

دراسة و تقييم أداء خوارزمية شبكة عصبية تلافيفية معدلة من خوارزميات التعلم العميق في تحديد اعتلالات الكلية

أ.د. عبدالله غندور *

م. ثراء محمد **

(تاريخ الإيداع ٢٠٢٤/٤/١٦ . قبل للنشر في ٢٠٢٤/٥/٣٠)

□ ملخص □

تعتبر الكلية من أهم الأعضاء في جسم الإنسان، حيث غالبًا ما تظهر مشاكلها الجدية في المراحل المبكرة من المرض دون أن يشعر المريض بأي أعراض واضحة. يُمكن اكتشاف وتشخيص العديد من أمراض الكلى مبكرًا بواسطة الأخصائيين باستخدام صور التصوير المقطعي المحوسب (CT) الروتينية. يعتبر الكشف المبكر عن هذه الأمراض ضروريًا للعلاج الناجح والوقاية من المضاعفات الخطيرة الأخرى. في هذه الدراسة، تم تطوير نموذج يعتمد على الذكاء الاصطناعي باستخدام النموذج المعروف باسم AlexNet لتصنيف صور CT للكليتين المصابتين بالحصى والأورام والكيسات. أظهر النموذج المقترح، الذي يتكون من خمس طبقات تلافيفية وثلاث طبقات اتصال بالكامل، دقة عالية قدرها ٩٩,٣٦٪ مقارنة بدقة نماذج مدربة مسبقًا مختلفة. تميز النموذج أيضًا بوجود طبقات تجميع قصوى بعد بعض الطبقات التلافيفية، وتم إضافة طبقة Batch Normalization بعد كل طبقة تلافيفية لتحسين استقرار النموذج وتسريع عملية التدريب وفي الطبقات الأخيرة من طبقات الاتصال بالكامل، تم إضافة طبقتي Dropout و Batch Normalization لتقليل الازدواجية وتحسين أداء النموذج. في النهاية، يتضمن النموذج النهائي طبقة إخراج تُعيد البيانات بناءً على التصنيف الذي تم تدريب النموذج عليه. كما استخدمت مقاييس مختلفة لتقييم أداء النموذج، وأظهرت هذه المقاييس أداءً متميزاً للنموذج المقترح، مما يشير إلى فعاليته العالية في تصنيف صور CT للكلى بشكل تلقائي وفعال.

الكلمات المفتاحية: التعلم العميق DL ، التصوير المقطعي المحوسب CT ، الشبكة العصبية التلافيفية CNN.

* مدرس في كلية الهندسة الميكانيكية والكهربائية - قسم هندسة الاتصالات والالكترونيات - جامعة البعث

** طالبة ماجستير في قسم الهندسة الالكترونية ، كلية الهندسة الميكانيكية والكهربائية - جامعة البعث - سورية

Study and evaluation of the performance of a convolutional neural network algorithm modified from deep learning algorithms in identifying kidney diseases

Dr-Eng. Abdullah Ghandour*
Eng. Tharaa Mohammad **

(Received 16/4/2024 . Accepted 30/5/2024)

□ ABSTRACT □

The kidney is considered one of the most important organs in the human body, as its serious problems often appear in the early stages of the disease without the patient feeling any obvious symptoms. Many kidney diseases can be detected and diagnosed early by specialists using routine computed tomography (CT) images. Early detection of these diseases is essential for successful treatment and prevention of other serious complications. In this study, an artificial intelligence-based model was developed using the model known as AlexNet to classify CT images of kidneys affected by stones, tumors, and cysts. The proposed model, which consists of five convolutional layers and three fully connection layers, showed a high accuracy of 99.36% compared to the accuracy of different pre-trained models. The model also featured max pooling layers after some convolutional layers, a Batch Normalization layer was added after each convolutional layer to improve model stability and speed up the training process, and in the last layers of the full connection layers, Dropout and Batch Normalization layers were added to reduce duplication and improve model performance. Finally, the final model includes an output layer that returns data based on the classification on which the model was trained. Various metrics were also used to evaluate the model's performance, and these metrics showed outstanding performance for the proposed model, indicating its high effectiveness in classifying CT images of the kidneys automatically and effectively.

Keywords: deep learning (DL), computed tomography (CT), convolutional neural network (CNN).

*Assistant professor, Faculty of Mechanical and Electrical Engineering - Department of Communications and Electronics Engineering - Al-Baath University, Homs , Syria.

** Master's student in the Department of Electronic Engineering, Faculty of Mechanical and Electrical Engineering - Al-Baath University – Syria.

١. مقدمة

في الوقت الحالي، تتوفر كميات كبيرة من البيانات التي تتطلب أدوات خاصة لتحليلها واستخراج المعلومات المفيدة منها. هذه الأدوات تأتي من حقول علمية متعددة مثل الإحصاء، النظم الخبيرة، تنقيب البيانات، والذكاء الاصطناعي بتقنياته المختلفة مثل التعلم الآلي والتعلم العميق والشبكات العصبية. في مجال الرعاية الصحية، ساعد الذكاء الاصطناعي الأطباء على تشخيص الأمراض من خلال جمع البيانات من السجلات الصحية وتقارير المسح والصور الطبية، مما أتاح إجراء تشخيصات أسرع وتوجيه المرضى لإجراء مزيد من الاختبارات أو وصف الأدوية. كما استخدم الذكاء الاصطناعي في عملية العلاج عبر مراقبة المرضى وتنبيه الأطباء عند حدوث أي خطأ.

تهدف هذه الدراسة إلى تحليل أداء نموذج شبكة عصبية تلافيفية معدلة في تشخيص أمراض الكلى المختلفة. إذ تقدم الدراسة نموذجًا يعتمد على التعلم العميق لتصنيف صور CT للكلى التي تحتوي على الكيسات والحصى والأورام بكفاءة عالية. تم تقسيم صور الكلى إلى مجموعة تدريب، مجموعة تحقق من الصحة، ومجموعة اختبار. بعد تدريب النموذج العميق باستخدام البيانات التدريبية، تم التحقق منه باستخدام بيانات التحقق من الصحة، من ثم اختبر باستخدام بيانات مجموعة الاختبار التي لم تُقدم للنموذج في مرحلتي التدريب والتحقق من الصحة. حقق النموذج دقة عالية بلغت 99,36%. هناك العديد من الدراسات التي استخدمت فيها خوارزميات للذكاء الاصطناعي في تصنيف أمراض الكلى [1,2]، وفيما يلي بعض الدراسات التي استخدمت خوارزميات التعلم في تصنيف صور الكلى :

قدمت الدراسة [3] شبكة X-ResNet-50، حيث تم تحليل صور مقطعية لـ 400 مريضًا (400 حالات تحتوي على حصى و 50 بدون حصى). قُسمت البيانات إلى ثلاث مجموعات بناءً على حجم الحصى: 1~0 سم، 2 سم، وأكبر من 2 سم، وأخذت الصور على ثلاثة مستويات (المحوري، الإكليلي، السهمي). بلغت نسب النجاح في المجموعة الأولى: 78% (المحوري)، 63% (الإكليلي)، 85% (السهمي). في المجموعة الثانية: 68% (المحوري)، 72% (الإكليلي)، 89% (السهمي). وفي المجموعة الثالثة: 70% (المحوري)، 64% (الإكليلي)، 93% (السهمي).

كما اقترحت الدراسة [4] نموذج (XRESNET-50) CNN لتصنيف حصى الكلى من صور التصوير المقطعي. استخدمت مجموعة بيانات مكونة من 1977 صورة، مع 1163 صورة للتدريب و 346 للتقييم. توقع النموذج 108 صورة حصى بشكل صحيح (TP) و 7 صور حصى في الفئة العادية (FN)، وصنف بشكل صحيح 177 صورة عادية (TN) وأخطأ في تصنيف 4 صور عادية كحصى (FP). حقق النموذج دقة بنسبة 96,82%.

أما الدراسة [5] استخدمت ستة نماذج للتعلم الآلي لتصنيف صور CT لأمراض الكلى (حصى، كيس، ورم) وصور الكلية الطبيعية. تضمنت ثلاث نماذج تعتمد على محولات الرؤية (EANet, CCT, Swin) وثلاثة تعتمد على التعلم العميق (VGG-16 المعدل، ResNet، Inception v3). استخدمت مجموعة بيانات مؤلفة من 12446 صورة. أظهرت النتائج أن نموذج Swin Transformer تفوق على الجميع بدقة بلغت 99,30%، يليه نموذج VGG-16 المعدل بدقة 98,20%.

كذلك قدمت الدراسة [٧] نموذجًا هجينًا من ٢٩ طبقة، يتضمن ٧ طبقات تلافيفية، ٤ طبقات تطبيع دُفعي (Batch Normalization)، ٧ طبقات تنشيط بنوع ReLU، 7 طبقات لتقليل الأبعاد (Max Pooling)، طبقة اتصال بالكامل، وطبقة Softmax لاستخراج خرائط الميزات. استخدم مصنف SVM لتصنيف الصور، حيث دُمجت خرائط الميزات من الطبقتين التلافيفيتين السادسة والسابعة باستخدام طريقة الإغاثة. استخدمت مجموعة بيانات من ١٢٤٤٦ صورة CT تمثل ثلاث أمراض في الكلى (حصى، كيس، ورم) وصور الكلية الطبيعية، وقُسمت إلى ٨٠% للتدريب و ٢٠% للاختبار. حقق النموذج دقة بلغت ٩٩,٣٧% عند اختباره باستخدام صور مجموعة التدريب إضافة إلى صور مجموعة الاختبار، وهذا ما يُفسر الوصول إلى معدل دقة عالية وحتمية عند اختبار النموذج بواسطة صور مستخدمة في مرحلة التدريب مما يجعل مقارنة نموذجنا مع هذه الدراسة مقارنة غير عادلة .

٢. هدف البحث

يهدف بحثنا في هذه الدراسة إلى تحسين دقة خوارزمية "AlexNet" من خلال إضافة طبقات إضافية وإعادة تدريب الشبكة على مجموعة الصور الطبية المتاحة للكلى. حيث أشارت الدراسات السابقة إلى أن استخدام خوارزمية AlexNet المدربة مسبقًا، بالتكامل مع مصنف SVM لتصنيف الصور الطبية للكلى، قد حقق دقة مقبولة [8,9]

. تسعى هذه الدراسة إلى بناء نموذج أكثر دقة وكفاءة من خلال تحسين البنية الأساسية لـ AlexNet وتدريبها باستخدام مجموعة البيانات المتاحة.


٣. طرق البحث وموارده

سنقوم باستخدام نوعاً من الشبكات العصبية التلافيفية المعروفة باسم AlexNet، وسنقوم بإضافة طبقات إضافية على طبقاتها الأساسية بحيث لا تؤثر على مخرجات الطبقات المتتالية. سنقوم ببناء الشبكة العصبية التلافيفية من البداية وسنقوم بتدريبها، حيث يتم تمرير الصور عبر سلسلة من الطبقات، وهي الطبقات التلافيفية Convolution والتجميعية Pooling والمسطحة Flatten والمتصلة بالكامل Fully Connected إضافة إلى الطبقات المضافة Batch Normalization و Dropout .

١,٣. مجموعة البيانات

مجموعة تم الحصول عليها عن طريق الانترنت [6]، حيث تم جمع مجموعة البيانات من PACS (نظام أرشفة الصور والاتصالات) من مستشفيات مختلفة في بنغلاديش، حيث تم بالفعل تشخيص إصابة المرضى بوجود ورم في الكلى، أو كيس، أو نتائج طبيعية أو حصوات. تم اختيار كل من القطع الإكليلي والمحوري من دراسات التباين وغير التباين مع بروتوكول لكامل البطن وجهاز الجهاز البولي. تم بعد ذلك اختيار دراسة Dicom (التصوير الرقمي والاتصالات في الطب) بعناية، تشخيصًا واحدًا في كل مرة، ومن تلك الدراسات قمنا بإنشاء مجموعة من صور Dicom للمنطقة محل الاهتمام لكل اكتشاف إشعاعي. بعد ذلك، قمنا باستبعاد معلومات كل مريض وبياناته التعريفية من صور Dicom وقمنا بتحويل صور Dicom إلى تنسيق صورة jpg بدون فقدان. بعد التحويل، تم التحقق مرة أخرى من كل نتيجة للصورة بواسطة أخصائي الأشعة وتقني طبي لإعادة تأكيد صحة البيانات.

تحتوي مجموعة البيانات التي تم إنشاؤها على 12446 بيانات فريدة بداخلها، حيث يحتوي الكيس على 3709، والطبيعي 5077، والحصى 1377، والورم 2283.



الشكل (1): لمحة حول صور مجموعة البيانات .

تم تقسيم مجموعة البيانات هذه إلى ثلاث مجموعات بنسبة 80% لمجموعة بيانات التدريب train dataset و 10% لمجموعة بيانات التحقق من الصحة validation dataset و 10% لمجموعة الاختبار test dataset. كل مجموعة من هذه المجموعات الثلاثة يحتوي على 4 أصناف من صور الكلى (طبيعي normal، كيس cyst، حصى stone، ورم tumor).

٢,٣. بنية الشبكة العصبية التلافيفية AlexNet المعدلة المقترحة

بعد جمع البيانات والحصول على قاعدة بيانات الصور الطبية من النوع CT سوف نقوم بمعالجة الصور قبل إدخالها إلى نموذج الشبكة العصبية التلافيفية المقترحة AlexNet المعدلة وتتمثل عملية المعالجة المسبقة للصور ب إعادة قياس الصورة وتطبيعها ، وتقسيم مجموعة البيانات ، إضافة إلى زيادة البيانات (توليد البيانات). تتمثل عملية إعادة قياس الصور وتطبيعها : بإعادة قياس الصورة (resize) وفقاً لمتطلبات الحجم القياسي لنموذج الشبكة العصبية التلافيفية AlexNet حيث تم تحويل صور مجموعة البيانات إلى صور بالحجم $3 \times 227 \times 227$ بكسل وهو الحجم المعياري لدخل شبكة AlexNet . من ثم تقسيم مجموعة البيانات : قمنا بتقسيم مجموعة البيانات ال dataset (حصى ، كيس ، ورم ، طبيعي) إلى ثلاث مجموعات وهي : مجموعة تدريب بنسبة 80% من مجموعة البيانات الأساسية ، مجموعة تحقق من صحة النموذج بنسبة 10% من مجموعة البيانات الأساسية، و مجموعة اختبار بنسبة 10% من مجموعة البيانات الأساسية .و أخيراً زيادة البيانات أو توليد البيانات : نقوم بتوليد البيانات من خلال مولد البيانات (ImageDataGenerator) الذي يتيح زيادة الصور في مجموعة البيانات (dataset) في الوقت ذاته الذي يقوم به النموذج بالتدريب ، وذلك من خلال تطبيق تحويلات عشوائية على كل صورة تدريبية عند تمريرها إلى النموذج ، باستخدام مولد البيانات (ImageDataGenerator) نقوم بتوفير استخداماً أقل للذاكرة و يعود السبب بذلك أنه ومن دون استخدام

هذه الفئة ، نقوم بتحميل جميع الصور في قاعدة البيانات مرة واحدة أو دفعة واحدة ، أما عند استخدام مولد البيانات هذا (ImageDataGenerator)، نقوم بتحميل الصور على شكل دفعات (batch) مما يوفر الكثير من الذاكرة. في نموذجنا هذا حددنا حجم الدفعة ب $batch_size=100$.

بعد عملية المعالجة المسبقة للصور نقوم ببناء النموذج CNN المعدل من البداية وتدريبه، من ثم نقوم بالتحقق من دقة بيانات التدريب وبيانات التحقق من الصحة، تليها عملية اختبار النموذج. لقد اخترنا عشوائياً 80% من مجموعة البيانات الأساسية (الحصى، الأورام، الكيس، الصور الطبيعية) للتدريب، ما يعادل 9955 صورة من الفئات الأربعة للتدريب. تم تدريب النموذج باستخدام برنامج Visual Studio Code مع ذاكرة عشوائية بحجم 8 غيغابايت، وذلك بحجم دفعة $Batch\ Size=100$.

يوضح الشكل (٢) الرسم التخطيطي الوظيفي لشبكة AlexNet دخلها عبارة عن صورة RGB بحجم $227 \times 227 \times 3$ بيكسل. حيث يتكون النموذج من 5 طبقات تلافيفية بأحجام نوى (kernal) أو فلاتر متتالية هي 11×11 ، 5×5 ، 3×3 ، 3×3 ، 3×3 . تمر هذه الفلاتر (kernal) على بكسلات دخل الطبقة وفق خطوة stride معينة حسب كل طبقة وتقوم هذه النوى باستخراج خرائط الميزات، حيث يحسب حجم خريطة الميزات الناتجة عن كل طبقة وفق العلاقة (1) ، يتوافق عدد النوى (kernal) في كل طبقة تلافيفية مع عدد خرائط الميزات الناتجة عن الطبقة . طبقة التجميع القصوى (Maxpooling) تقوم هذه الطبقة بتحديد القيمة القصوى في كل نافذة وتحافظ هذه الطبقة على عدد النوى (kernal) الناتج عن الطبقة السابقة لها ، كما ويحسب أيضاً حجم خريطة الميزات في كل طبقة وفق العلاقة (1) ويعتبر $p=0$ في حال غياب الحشوة (padding) في الطبقة. طبقة الاتصال بالكامل FC فيها يتم بسط مصفوفة الدخل إلى شعاع من الميزات من ثم يتم تمريره إلى شبكة العصبونات للتنبؤ بالخرج. نوضح طريقة حساب خرج كل طبقة وفق العلاقة (١) التي تعبر عن حجم خريطة الميزات الناتج عن الطبقة الحالية :

$$Size_feature_map = \left\lceil \frac{n + 2p - f}{stride} \right\rceil + 1 \quad (1)$$


حيث أن :

n : هو دخل الطبقة (حجم مصفوفة الميزات عند دخل الطبقة).

p : هو الحشوة أو padding حال عدم وجود حشوة تعتبر صفر .

f : هو حجم الفلتر filter .

الشبكة العصبية التلافيفية المقترحة AlexNet المعدلة تم بناؤها من البداية باستخدام مكتبة Keras ، وتم التعديل على الشكل العام للنموذج الموصف في الشكل (2). سيتم شرح تفصيلي للتعديلات التي تم إجراؤها على الشكل العام للنموذج فيما يلي.



الشكل (2): بنية الشبكة العصبية الملتفة AlexNet.

النموذج المعدل يتكون من خمس طبقات تلافيفية (convolutional layers) بأحجام نواة (kernel) متتالية هي 11×11 ، 5×5 ، 3×3 ، 3×3 ، 3×3 . بعد كل طبقة تلافيفية، تمت إضافة طبقة BatchNormalization لتحسين أداء الشبكة. يتكون النموذج أيضًا من ثلاث طبقات متصلة بالكامل (fully connected) مع استخدام وظيفة التنشيط ReLU في جميع الطبقات ما عدا الطبقة الأخيرة التي تستخدم وظيفة التنشيط Softmax. تم إضافة طبقة Dropout في الطبقات الأخيرة، وتمت إضافة طبقة BatchNormalization أيضًا في هذه الطبقات لتحسين أداء الشبكة. في النهاية، تمت إضافة طبقة dense الأخيرة لتصنيف صور الكلى إلى الفئات الأربع المطلوبة.

شرح وظيفة الطبقات العصبية المضافة الى الشبكة المقترحة AlexNet المعدلة: سنقوم فيما يلي بشرح رياضي هندسي لوظائف الطبقات العصبية المضافة الى الشبكة العصبية المقترحة AlexNet المعدلة .

(a) الطبقة المضافة طبقة BatchNormalization :

وظيفة طبقة الـ Batch Normalization (BN) هي تحسين تدريب الشبكات العصبية العميقة من خلال تقليل مشكلة تغيير توزيع البيانات المتغيرة خلال عملية التدريب إذ أنه في تدريب الشبكات العصبية العميقة، يمكن مواجهة مشكلة تسمى "تبدل توزيع البيانات" وهي مشكلة تحدث عندما تكون البيانات التي يتم تدريب النموذج عليها مختلفة بشكل كبير عن البيانات التي سيتم اختبار النموذج عليها، فإن ذلك قد يؤدي إلى تدهور أداء النموذج وذلك بفقدان التناغم بين البيانات فإن النموذج قد يجد صعوبة في تعميم ما تعلمه خلال التدريب إلى بيانات جديدة في مرحلة الاختبار. كما قد تحتوي مجموعة بيانات الاختبار على أنماط نادرة أو حالات استثنائية لم تكن ممثلة بشكل كافٍ في بيانات التدريب، مما يؤدي إلى أداء ضعيف للنموذج في التعامل مع هذه الحالات.

المعادلة الأساسية لعملية الـ Batch Normalization للإدخال x هي وفق الشكل التالي:

$$\hat{x} = \frac{x - \mu}{\sqrt{\sigma^2 + \epsilon}} \quad (2)$$

حيث:

- $\hat{x}$ هو الإدخال المقيس (normalized input) .
- x هو الإدخال الأصلي.
- μ هو المتوسط (mean) عبر الدفعة.
- σ^2 هو الانحراف المعياري (variance) عبر الدفعة.
- ϵ هو قيمة صغيرة موجبة تُضاف للمحافظة على استقرار القسمة في حالة وجود انحراف معياري صغير.

ثم، يتم تطبيق تقليل (scaling) وانزياح (shifting) على الناتج المقيس باستخدام معاملات γ و β على التوالي المعادلة موضحة فيما يلي (3) :

$$y = \gamma \hat{x} + \beta \quad (3)$$

حيث:

- γ هو الإخراج النهائي للطبقة.
 - γ هو معامل التقليل (scaling factor) .
 - β هو معامل الانزياح (shifting factor) .
- باستخدام هذه العمليات، تحافظ طبقة الـ Batch Normalization على استقرار تدريب الشبكة العصبية عميقة وتساعد في تسريع عملية التدريب.

(b) الطبقة المضافة الـ Dropout :

هي تقنية تستخدم في الشبكات العصبية الاصطناعية للحد من الفرط في التعلم (Overfitting) عن طريق إبطال (تعطيل) عشوائي لبعض وحدات النموذج أثناء عملية التدريب. تعمل هذه الطبقة على تجنب اعتماد النموذج بشكل كبير على وحدات محددة أثناء التدريب، مما يعزز التعميم generalization ويقلل من ارتفاع معدل الفرط في التعلم. هذا التبديل العشوائي يجبر النموذج على تعلم ميزات مستقلة أكثر، مما يجعله أقل تأثرًا بالتغيرات الطفيفة في بيانات التدريب . بشكل رياضي، يمكن تمثيل عملية Dropout لنفترض x متجه الإدخال إلى الطبقة Dropout . يتم إبطال الوحدات بشكل عشوائي مع احتمال p ، ويتم تطبيق العملية التالية (4) :

$$\hat{x} = \frac{x}{1-p} \cdot mask \quad (4)$$

حيث:

- $\hat{x}$ هو الإدخال المعدل بعملية Dropout .
- p هو احتمال إبطال الوحدات.
- $mask$ هو مصفوفة بنفس الحجم مثل x تحتوي على قيم 0 أو 1، حيث يتم اختيار القيم بشكل عشوائي بناءً على احتمال p . حيث أنه في عملية التدريب، يتم إبطال الوحدات بنسبة p بشكل عشوائي. للقيام بذلك، يتم إنشاء مصفوفة عشوائية D بنفس الحجم مثل X حيث تكون القيم فيها موزعة بين 0 و 1. ثم يتم تحديد الوحدات التي يجب إبطالها من خلال تطبيق الشرط التالي (5) :

$$D = \begin{cases} 1 & \text{if } R_{ij} > p \\ 0 & \text{otherwise} \end{cases} \quad (5)$$

حيث D هو مصفوفة القناع (Mask) التي تحدد الوحدات التي يجب إبطالها، و p هو نسبة الوحدات التي يتم إبطالها.

أثناء عملية الاختبار، تتم إعادة تشغيل جميع الوحدات بدون تعديل. أي في عملية الاختبار، لا يتم إجراء أي إبطال وتتم معالجة البيانات كما هو، وبالتالي لا تؤثر الطبقة الـ Dropout على الإخراج في عملية الاختبار.

هذه الهيكلية الشبكية المعدلة لنموذج AlexNet تعكس تركيباً عميقاً يُمكن من التعرف الفعّال على الأنماط والمعالم في البيانات، مما يجعلها مناسبة لتطبيقات تصنيف الصور والتعرف عليها. ويُساعد استخدام طبقات الـ Batch Normalization و Dropout في تجنب التحام النموذج وتحسين استقراره وأدائه، وتم إضافة الطبقات بحيث يتم الحفاظ على مخرجات الطبقة التالية كما هو الحال في نموذج AlexNet الكلاسيكي. يُظهر الجدول التالي ملخصاً لشبكة AlexNet الكلاسيكية:

الجدول (1): ملخص شبكة AlexNet الكلاسيكية

	Layer	Feature Map	Size	Kernel Size	Stride	Activation
	Input	Image	1	227x227x3	-	-
1	Convolution	96	55 x 55 x 96	11x11	4	relu
	Max Pooling	96	27 x 27 x 96	3x3	2	relu
2	Convolution	256	27 x 27 x 256	5x5	1	relu
	Max Pooling	256	13 x 13 x 256	3x3	2	relu
3	Convolution	384	13 x 13 x 384	3x3	1	relu
4	Convolution	384	13 x 13 x 384	3x3	1	relu
5	Convolution	256	13 x 13 x 256	3x3	1	relu
	Max Pooling	256	6 x 6 x 256	3x3	2	relu
6	FC	-	9216	-	-	relu
7	FC	-	4096	-	-	relu
8	FC	-	4096	-	-	relu
	Output	FC	-	1000	-	Softmax

من الجدول (1) نلاحظ خرج كل طبقة من طبقات الشبكة العصبية التلافيفية AlexNet قياس النواة أو الفلتر المطبق في كل طبقة (kernel size) وعدد خرائط الميزات أو السمات عند خرج كل طبقة (feature map) إضافة إلى قياس أو حجم كل خريطة ميزات ناتجة عند خرج كل طبقة من هذه الطبقات (size). أما بالنسبة لنموذج الشبكة العصبية التلافيفية المعدل من النوع AlexNet سنوضح الفرق الذي سيتم إجماعه بالنسبة لخرج الطبقات الأصلية والمضافة كما هو موضح بشكل تفصيلي في الجدول التالي (الجدول 2):

الجدول(2): ملخص شبكة AlexNet المعدلة .

Layer		Feature Map	size	Kernal size	stride	Activation
input	Image	1	227×227×3	-	-	-
1	Convolution	96	55×55×96	11×11	4	Relu
	Maxpooling	96	27×27×96	3×3	2	Relu
	BatchNormalize	96	27×27×96	-	-	-
2	Convolution	256	27×27×256	5×5	1	Relu
	Maxpooling	256	13×13×256	3×3	2	Relu
	BatchNormalize	256	13×13×256	-	-	-
3	Convolution	384	13×13×384	3×3	1	Relu
	BatchNormalize	384	13×13×384	-	-	-
4	Convolution	384	13×13×384	3×3	1	Relu
	BatchNormalize	384	13×13×384	-	-	-
5	Convolution	256	13×13×256	3×3	1	Relu
	Maxpooling	256	6×6×256	3×3	2	Relu
	BatchNormalize	256	6×6×256	-	-	-
6	FC	-	9216	-	-	Relu
7	FC	-	4096	-	-	Relu
	Dropout	-	4096	-	-	-
	BatchNormalize	-	4096	-	-	-
8	FC	-	4096	-	-	-
	Dropout	-	4096	-	-	-
	BatchNormalize	-	4096	-	-	-
output	FC	-	4	-	-	SOFTMAX

قانون حساب خرج كل طبقة في الشبكات العصبية التلافيفية (حجم خريطة الميزات عند خرج كل طبقة)

كما هو موضح في العلاقة (1) ، وعليه سيكون حجم ميزة الإخراج في كل طبقة والنتائج بعد بناء الشبكة

باستخدام مكتبة كيراس موضح وفق الجدول (3):

الجدول (3): خرج كل طبقة في الشبكة.

Layer (type)	Output Shape	Param
conv2d (Conv2D)	(None, 55, 55, 96)	11712
max_pooling2d (MaxPooling2D)	(None, 27, 27, 96)	0
batch_normalization (BatchNormalization)	(None, 27, 27, 96)	384

conv2d_1 (Conv2D)	(None, 27, 27, 256)	614656
max_pooling2d_1 (MaxPooling2D)	(None, 13, 13, 256)	0
batch_normalization_1	(None, 13, 13, 256)	1024
(BatchNormalization)		
conv2d_2 (Conv2D)	(None, 13, 13, 384)	885120
batch_normalization_2	(None, 13, 13, 384)	1533
(BatchNormalization)		
conv2d_3 (Conv2D)	(None, 13, 13, 384)	1327488
batch_normalization_3	(None, 13, 13, 384)	1536
(BatchNormalization)		
conv2d_4 (Conv2D)	(None, 13, 13, 256)	884992
max_pooling2d_2 (MaxPooling2D)	(None, 6, 6, 256)	0
batch_normalization_4	(None, 6, 6, 256)	1024
(BatchNormalization)		
flatten (Flatten)	(None, 9216)	0
dense (Dense)	(None, 4096)	3775283
		2
dropout (Dropout)	(None, 4096)	0
batch_normalization_5	(None, 4096)	16384
(BatchNormalization)		
dense_1 (Dense)	(None, 4096)	1678131
		2
dropout_1 (Dropout)	(None, 4096)	0
batch_normalization_6	(None, 4096)	16384
(BatchNormalization)		
dense_2 (Dense)	(None, 4)	16388

إجمالي عدد المعلمات في AlexNet المعدل هو 58,312,772 منها 58,293,636 معلمة قابلة للتدريب و 19,136 غير قابلة للتدريب .

٤. النتائج

باختبار النموذج المدرب باستخدام مجموعة بيانات الاختبار، تم تحقيق دقة عالية ومتميزة تبلغ ٩٩,٣٦%. هذه النتيجة تعكس قوة وفعالية النموذج في تصنيف وتشخيص الصور الطبية بنجاح، مما يبرز إمكانات التعلم العميق في مجال الطب وتطبيقاته الواعدة في تحسين رعاية المرضى وتشخيص الأمراض بدقة. تم اختبار دقة النموذج وفق التعليمات التالية :

`evaluate(test_dataset.classes,predictions)`

تكون نتيجة هذه التعليمات كما يلي وموضحة في الجدول (4):

loss: 0.0209 – accuracy: 0.9936 – precision: 0.9936 – recall: 0.9936–


F1_score: 0.9924030679465461

الجدول(4) : مقاييس الدقة باختبار النموذج على مجموعة بيانات الاختبار.

Accuracy	precision	Recall	F1-score
99.36%	99.36%	99.36%	99.24 %

نلاحظ نتائج دقة عالية (99.36%) للنموذج في مرحلة اختبار النموذج .

سنقوم الآن بإنشاء مصفوفة الارتباك للنموذج : حيث يوضح الشكل (3) أن النموذج صنف 372 صورة من نوع كيسة cyst على أنها كيسة بشكل صحيح ، ولم يخطئ أبداً في تصنيف أي صورة من هذا النوع . كما صنف 503 صورة من نوع طبيعي normal على أنها طبيعية بشكل صحيح و أخطأ في تصنيف ٦ من هذا النوع . كما صنف 139 من نوع حصى stone على أنها حصى بشكل صحيح ولم يخطئ أبداً في تصنيف أي صورة من هذا النوع. صنف 227 من نوع ورم tumor على أنها ورم بشكل صحيح ، أخطأ في تصنيف 2 صورة من النوع ورم tumor على أنها طبيعية normal .



الشكل (٣): مصفوفة الارتباك .

٥. مناقشة النتائج

في هذا البحث، أجرينا دراسة تحليلية ، حيث قمنا ببناء شبكة AlexNet معدلة تماماً من الصفر وتدريبها لتصنيف الصور الطبية للكلية من نوع CT . تم توظيف هذا النموذج لاكتشاف وتصنيف أربعة أنواع مختلفة من الصور الطبية للكلية (حصى، كيس، ورم، وطبيعي) باستخدام نفس مجموعة البيانات المستخدمة في الدراسة السابقة [٦]. ونتج عن هذا البحث مستوى عالٍ من الدقة يبلغ ٩٩,٣٦%، وهو معدل أداء يتفوق على الخوارزميات المستخدمة في الدراسات السابقة. يعكس هذا الأداء العالي للنموذج العمق والفاعلية الفائقة لتقنيات التعلم العميق في التعرف على أمراض الكلية من خلال الصور الطبية. يتميز هذا البحث بمنهجية متقدمة وتحليل دقيق لأداء النموذج المعدل، مما يعزز فهمنا لقدرة الخوارزميات العميقة على تحسين التشخيص والعلاج

في مجال طب الكلى. يظهر الجدول(٤) مقارنة أداء هذه الخوارزمية المقترحة مع خوارزميات مستخدمة في الدراسات السابقة وبنفس المجال .

الجدول (٤):مقارنة خوارزمية AlexNet المعدل مع خوارزميات الدراسات السابقة من نفس المجال.

Model	المرجع	Images used	Accuracy	precision	Recall	F1-score
AlexNet المعدلة المقترحة	البحث الحالي	CT (stone , cyst , tumor , normal)	99.36%	99.36%	99.36%	99.24 %
Swin	[5]	CT (stone , cyst , tumor , normal)	99.30%	99.15%	99.15%	99.125%
VGG-16 المعدلة	[5]	CT (stone , cyst , tumor , normal)	98.20%	98.225%	98.125%	98.175%
Inception v3 المعدلة	[5]	CT (stone , cyst , tumor , normal)	61.60%	63.925%	62.025%	59.15%
Resnet50 المعدلة	[5]	CT (stone , cyst , tumor , normal)	73.80%	73.9%	73.75%	73.6%
AlexNet	[7]	CT (stone , cyst , tumor , normal)	٧٢,٢٥%	-	-	-
Inception v3	[7]	CT (stone , cyst , tumor , normal)	٨٧,٧٥%	-	-	-
Resnet50	[7]	CT (stone , cyst , tumor , normal)	٨٦,٠٦%	-	-	-

٦. التوصيات و الأعمال المستقبلية

على الرغم من التقدم المستمر في تطوير تقنيات التعلم العميق وتطبيقاتها في مجال الطب، إلا أن هناك تحديات تقنية وتشغيلية يمكن أن تعوق تبني هذه التقنيات في المجال الطبي. لذا، يعتبر التعاون والشراكات بين القطاعين الطبي والتكنولوجي أمراً حاسماً في تطوير استخدامات التعلم العميق في مجال معالجة وتشخيص أمراض الكلى.

من الممكن العمل على تحسين دقة النموذج من خلال التدريب على عدد أكبر من الصور وفحص دقة التصنيف في مستويات تشريحية أخرى للكلى (المستوى السهمي) ، بالإضافة إلى زيادة عدد الصور التدريبية في فئتي الصور الطبيعية والاورام لمحاولة تقادي الأخطاء الحاصلة في التعرف على هاتين الفئتين في نموذجنا المقترح .

References:

- [1] A. Nithya, A. Appathurai, N. Venkatadri, D. Ramji, and C. A. Palagan, "Kidney disease detection and segmentation using artificial neural network and multi-kernel k-means clustering for ultrasound images," *Measurement*, vol. 149, p. 106952, 2020.
https://www.researchgate.net/publication/335246781_Kidney_disease_detection_and_segmentation_using_artificial_neural_network_and_multi-kernel_k-means_clustering_for_ultrasound_images
- [2] ELTON, Daniel C., et al. A deep learning system for automated kidney stone detection and volumetric segmentation on noncontrast CT scans. *Medical Physics*, 2022, 49.4: 2545-2554. <https://aapm.onlinelibrary.wiley.com/doi/abs/10.1002/mp.15518>
- [3] