

Applying Transfer Learning Using DenseNet121 in Radiographic Image Classification

Nahla Saeed Saad Aldeen

Yosser Mohammad Marwan Atassi

Faculty of Information Technology || AlBaath University || Syria

Abstract: The study aims to apply one of the fully connected convolutional neural networks, DenseNet121 network, to a data sample that includes a large group of radiographs through transfer learning technology.

Radiography technology is a very important technique in the medical community to detect diseases and abnormalities that may be present, but the interpretation of these images may take a long time and it is subject to error by radiologists who are exposed to external practical factors (such as fatigue resulting from working for long hours, or exhaustion, or thinking about other life matters). To assist radiologists, we have worked on developing a diagnostic model with the help of a deep learning technique to classify radiographic images into two classes: (Normal and Abnormal images), by transferring the selected deep convolutional neural network between a large group of available networks that we studied on the basis of the regions that possibly abnormalities provided by the radiologists for the study sample.

We also studied the feasibility of using the well-known VGG16 model on the same data sample and its performance through transfer learning technology and compared its results with the results of the DenseNet121 network.

At the end of the research, we obtained a set of good results, which achieved a high diagnostic accuracy of 87.5% in some studied cases, using the DenseNet121 network model, which is considered satisfactory results in the case studied compared to the performance of other models. As for the VGG16 model, it did not give any of the satisfactory results in this field, the accuracy of the classification did not exceed 55% in most cases, and in only two cases it reached about 60% and 62%.

The model presented during the research - DenseNet121 model - can be used in the diagnostic process and help in obtaining accurate results in terms of diagnostic results. As for the VGG16 model, it does not give satisfactory results according to the results also obtained during the research, so it is excluded in this type of applications.

Keywords: Transfer learning, Machine Learning, Radiographic Image Classification, DenseNet121, Convolutional Neural Networks.

تطبيق التعلم بالنقل باستخدام شبكة DenseNet121 في تصنيف الصور الشعاعية

نهله سعيد سعد الدين

يسر محمد مروان الأتاسي

كلية الهندسة المعلوماتية || جامعة البعث || سوريا

المستخلص: هدفت الدراسة إلى تطبيق إحدى الشبكات العصبونية التلافيفية المتصلة كلياً وهي شبكة DenseNet121 على عينة بيانات تضم مجموعة كبيرة من الصور الشعاعية من خلال تقنية التعلم بالنقل.

تعد تقنية التصوير الشعاعي تقنية مهمة جداً في المجتمع الطبي للكشف عن الأمراض والتشوهات التي من الممكن وجودها، إلا أن تفسير هذه الصور قد يستغرق وقتاً طويلاً كما أنه معرض للخطأ من قبل أخصائي الأشعة الذين يتعرضون للعوامل العملية الخارجية (مثل التعب الناتج عن العمل لساعات طويلة، أو الإرهاق، أو التفكير بأمور الحياة الأخرى). ولمساعدة أخصائي الأشعة، قمنا بالعمل على تطوير نموذج تشخيص بمساعدة إحدى تقنيات التعلم العميق لتصنيف الصور الشعاعية إلى تصنيفين: (صور طبيعية وصور غير طبيعية). وذلك من خلال نقل الشبكة العصبونية التلافيفية العميقة المختارة بين مجموعة شبكات كبيرة متوفرة قمنا بدراستها على أساس المناطق التي من المحتمل أن تكون غير طبيعية والتي يوفرها اختصاصيو الأشعة لعينة الدراسة. كما قمنا بدراسة جدوى استخدام نموذج VGG16 المعروف على نفس عينة البيانات ودراسة أدائه أيضاً من خلال تقنية التعلم بالنقل ومقارنة نتائجه مع نتائج شبكة DenseNet121.

حصلنا في نهاية البحث على مجموعة من النتائج الجيدة، والتي حققت دقة تشخيص عالية بلغت 87.5% في بعض الحالات المدروسة بالاستفادة من نموذج شبكة DenseNet121 والتي تعتبر نتائج مرضية في الحالة المدروسة مقارنة مع أداء النماذج الأخرى، أما نموذج VGG16 فلم يعطي أي من النتائج المرضية في هذا المجال المدروس ولم تتجاوز دقة التصنيف 55% في معظم الحالات، وصلت في حالتين فقط إلى حوالي 60% و62%.

يمكن الاستفادة من النموذج الذي تم تقديمه خلال البحث- نموذج DenseNet121 - في عملية التشخيص المطروحة والمساعدة بالحصول على نتائج دقيقة من ناحية نتائج التشخيص، أما نموذج VGG16 فلا يعطي نتائج مرضية وفق ما تم الحصول عليه من نتائج أيضاً خلال البحث، لذلك يتم استبعاده في هذا النوع من التطبيقات.

الكلمات المفتاحية: التعلم بالنقل، تعلم الآلة، تصنيف الصور الشعاعية، DenseNet121، شبكة عصبية تلافيفية.

1- المقدمة.

تعد الصور الشعاعية من أكثر الصور التي يتم الحصول عليها بشكل متكرر في المجال الطبي وقد أصبحت موضوعاً لأبحاث الرؤية الحاسوبية. معظم النماذج الحديثة المستخدمة لتصنيف الصور الشعاعية مستمدة من الشبكات العصبية العميقة المتاحة والمدرّبة على مجموعات بيانات الصور الكبيرة، تم إنجاز أعمال كبيرة لتصميم أنظمة تشخيص بمساعدة الحاسب (Computer Aided Diagnosing) CAD مساعدة في المجال الطبي عموماً ومجال الصور الشعاعية خصوصاً [6].

عادةً ما يكون تحديد المناطق غير الطبيعية في الصور (أو ما يسمى عادة حالات Abnormality) هو الخطوة الأساسية والأهم في جميع أنظمة CAD. كما يمكن أن تكون هذه الأنظمة مفيدة عندما يصعب على أخصائي الأشعة اكتشاف أو تحديد المناطق غير الطبيعية نظراً للمحتويات المعقدة في الصور. إضافة إلى ذلك، يتم تطبيق أنظمة التشخيص بشكل عام لمساعدة أخصائي الأشعة على اتخاذ قرارات بشأن تشخيص الصور عند الضرورة [24].

نقوم بالعمل على تحديد أنسب نموذج لتصنيف صور الأشعة السينية لعظام الطرف العلوي على أنها طبيعية أو غير طبيعية بحيث يمكن للدراسة أن تساعد الأطباء الذين ليسوا خبراء في المجال في مرحلة تصنيف الصور الشعاعية، والتي يتم مواجهتها بشكل متكرر في أقسام الطوارئ بالمستشفيات.

2- الدراسات ذات الصلة:

1-2 - دراسات ذات صلة بالبيانات:

تم تقديم مجموعة بيانات MURA لأول مرة في مؤتمر "التصوير الطبي مع التعلم العميق" الذي عقد في أمستردام عام 2018، وتم إتاحة مجموعة البيانات هذه للدراسات الأكاديمية في مسابقة تسمى "Bone X-Ray Deep".

"Learning Competition" من قبل مجموعة Machine Learning في جامعة ستانفورد لكونها واحدة من أكبر مجموعات بيانات الصور الشعاعية.

هناك دراسات كثيرة تم إجراؤها ونشرها باستخدام مجموعة البيانات بأكملها أو جزء منها. هذه الدراسات كانت كما يلي:

تم تحقيق متوسط دقة بنسبة 62.04% في إجراء الكشف عن الكسور باستخدام نموذج CNN العميق المقترح بعد أن تم وسم وتمييز الكسور من قبل الأطباء على صور الأشعة السينية للذراع في مجموعة بيانات MURA بواسطة Guan وآخرون [7].

كما أجرى كل من Wang و Shao تصنيف باستخدام مجموعة بيانات MURA بالكامل، بحيث تم تطوير طريقة من مرحلتين، وكانت أعلى دقة تم تحقيقها في صور عظم العضد بنسبة 88.5% لنموذج SENet154، بينما تم تحقيق أعلى دقة لنموذج DenseNet201 على صور العضد بنسبة 90.94% [18].

في التصنيف الذي أجراه Cheng وآخرون باستخدام مجموعة بيانات تحتوي على صور عظم الورك ومجموعة بيانات MURA بأكملها، كانت أعلى دقة تم تحقيقها هي 86.53% لصور عظم العضد [2].

تم تحقيق دقة تصنيف بواسطة Pelka وآخرون الذين قاموا باستخدام مجموعة بيانات MURA أيضاً بالكامل 79.85% مع نموذج InceptionV3 [12].

كما قام Harini بتصنيف صور الإصبع والمعصم والكتف في مجموعة بيانات MURA باستخدام خمس طرق مختلفة للتعلم العميق المبنية على أساس CNN، كانت أعلى دقة 56.30% في بيانات المعصم باستخدام DenseNet169 [8].

في تصنيف النوع الذي قام به Pradhan وآخرون باستخدام مجموعة بيانات MURA بالكامل، تم تحقيق دقة 91.37% مع نموذج CNN العميق المقترح [13].

