study aims to emphasize the importance of screening COVID-19 disease using Artificial Intelligence and radiological images (chest X-ray and CT images), by extracting the features from the images and classifying them using standard classification algorithms. Finally, we combined the classification task with the retrieving task for its importance in facilitating comparison and diagnosis. We proposed a novel method for extracting features by combines both Handcraft and Automatic feature extraction methods, and we got better results from using one of the two methods. Our proposed method combines three levels of feature extraction, the Local Binary Pattern for extracting low-level feature extraction, Bag of Visual Word for mid-level, and the AlexNet, which relies on deep learning for high-level features. Finally, we weighted these features according to their importance, and we used Principal Component Analysis for dimension reduction.

Keyword: COVID-19 Disease; Local Binary Pattern; Bag of Visual Word; Deep Learning; Image Classification; Image Retrieval.