كانت درجة الدقة في التصنيف الذي أجراه Varma وآخرون 88% على مجموعة بيانات الأشعة (LERA) التي تحتوي على بيانات القدم والركبة والكاحل والورك لنموذج ImageNet و DenseNet161 مُدرَّب مسبقاً مع MURA [21].

حقق Khan و Kim دقة 93.5% في تصنيف عدم انتظام ضربات القلب باستخدام الذاكرة طويلة المدى (LSTM) [10].

تم استخدام نموذجي ResNet18 و GoogLeNet من قبل Storey للكشف عن الشذوذ في عظام الرسغ [19]. كما تم الحصول على دقة 88.6% في تصنيف Yin وآخرون للأمراض الكلى باستخدام طريقة التعلم العميق متعددة المثيلات [23].

وأخيراً، تم الحصول على أعلى دقة بنسبة 81.98% مع نموذج SqueezeNet لاكتشاف التشوهات العظمية الهيكلية التي قام بها Dias [4].

2-2 - دراسات ذات صلة بالتعلم بالنقل:

تتطلب شبكات CNN العميقة عادةً كميات كبيرة من البيانات المصنفة لغرض التدريب لتجنب فرط التجهيز، لذلك يتم تطبيق التعلم بالنقل - وهي طريقة فعالة لحالات ندرة البيانات - على نطاق واسع باستخدام بنى كلاسيكية مدربة مسبقاً على ImageNet.

تم تطبيق التعلم بالنقل لتصنيف شذوذ الدماغ الآلي باستخدام صور MR في [20]، بحيث تم اقتراح نهج يستخدم التعلم العميق بالنقل لتصنيف صور الرنين المغناطيسي للدماغ الطبيعية وغير الطبيعية تلقائياً. وتم استخدام نموذج ResNet34 المبني على الشبكة العصبية التلافيفية (CNN) كنموذج التعلم العميق. كما تم استخدام تقنيات التعلم العميق الحالية مثل زيادة البيانات، ومكتشف معدل التعلم الأمثل والضبط الدقيق لتدريب النموذج. وقد حقق النموذج المقترح دقة تصنيف بنسبة اقترنت من 100% على 613 صورة بالرنين المغناطيسي.

كما تم العمل على تصنيف أورام الدماغ باستخدام ميزات CNN العميقة عن طريق التعلم بالنقل في [3]، بحيث تم العمل على مشكلة تصنيف من ثلاث فئات للتمييز بين الأورام الدبقية والورم السحائي وأورام الغدة النخامية، والتي تشكل ثلاثة أنواع بارزة من أورام المخ. تبني نظام التصنيف المقترح مفهوم التعلم بالنقل وتم استخدام شبكة GoogleNet المدربة مسبقاً لاستخراج الميزات من صور التصوير بالرنين المغناطيسي للدماغ. سجل النموذج المقترح متوسط دقة تصنيف بنسبة 98%. وتمت الإشارة في هذه الدراسة إلى أهمية التعلم بالنقل كأسلوب مفيد عندما يكون توافر الصور الطبية محدوداً.

في الدراسة [5] قام الباحثون بتطبيق التعلم بالنقل العميق لتصنيف الصور المقطعية بالموجات فوق الصوتية، وتكونت الدراسة من تطبيق نماذج التعلم بالنقل Inception V3 و MobileNet و NasNet و Ameobanet على صور التصوير المقطعي بالموجات فوق الصوتية (USCT) لتصنيفها إلى ثلاث فئات. ووصلت دقة الاختبار إلى 96% مع مدة زمنية قصيرة.

3- مشكلة الدراسة:

يعتبر عمل أخصائي الأشعة في تصنيف الصور الشعاعية من الأعمال المهمة جداً في المجال الطبي بسبب ما يترتب على نتائج التشخيص والتصنيف من أمور تتعلق بالمرضى لاحقاً.

وبالرغم من أن شبكات CNN العميقة قد استخدمت على نطاق واسع في مجالات واسعة منها التحليل والتشخيص الطبي [22]، وبناءً على الدراسات السابقة التي تم تقديمها في القسم السابق إلا أنه لا تزال هناك بعض المشكلات التي يتعين حلها في الاستخدام العملي، ومن المشاكل العملية: الحجم المحدود لبيانات التدريب والتي تعتبر مشكلة عامة في مجالات التعلم بالآلة والتعلم العميق.

التعلم بالنقل الذي تم تقديمه لتبني المصنفات المدربة لفئات أخرى لتصنيف فئات معينة، تبين من خلال الدراسات أنه طريقة فعالة أيضاً لحل مثل هذه الحالات [14]. ولهذا قمنا بالعمل على تطبيقه ودراسة دوره في عينة البيانات المستخدمة في بحثنا هذا.

تظهر نماذج التعلم العميق في التصوير الطبي الشيء الذي لا تزال تفتقر إليه هذه النماذج بشكل كبير وهو القدرة على تعميم النتائج على البيانات الواقعية غير المرئية (ظروف الحياة الواقعية التي تختلف عادةً عن تلك التي نواجهها أثناء التدريب)، لذلك عندما نريد تطبيق نموذج عملياً، من المحتمل أن نفشل.

كما أنه غالباً ما تكون بيانات التدريب المتوفرة محدودة، وهذا يقيد أداء النماذج العميقة، كونه مرتبط بعدد عينة البيانات المتوفرة، لذلك يبقى الحل الوحيد هو العثور على المزيد من البيانات. إلا أنه ليس من الممكن دائماً العثور على البيانات التي نريدها بالضبط (وهي حالة شائعة جداً)، لهذا نلجأ للتفكير في التعلم بالنقل كأفضل حل.

"سيكون تعلم النقل هو المحرك التالي لنجاح التعلم بالآلة" هذا ما ذكره Andrew Ng، في برنامج NeurIPS التعليمي.

هدفنا هو إظهار قوة التعلم بالنقل في سياق مهام رؤية الكمبيوتر عموماً وتصنيف الصور الطبية خصوصاً. ففي دراستنا هذه، تم إجراء التصنيف على صور الأشعة السينية لعظام الطرف العلوي الطبيعية وغير الطبيعية في مجموعة بيانات MURA. وكدراسة مختلفة عن الدراسات السابقة، تم استخدام نموذج التعلم العميق القائم على DenseNet121 عن طريق نقل التعلم باستخدام عينة البيانات ImageNet المدرب عليها النموذج مسبقاً، كما تم مقارنة النتائج التي تم الحصول عليها مع نتائج تطبيق نموذج التعلم العميق المبني على VGG16 والتي تم أيضاً العمل عليها خلال البحث. السبب الرئيسي لتطبيق التعلم بالنقل على نماذج CNN المبنية هو المساهمة في كفاءة نماذج التعلم العميق المقترحة في تصنيف صور الأشعة السينية المدروسة.

4- فرضيات الدراسة.

تفترض الدراسة:

1- امتلاك الباحث معرفة بتقنيات تعلم الآلة والتعلم العميق وأساسياتهما.

2- اطلاع الباحث على عينة البيانات المدروسة.

5- أهمية الدراسة:

تنبع الأهمية العلمية للدراسة كون تصنيف الصور الشعاعية يعتبر من المجالات المهمة جداً لتركيز تطبيق نماذج التعلم بالآلة عموماً على عينات من هذا المجال، والتعلم العميق والتعلم بالنقل خصوصاً نظراً للنتائج المرضية التي نتجت عن تطبيقها في أغلب مجالات الحياة العملية بمختلف جوانبها [1]. سعينا في هذه الدراسة لتجربة تطبيق إحدى الشبكات العصبونية التلافيفية العميقة (وهي شبكة DenseNet121) على عينة بيانات كبيرة من الصور الشعاعية لدراسة مدى تأثير استخدام التعلم بالنقل على نتائج التصنيف (دقة تشخيص الصور). كما قمنا بتطبيق نموذج VGG16 ومقارنة نتائجه مع نتائج الشبكة DenseNet121.

تناولنا في الدراسة أيضاً تفاصيل بنية الشبكة المدروسة، وآلية تطبيق التعلم بالنقل بالاستفادة من التقنيات المتوفرة للأبحاث، إضافةً إلى النتائج والملاحظات التي حصلنا عليها بعد تنفيذ هذه الدراسة.

6- هيكلية الدراسة:

تم تقسيم هذه الدراسة إلى ثلاثة أقسام، يتناول القسم الأول منها الإطار النظري للدراسة، بينما يتطرق القسم الثاني إلى دراسة الحالة التجريبية وتطبيق التعلم بالنقل من خلال الشبكة التي تم اختيارها لدراسة نتائجها (دقة تصنيفها للصور)، ونتائج نموذج VGG16 أيضاً، ويعرض القسم الثالث والأخير نتائج الدراسة والدقة التي حصلنا عليها في نهاية عملية تدريب النموذج المقترح والنموذج الآخر الذي تمت المقارنة معه.

القسم الأول- الإطار النظري والدراسات السابقة.

أولاً- الإطار النظري:

1- الشبكات التلافيفية المتصلة بكثافة (Densely connected convolutional networks)

أظهرت الدراسات الحديثة [15] أن الشبكات التلافيفية يمكن أن تكون أعمق بكثير وأكثر دقة وكفاءة للتدريب إذا كانت تحتوي على اتصالات أقصر بين الطبقات القريبة من المدخلات وتلك القريبة من المخرجات. نقدم الشبكة التلافيفية الكثيفة (DenseNet)، التي تربط كل طبقة بكل طبقة أخرى بطريقة التغذية إلى الأمام. في حين أن الشبكات التلافيفية التقليدية ذات الطبقات L لها وصلات بعدد L - واحدة بين كل طبقة وطبقها اللاحقة - تحتوي شبكتنا على اتصالات مباشرة $L(L+1)/2$.

لكل طبقة، تُستخدم خرائط البارامترات لجميع الطبقات السابقة كمدخلات، وتُستخدم خرائط البارامترات الخاصة بها كمدخلات في جميع الطبقات اللاحقة [11].

تتمتع DenseNets بالعديد من المزايا:

- تقوي انتشار الميزات
- تشجع على إعادة استخدام الميزات
- تقلل عدد البارامترات بشكل كبير

نقوم بتقييم هذه الشبكة من خلال اعتماد تقنية التعلم بالنقل لشبكة DenseNet121 مدربة مسبقاً على عينة البيانات ImageNet الشهيرة ونقلها لتقوم بالعمل على عينة البيانات الخاصة بالدراسة. تحصل DenseNets على تحسينات كبيرة على أحدث التقنيات في معظمها، كما تتطلب ذاكرة وحسابات أقل لتحقيق أداء عالٍ.

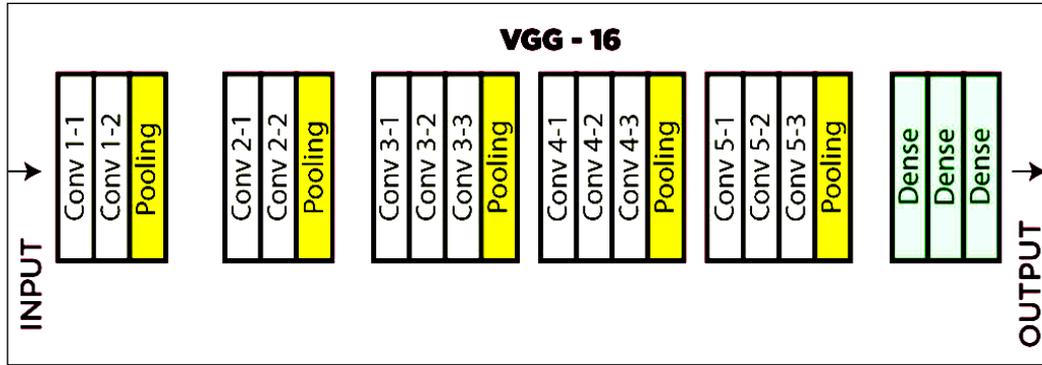
جدول (1) بنية شبكة DenseNet121 [9]

Layers	Output Size	DenseNet-121
Convolution	112×112	
Pooling	56×56	
Dense Block (1)	56×56	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 6$
Transition Layer (1)	56×56 28×28	
Dense Block (2)	28×28	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 12$
Transition Layer (2)	28×28 14×14	
Dense Block (3)	14×14	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 24$
Transition Layer (3)	14×14 7×7	
Dense Block (4)	7×7	$\begin{bmatrix} 1 \times 1 \text{ conv} \\ 3 \times 3 \text{ conv} \end{bmatrix} \times 16$
Classification Layer	1×1	7×7 global average pool 1000D fully-connected, softmax

VGG16 -2

عبارة عن بنية شبكة عصبونية التلافيفية (CNN) تم استخدامها للفوز بمسابقة ILSVR (ImageNet Large Scale Visual Recognition Challenge) في جامعة أكسفورد في عام 2014 في مقالة بعنوان "شبكات عميقة للغاية للتعرف على الصور على نطاق واسع". وتعتبر واحدة من تصميمات نماذج الرؤية الحاسوبية المميزة، بحيث حقق النموذج 92.7% من أعلى 5 اختبارات دقة على مجموعة بيانات ImageNet التي تحتوي على 14 مليون صورة تنتمي إلى 1000 تصنيف/فئة.

ما يميز VGG16 هو أنه بدلاً من وجود عدد كبير من البارامترات الفائقة، تم التركيز على وجود طبقات التلافيف من مرشح 3x3 مع خطوة 1 وتم استخدام نفس الحشو دائماً وطبقة الحد الأقصى من مرشح الخطوة 2 × 2. في النهاية يحتوي على 2 FC (طبقتين متصلتين بالكامل) متبوعاً بـ softmax للإخراج. يشير الرقم 16 في VGG16 إلى أن الشبكة تحتوي على 16 طبقة لها أوزان وتعتبر هذه الشبكة شبكة كبيرة جداً ولديها حوالي 138 مليون بارامتر تقريباً. كما يتوفر نسخة أخرى منه VGG19 بـ 19 طبقة بأوزان.



الشكل (1) بنية VGG16

3- تقنية التعلم بالنقل (Transfer Learning)

قد تستغرق نماذج الشبكة العصبية التلافيفية العميقة أياماً أو حتى أسابيع للتدريب على مجموعات بيانات كبيرة جداً. وتتمثل إحدى طرق اختصار هذه العملية في إعادة استخدام أوزان النموذج من النماذج المدربة مسبقاً التي تم تطويرها لمجموعات البيانات المعيارية، مثل مهام التعرف على الصور ImageNet. يمكن تنزيل النماذج الأفضل أداءً واستخدامها مباشرة، أو دمجها في نموذج جديد لحل مشكلات الرؤية الحاسوبية [17] [11].

يشير مصطلح التعلم بالنقل إلى تأثير المعرفة المكتسبة من قبل الشبكة العصبية المدربة مسبقاً على مجموعة بيانات معينة (كبيرة عادة) متاحة لحل المشكلات الجديدة التي تتوفر لها أمثلة تدريب قليلة، ودمج المعرفة الحالية مع المعرفة الجديدة المستفادة من الأمثلة القليلة من مجموعة البيانات الخاصة بالمسألة الحالية. وبالتالي، يتم استخدام التعلم بالنقل بشكل كبير، غالباً مع تقنيات أخرى مثل زيادة عينة البيانات المدروسة، من أجل معالجة مشكلة نقص بيانات التدريب.

يعمل التعلم بالنقل فقط في التعلم العميق إذا كانت ميزات النموذج التي تم تعلمها من المهمة الأولى عامة

[16].

في التعلم بالنقل، نقوم أولاً بتدريب شبكة أساسية على مجموعة بيانات أساسية ومهمة، ثم نقوم بإعادة توظيف الميزات المكتسبة، أو نقلها، إلى الشبكة الهدف ليتم تدريبها على مجموعة بيانات ومهمة هدف. ستتم هذه

العملية إذا كانت الميزات عامة، ما يعني أنها مناسبة لكل من المهام الأساسية والهدف، بدلاً من المهمة المحددة للمهمة الأساسية.

طريقة النموذج المدرب مسبقاً:

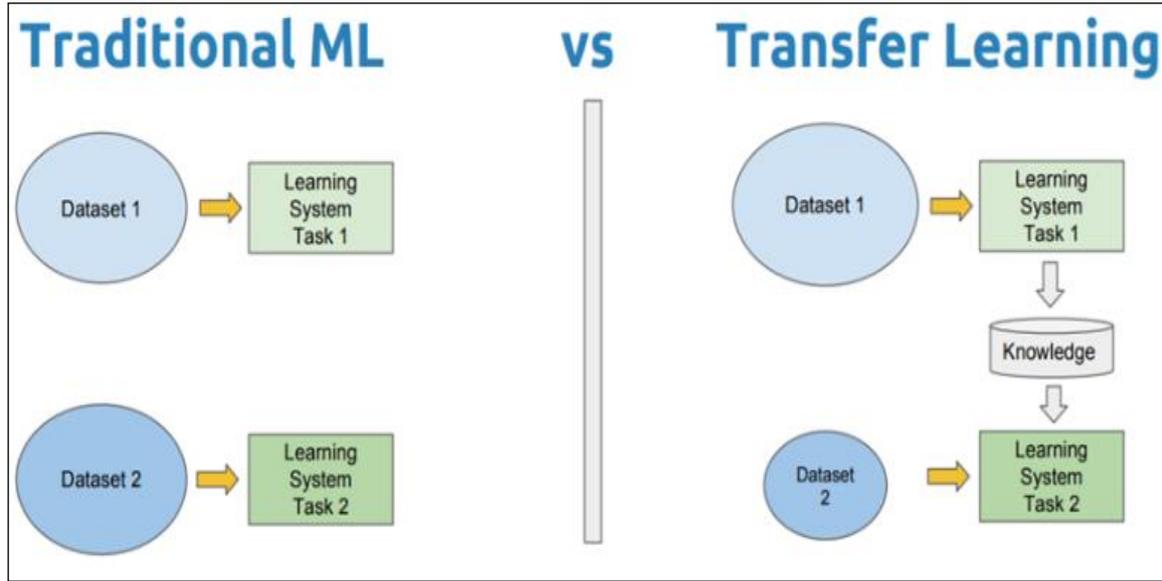
1. نحدد النموذج المصدر: يتم اختيار نموذج مصدر مدرب مسبقاً من النماذج المتاحة بحيث تطلق العديد من المؤسسات البحثية نماذج على مجموعات بيانات كبيرة وصعبة يمكن تضمينها في مجموعة النماذج المرشحة للاختيار من بينها.
2. إعادة استخدام النموذج: يمكن استخدام النموذج الذي تم تدريبه مسبقاً كنقطة انطلاق لنموذج في مهمة ثانية. قد يشمل ذلك استخدام النموذج بالكامل أو أجزاء منه، اعتماداً على تقنية النمذجة المستخدمة.
3. ضبط النموذج: قد يحتاج النموذج إلى تكييفه أو تعديله على بيانات الإدخال والإخراج المتاحة للمهمة الهدف. ولكن يمكن أن يتساءل الباحثون هنا ما مقدار المساعدة التي يمكن أن يساعدها التعلم بالنقل فعلياً، قمنا بالإجابة على هذا السؤال فيما يتعلق بتصنيف مجموعة البيانات الخاصة بالصور الشعاعية الطبية المدروسة. يعتبر التعلم بالنقل تحسين، اختصار لتوفير الوقت أو الحصول على أداء أفضل. وبشكل عام، ليس من الواضح أنه ستكون هناك فائدة من استخدام التعلم بالنقل في المجال إلا بعد تطوير النموذج وتقييمه.

4- مقارنة التعلم التقليدي بالتعلم بالنقل:

تتعرف خوارزميات التعلم الآلي التقليدية على الأنماط في البيانات وتقوم بالتنبؤات للبيانات الجديدة. يتم تصميم خوارزميات تعلم الآلة التقليدية لتعلم مهام محددة، وبالتالي يجب إعادة بناء النماذج من الصفر لمهام جديدة وتدريبه وهذا يتطلب الوقت والمال. أي أن النماذج تعمل بمعزل عن غيرها، فعند إعطائها مجموعة بيانات، فإنها تتعلم كيفية أداء مهمة محددة، إلا أنها عند تكليفها بحل مشكلة جديدة، لا يمكنها اللجوء إلى أي معرفة مكتسبة مسبقاً. وإنما تحتاج هذه الخوارزميات التقليدية إلى مجموعة بيانات ثانية لبدء عملية تعلم جديدة. كما تتطلب أيضاً معظم خوارزميات التعلم الآلي كميات هائلة من البيانات. فغالباً ما تحتاج نماذج التعلم العميق إلى ملايين نقاط البيانات لتوليد نتائج مرضية. وبالرغم أن التعلم العميق تلقى تقديراً كبيراً في مجال الذكاء الصناعي، إلا أنه يعاني من ناحية البيانات الضخمة والمتطلبات الزمنية.

ظهر حديثاً التعلم بالنقل والذي يعمل على تحسين التعلم في مهمة جديدة من خلال نقل المعرفة من مهمة ذات صلة تم تعلمها بالفعل مسبقاً، مثلاً يمكن تدريب الخوارزمية التي تعلمت كيفية التعرف على الكلاب على التعرف على القطط بسهولة نسبية عن طريق نقل بعض المفاهيم المجردة. ففي التعلم بالنقل، يعتمد تعلم المهام الجديدة على المهام التي تم تعلمها مسبقاً، بحيث يمكن للخوارزمية تخزين المعرفة والوصول إليها لاحقاً وبالتالي يمكننا القول إن النموذج عام وليس محدد مثل النماذج التقليدية.

بالتالي يزيد التعلم بالنقل من سرعة التعلم مع وجود عدد أقل من الأشياء الجديدة التي يجب تعلمها، وتكون الخوارزمية أسرع في إنتاج مخرجات عالية الجودة. كما أنه يقلل من كمية البيانات المطلوبة. في التعلم التقليدي كما أشرنا سابقاً، يمكن للخوارزمية أن تتعلم فقط عندما يتم تزويدها ببيانات تدريب كافية، وأحياناً ملايين نقاط البيانات. وقد لا تكون هذه البيانات متاحة على الإطلاق أو قد تكون مكلفة للغاية لإنشاء النموذج والتحضير له.



الشكل (2) مقارنة التعلم التقليدي بالتعلم العميق

القسم الثاني- دراسة الحالة التجريبية وتطبيق التعلم بالنقل باستخدام شبكة DenseNet121:

أولاً- دراسة الحالة التجريبية:

لعبت مجموعات البيانات الكبيرة والعالية الجودة دوراً مهماً في دفع عجلة التقدم في مجالات التعليم العميق.

تتكون المهمة المختارة لتجربة التعلم بالنقل من تصنيف صور شعاعية طبية لسبعة أنواع مفاصل وعظام في الجسم إلى فئتين. يرجع اختيار هذه المهمة بشكل أساسي إلى توفر هذه المجموعة من البيانات، بالإضافة إلى مجال المشكلة، وهو عام بما يكفي ليكون مناسباً للتطبيق الفعال للتعلم بالنقل مع الشبكات العصبية المدربة مسبقاً على مجموعة بيانات ImageNet الشهيرة.

حسب الاحصائيات الأخيرة المتوفرة في مجال الحالات المتعلقة بمجال دراستنا (الصور الشعاعية) فإن أمراض العظام والعضلات تؤثر على أكثر من 1.7 مليار شخص في جميع أنحاء العالم، وهي السبب الأكثر شيوعاً للألم والإعاقة الشديدة وطويلة الأجل، بحيث تزداد 30 مليون زيارة لقسم الطوارئ سنوياً وتزايد بسبب هذا النوع من الحالات [26].

مهمة الكشف عن المرض، أو بمعنى آخر تحديد ما إذا كانت الصور الشعاعية طبيعية أو غير طبيعية، هي عملية مهمة بحيث تعتبر دراسة تفسر على أنها تستبعد المرض بشكل طبيعي ويمكن أن تلغي حاجة المرضى للخضوع لمزيد من الإجراءات التشخيصية أو التدخلات.

عينة البيانات المدروسة:

عملنا من خلال دراستنا على عينة البيانات MURA Dataset، وهي مجموعة بيانات كبيرة للكشف عن التشوهات في التصوير الشعاعي العضلي الهيكلي تتألف من 14863 دراسة (وتحتوي كل دراسة على واحد أو أكثر من المشاهدات (الصور)) من 12173 مريضاً، بإجمالي 40,561 صورة إشعاعية متعددة الرؤية.

تحتوي مجموعة البيانات على 9,045 دراسة طبيعية و5818 دراسات إشعاعية عضلية هيكلية غير طبيعية، تنتمي كل منها إلى واحدة من سبعة أنواع من الدراسات التصويرية للأطراف العلوية: الكوع، الإصبع، الساعد، العضد، الكتف، اليد والمعصم.

تم تصنيف كل دراسة يدوياً على أنها طبيعية أو غير طبيعية من قبل أطباء الأشعة المعتمدين من مستشفى ستانفورد في وقت التفسير الشعاعي السريري في بيئة الأشعة التشخيصية بين 2001 و2012 [14].

في الدراسة التي قدمتها جامعة ستانفورد تم تقسيم مجموعة البيانات إلى ثلاث مجموعات: مجموعة التدريب (11184 مريض، 13457 دراسة، 36808 صورة)، مجموعة التحقق (783 مريض، 1199 دراسة، 3197 صورة)، ومجموعة الاختبار (206 مريض، 207 دراسة، 556 صورة). كما أنه لا يوجد تداخل في المرضى بين أي من المجموعات.

أما في أغلب الدراسات التي تمت على نفس عينة البيانات فإنها تنقسم الصور إلى 36808 صورة تدريبية و3197 صورة للتحقق منها. بحيث تأتي عينة البيانات كمجموعة بيانات منقسمة إلى مجموعتين: مجموعة التدريب ومجموعة التحقق في مجلدات منفصلة.

ثانياً- تطبيق التعلم بالنقل باستخدام شبكة DenseNet121 ومناقشة النتائج:

قمنا بتطبيق نموذج التعلم بالنقل المقترح من خلال تدريبه ثم قمنا بمقارنة أداء النموذج وأخصائي الأشعة (والذي تم أيضاً إعطاؤهم الصور وقاموا بتصنيفها يدوياً، حيث قام 6 من أخصائي الأشعة بالعمل على ذلك وفقاً للورقة البحثية الخاصة بالبيانات المنشورة [14])، كما قمنا بالمقارنة مع نموذج مبني على VGG16.

قمنا بتخزين أوزان النموذج، فبدلاً من العمل على الأوزان العشوائية، بدأنا بالأوزان المستفاد من النموذج المدرب مسبقاً على مهمة مختلفة (مهمة تصنيف الصور في ImageNet). وكون المهمة الجديدة مختلفة عن المهمة المدربة، تم تجاهل الطبقة الأخيرة (أو حتى الأجزاء الأكبر من الشبكة مثلما تكلمنا عنها في قسم تعديل النموذج المدرب سابقاً).

وتم تدريب الشبكة من طرف إلى طرف باستخدام Adam Optimizer مع البارامترات الافتراضية. استخدمنا نفس حجم batch = 8 ومعدل التعلم 0.0001

قمنا بتدريب الشبكات لكل أنواع الدراسة بشكل منفصل بحيث قمنا بتطبيق نموذج التعلم بالنقل على عينة البيانات المدروسة على كل نوع بشكل مستقل (أي التطبيق على فئة المعصم بشكل مستقل، على فئة الأصابع بشكل مستقل... الخ) وبعدها مرات 115 لكل الأنواع، كما قمنا بمتابعة تدريب النموذج على عينة البيانات كاملة دون فصل الأنواع بشكل مستقل، وقمنا بتسجيل النتائج لكل الحالات المدروسة.

تم تهيئة نموذج VGG16 بنفس الأوزان والبارامترات لنموذج DenseNet121 أيضاً.

ونعرض النتائج في الجدول الآتي:

جدول (2) مقارنة نتائج تقييم نموذج التعلم العميق القائم على DenseNet121 المقترح على عينة البيانات مع

نتائج الورقة البحثية المذكورة ومع نموذج التعلم العميق القائم على VGG16

Study Type	Ref. Precision	DenseNet121 Precision	VGG16 Precision
WRIST	0.86	0.8552	0.5549
ELBOW	0.85	0.8556	0.5065
HUMERUS	0.82	0.875	0.5139

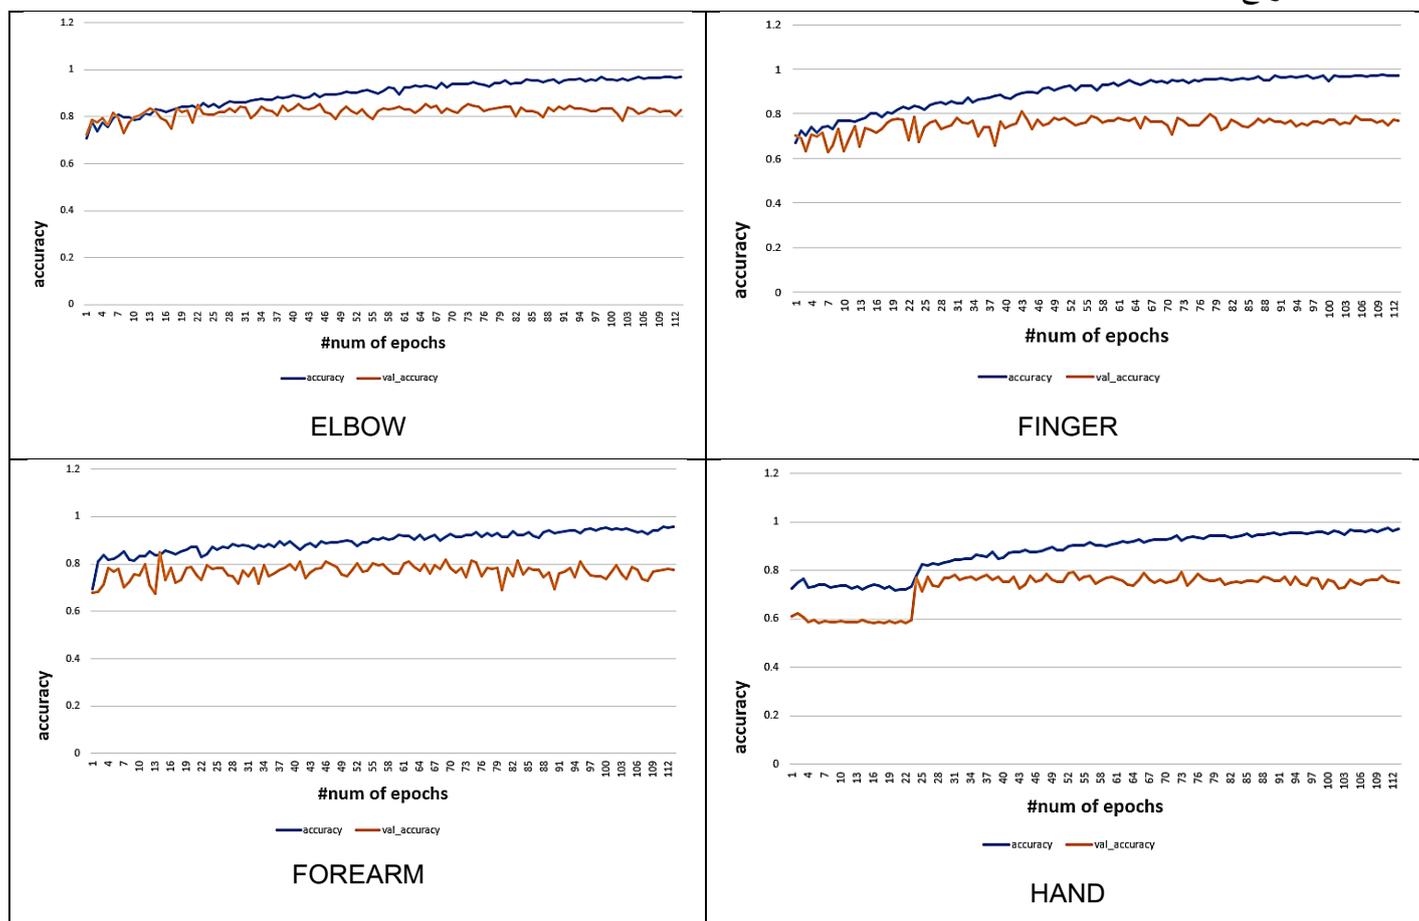
Study Type	Ref. Precision	DenseNet121 Precision	VGG16 Precision
SHOULDER	0.79	0.7946	0.5089
FINGER	0.78	0.808	0.62
FOREARM	0.77	0.8472	0.5104
HAND	0.73	0.7946	0.5982
ALL	-	0.8207	0.5546

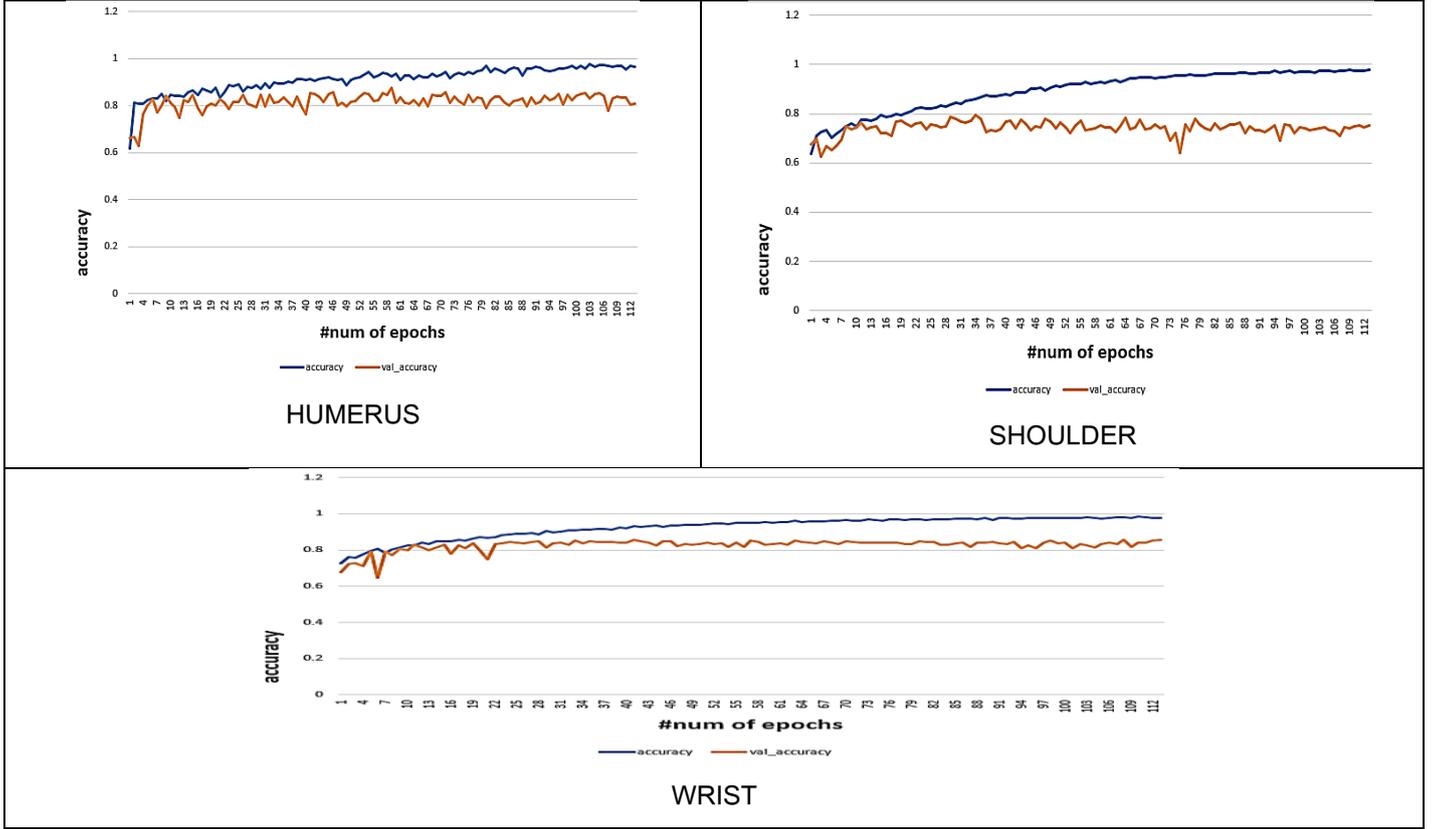
نلاحظ من الجدول أن الدقة التي حصلنا عليها في نموذج DenseNet121 كانت أفضل من النتائج التي تمت المقارنة معها في المرجع المذكور ومن نتائج نموذج VGG16 بحيث وجدنا فارق جيد في دقة التصنيف بالنسبة لأنواع Hand، Forearm، Humerus، مع المرجع، أما بالنسبة لنموذج VGG16 فلم يعط أي نتائج جيدة.

القسم الثالث- نتائج الدراسة ومناقشتها.

نعرض في هذا القسم مخططات تعرض نتائج تدريب وتقييم النموذج على عينة البيانات لكل أنواع الدراسة

(لنموذج DenseNet121):





الشكل (3) نتائج تدريب وتقييم النموذج DenseNet121 على عينة البيانات لكل أنواع الدراسة (ذكرنا اسم كل نوع تحت المخطط الخاص به)

نلاحظ من المخططات عموماً أن دقة التدريب استمرت في التصاعد واقتربت من الدقة المثالية أثناء الاستمرار في التدريب إلى 115 دورة (عدد الدورات الذي تم اختياره للتدريب)، وبالتفصيل: وصلت دقة التدريب إلى 98% في نوع Elbow (المرفق) بينما وصلت دقة التحقق إلى 85.6%، بحيث بدأت بقيمة صغيرة 72% من ثم تصاعدت ووصلت لدقة 85.6% والتي قمنا بتسجيلها عند الدورة 73 ولم تتجاوز هذه الدقة في الدورات الباقية.

وصلت دقة التدريب إلى 98% في نوع Finger (الأصابع) بينما وصلت دقة التحقق إلى 80.8%، بحيث بدأت بقيمة صغيرة 70% من ثم تصاعدت ووصلت لدقة 80.8% والتي قمنا بتسجيلها عند الدورة 43 ولم تتجاوز هذه الدقة في الدورات الباقية.

وصلت دقة التدريب إلى 97% في نوع Forearm (الساعد) بينما وصلت دقة التحقق إلى 84.7%، بحيث بدأت بقيمة صغيرة 67.7% من ثم تصاعدت ووصلت لدقة 84.7% والتي قمنا بتسجيلها عند الدورة 14 ولم تتجاوز هذه الدقة في الدورات الباقية.

وصلت دقة التدريب إلى 98.5% في نوع Hand (اليد) بينما وصلت دقة التحقق إلى 79.5%، بحيث بدأت بقيمة صغيرة 61% من ثم تصاعدت ووصلت لدقة 79.5% والتي قمنا بتسجيلها عند الدورة 53 والدورة 73 ولم تتجاوز هذه الدقة في الدورات الباقية.

وصلت دقة التدريب إلى 98.5% في نوع Humerus (عظم العضد) بينما وصلت دقة التحقق إلى 87.5%، بحيث بدأت بقيمة صغيرة 66.3% من ثم تصاعدت ووصلت لدقة 87.5% والتي قمنا بتسجيلها عند الدورة 59 ولم تتجاوز هذه الدقة في الدورات الباقية.

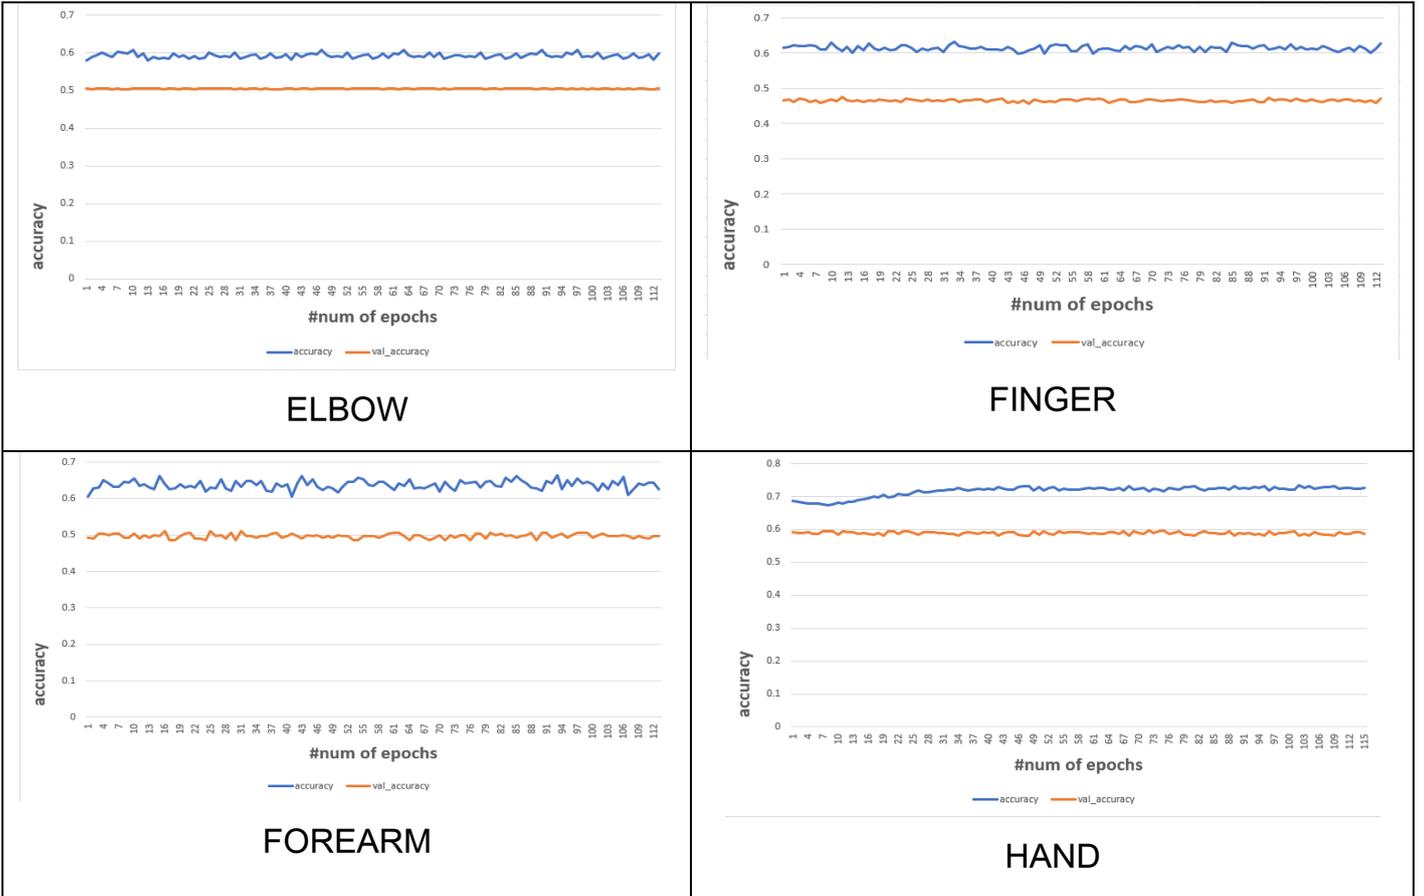
وصلت دقة التدريب إلى 97.9% في نوع Shoulder (الكتف) بينما وصلت دقة التحقق إلى 79.5%، بحيث بدأت بقيمة صغيرة 67.5% من ثم تصاعدت ووصلت لدقة 87.5% والتي قمنا بتسجيلها عند الدورة 34 ولم تتجاوز هذه الدقة في الدورات الباقية.

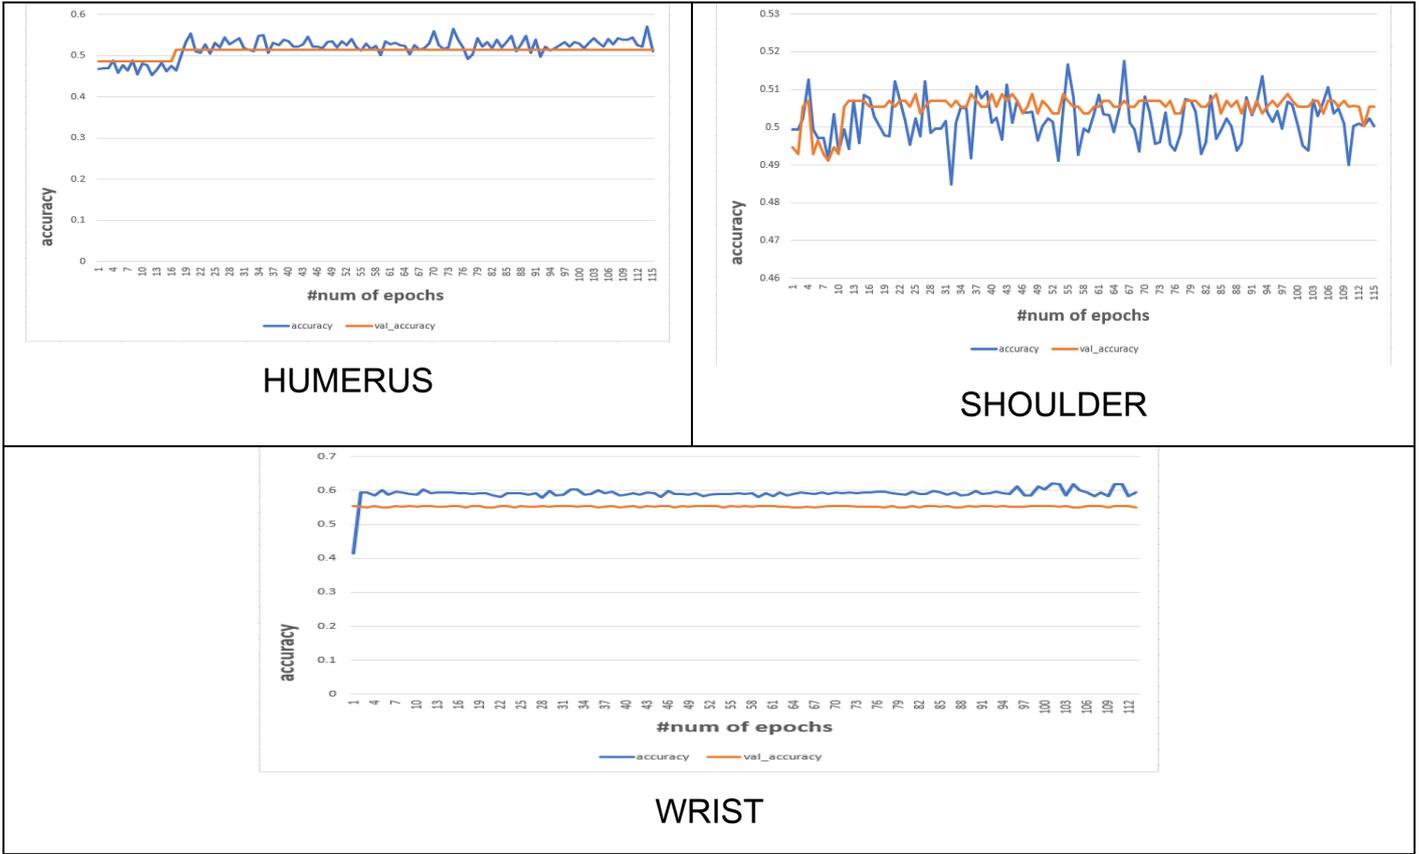
وصلت دقة التدريب إلى 98% في نوع Wrist (الرسغ) بينما وصلت دقة التحقق إلى 85.5%، بحيث بدأت بقيمة صغيرة 67.8% من ثم تصاعدت ووصلت لدقة 85.5% والتي قمنا بتسجيلها عند الدورة 108 ولم تتجاوز هذه الدقة في الدورات الباقية.

نلاحظ من هذه النتائج أن دقة التدريب تصل إلى نسبة مثالية نوعاً ما (يكون ذلك عادةً إما بسبب حجم عينة التدريب الكبيرة أو أنه يحصل Overfitting بعد عدد معين من الدورات)، أما نتائج الاختبار فقد كانت متراوحة بنسب معقولة في كل الأنواع المدروسة.

كما نلاحظ أننا حصلنا على أعلى دقة تحقق عند دورات مختلفة في كل نوع من الأنواع، مثلاً الدورة 73 والدورة 43 والدورة 34 والدورة 59 والدورة 108 (في حالة نوع الرسغ فقط)، ما يعني أننا حصلنا على أعلى دقة قبل الوصول لعدد الدورات الأعظمي بكثير، أي أنه لا يحصل لدينا ما يسمى Overfitting.

كما نقدم في هذا القسم مخططات تعرض نتائج تدريب وتقييم النموذج على عينة البيانات لكل أنواع الدراسة (لنموذج VGG16)، بغرض المقارنة بين أداء النموذجين على نفس عينة البيانات واستنتاج أي نموذج سيقدم نتيجة أفضل من حيث دقة التصنيف.





الشكل (4) نتائج تدريب وتقييم النموذج VGG16 على عينة البيانات لكل أنواع الدراسة (ذكرنا اسم كل نوع تحت المخطط الخاص به)

نلاحظ من المخططات عموماً أن دقة التدريب في أغلب أنواع الدراسة لم تتقدم بشكل جيد وإنما تقدمت بشكل بطيء جداً أو تراوحت حول قيم ثابتة أثناء الاستمرار في التدريب إلى 115 دورة (عدد الدورات الذي تم اختياره للتدريب)، أما نتائج الاختبار فقد كانت غير جيدة في أغلب الأنواع المدروسة، وبالتفصيل:

وصلت دقة التدريب إلى 61% تقريباً في نوع Elbow (المرفق)، بينما لم تتجاوز دقة التحقق 50.65%.
 وصلت دقة التدريب إلى 63.11% في نوع Finger (الأصابع)، بينما لم تتجاوز دقة التحقق 62%.
 وصلت دقة التدريب إلى 66.5% في نوع Forearm (الساعد)، بينما لم تتجاوز دقة التحقق 51.4%.
 وصلت دقة التدريب إلى 73.39% في نوع Hand (اليد)، بينما لم تتجاوز دقة التحقق 60%.
 وصلت دقة التدريب إلى حوالي 57% في نوع Humerus (عظم العضد)، بينما لم تتجاوز دقة التحقق 51.39%.

وصلت دقة التدريب إلى 51.8% في نوع Shoulder (الكتف)، بينما لم تتجاوز دقة التحقق 50.9%.
 وصلت دقة التدريب إلى 62.6% في نوع Wrist (الرسغ)، بينما لم تتجاوز دقة التحقق 55.59%.
 حقق النموذج المبني على شبكة DenseNet121 نتائج مرضية من ناحية دقة التصنيف، تفوق النتائج التي حصلنا عليها على النتائج التي تمت المقارنة معها من المرجع المذكور وكذلك نتائج النموذج المبني على VGG16، وهذا ما يؤكد جدوى استفادتنا من تطبيق التعلم بالنقل للاستفادة من النماذج المدربة مسبقاً واختصار الوقت اللازم للتدريب والحصول على النتائج المرجوة.

نجد من خلال نتائج النموذجين أن تطبيق التعلم بالنقل للنموذج المبني على DenseNet121 أعطى نتائج جيدة في تصنيف هذا النوع من الصور، أما النموذج المبني على VGG16 فلم يقدم أي نتائج مرضية وذلك وفقاً للدقة التي تم الحصول عليها في كلا النموذجين.

لذلك يمكننا القول إنه لا يمكن الحكم على نتائج أي نموذج مدرب مسبقاً ومنقول للعمل على بيانات جديدة إلا بعد تطبيق النموذج فعلياً (ربما تعتبر إحدى سلبيات التعلم بالنقل إلا أنه لا يمكن التنبؤ بالنتائج مسبقاً).

7- الخلاصة.

من النتائج التي تم الحصول عليها في النموذجين، نجد أن نموذج شبكة DenseNet121 يعمل بشكل شبه مثالي بالنسبة لعينة البيانات، أما نموذج VGG16 فقد أعطى نتائج غير جيدة في هذا النمط.

يمكن الاستفادة من النموذج الذي تم تدريبه وأعطى نتائج جيدة وتخزينه ليُعمل على عينات مشابهة من البيانات للاستفادة من نقل التعلم في الحصول على نتائج أفضل وبدقة أفضل وسرعة وأداء جيدين مقارنة بتدريب نموذج من الصفر.

تقنية التعلم بالنقل تعتمد على عدم بناء نموذج من الصفر، وإنما الاستفادة من النموذج المدرب مسبقاً والعمل على دراسة مدى الاستفادة منه في البيانات المدروسة، ولا يمكن التنبؤ بنتائجه قبل تطبيقه فعلياً، فقد وجدنا الفرق بين نتائج النموذج المبني على DenseNet121 والنموذج المبني على VGG16، كما يمكن تطبيق أي من النماذج الكثيرة الموجودة والمتاحة للبحث ودراسة مدى الاستفادة منها أيضاً وتوفير وقت الباحثين في هذا المجال لعدم البدء من الصفر في كل مهمة جديدة للتصنيف.

وضحنا من خلال الدراسة فائدة نقل التعلم لمهام رؤية الكمبيوتر. ووجدنا أن ضبط النماذج التي تم اختبارها مسبقاً أعطى نتائج جيدة، كون ImageNet هي قاعدة بيانات ضخمة للصور.

تمثل الأوزان من الطبقات العميقة لهذه النماذج بالتأكيد سمات مختلفة جداً عن تلك الموجودة في الصور الحالية (الحالة المدروسة)، ومن خلال إلغاء تجميد بعض الطبقات اللاحقة، تم الاحتفاظ بجميع الميزات القابلة للتعميم الأكثر فائدة. وبالتالي العمل على تسخير القوة والعمق المتاحين من أحدث الموديلات على تغيير وتحسين النتائج في المجال الطبي، ونؤكد أنه عندما تصبح بيانات الصور الطبية متاحة بشكل أكبر، ستكون هناك نتائج رائعة لكافة مجالات تعلم الآلة على عمليات التشخيص وغيرها.

8- التوصيات والمقترحات.

بناءً على النتائج التي تم التوصل إليها توصي الدراسة بالتالي:

- كان الهدف من الدراسة هو السعي للوصول أن يحقق نموذجنا (نموذج DenseNet121) أداءً مشابهاً لأداء أطباء الأشعة. بالنسبة للدراسات التي أجريت على اليد والرسم والمعصم، فإن نتائج النموذج الخاصة بنا من ناحية دقة التصنيف أعلى بشكل كبير من تلك النتائج الخاصة بأطباء الأشعة؛ وفي دراسات الكوع والساعد والعضد والكتف، كانت درجات الدقة الخاصة بنا مقارنة بشكل كبير من درجات إحصائي الأشعة، ولكنها ليست ذات دلالة إحصائية، مما يشير ويؤكد إلى أن مجموعة البيانات تمثل مشكلة تحدي جيدة للبحث في المستقبل.
- يمكن توسيع هذه الدراسة أيضاً لتشمل تطبيق أنواع أخرى من خوارزميات نقل التعلم على عينة البيانات ومقارنة نتائجها مع نتائج الدراسة الحالية.

- يمكن الاستفادة من النموذج الذي تم تدريبه على عينة البيانات وحصلنا من خلاله على نتائج جيدة جداً في العمل على مجموعات بيانات أخرى والاستفادة من آلية التعلم بالنقل في تحسين النتائج والأداء والحصول على نتائج بسرعة أكبر.

9- قائمة المراجع.

أولاً- المراجع الورقية:

- [1] Balaji ME, K., Lavanya, K., (2019)- Medical Image Analysis with Deep Neural Networks. Multimedia Tools and Applications, An International Journal.
- [2] Cheng, K., Iriondo, C., Calivá, F., Krogue, J., Majumdar, S., Pedoia, V., (2019) - Adversarial Policy Gradient for Deep Learning Image Augmentation. Medical Image Computing and Computer Assisted Intervention – MICCAI.
- [3] Deepak, S. Ameer, P.M., (2019) - Brain tumor classification using deep CNN features via transfer learning. Department of Electronics & Communication Engineering, National Institute of Technology, Calicut, India.
- [4] Dias, D.D.A., (2019) - Musculoskeletal Abnormality Detection on X-Ray Using Transfer Learning. Universitat Pompeu Fabra, Barcelons, Spain.
- [5] Fradi, M., Afif, M., Zahzeh, H., Bouallegue, K., Machhout, M., (2020) – Transfer Deep Learning Application for Ultrasonic Computed Tomographic Image Classification. IEEE.
- [6] Gao, J., Jiang, Q., Zhou, B., Chen, D., (2019)- Convolutional neural networks for computer-aided detection or diagnosis in medical image analysis: An overview. Math Biosci Eng.
- [7] Guan, B., Zhang, G., Yao, J., Wang, X., Wang, M., (2020) - Arm fracture detection in X-rays based on improved deep convolutional neural network. Computers & Electrical Engineering, China.
- [8] Harini, N., Ramji, B., Sriram, S., Sowmya, V., Soman, K.P., (2020) - Musculoskeletal radiographs classification using deep learning. In Deep Learning for Data Analytics: Foundations, Biomedical Applications and Challenges. Center for Computational Engineering and Networking (CEN), Amrita School of Engineering, Amrita Vishwa Vidyapeetham, Coimbatore, India.
- [9] Huang, G., Liu, Z., van der Maaten, L. (2018)-Densely Connected Convolutional Networks. Cornell University, Ithaca, New York.
- [10] Khan, M.A., Kim, Y., (2021) - Cardiac Arrhythmia Disease Classification Using LSTM Deep Learning Approach. Department of Information and Communication Engineering, Dongguk University, Seoul, Korea.
- [11] Pan, S.J., Yang, Q., (2010)- A survey on transfer learning. IEEE.
- [12] Pelka, O., Nensa, F., Friedrich, C.M., (2019) - Branding-Fusion of Meta Data and Musculoskeletal Radiographs for Multi-modal Diagnostic Recognition. IEEE.

- [13] Pradhan, N., Dhaka, V.S., Chaudhary, H., (2019) - Classification of Human Bones Using Deep Convolutional Neural Network. IOP Conference Series: Materials Science and Engineering.
- [14] Pranav, R., Jeremy, I., Aarti, B., Daisy, D., Tony, D., Hershel, M., Brandon, Y., Kaylie, Z., Dillon, L., Robyn, L. B., Curtis, L., Katie, S., Matthew, P. L., Andrew, Y. Ng.,(2018)- MURA: Large Dataset for Abnormality Detection in Musculoskeletal Radiographs. 1st Conference on Medical Imaging with Deep Learning (MIDL 2018).
- [15] Ravi, S. K., Heang, P.C., Lubomir, H., Mark, H.A., Jun, W., Kenny, C. (2016)- Mass detection in digital breast tomosynthesis: Deep convolutional neural network with transfer learning from mammography. Med Phys.
- [16] Sedrick, C., Michele, Z., (2020)- Transfer Learning in Image Classification: how much training data do we really need?
- [17] Se-woon, C., Kokeb, D., Gelan, A., (2021)- Transfer Learning in Breast Cancer Diagnoses via Ultrasound Imaging. Department of IT Convergence Engineering, Kumoh National Institute of Technology, Gumi 39253, Korea.
- [18] Shao, Y., Wang, X., (2020) - A Two Stage Method for Abnormality Diagnosis of Musculoskeletal Radiographs. Springer, Cham.
- [19] Storey, O., Wei, B., Zhang, L., Mtope, F.R.F., (2020) - Adaptive bone abnormality detection in medical imagery using deep neural net-works. Conference: 14th International FLINS Conference (FLINS 2020).
- [20] Talo, M., Baloglu, U.B., Yildirim, O., Acharya, U R., (2019) - Application of deep transfer learning for automated brain abnormality classification using MR images. Cognitive Systems Research.
- [21] Varma, M., Lu, M., Gardner, R., Dunnmon, J., Khandwala, N., Rajpurkar, P., Long, J., Beaulieu, C., Shpanskaya, K., (2019) - Automated abnormality detection in lower extremity radiographs using deep learning. Nat Mach Intell.
- [22] Yamashita, R., Nishio, M., Do, R.K.G (2018)- Convolutional neural networks: an overview and application in radiology. Insights into Imaging, Springer.
- [23] Yin, S., Peng, Li, Q. H., Zhang, Z., You, X., Liu, H., Fischer, K., Furth, S.L., Tasian, G.E., Fan, Y., (2019) - Multi-Instance Deep Learning with Graph Convolutional Neural Networks for Diagnosis of Kidney Diseases Using Ultrasound Imaging. Springer, Cham.
- [24] Yuliana- Gaona, J., Maria - Alvarez, J. R., Vasudevan, L., (2020)– Deep Learning Based Computer-Aided Systems for Breast Cancer Imaging: A Critical Review. Department of Systems Design Engineering, Physics, and Electrical and Computer Engineering, University of Waterloo, Ontario, Canada.

المراجع الإلكترونية:

[25] <https://stanfordmlgroup.github.io/competitions/mura>

[26] Musculoskeletal conditions (who.int)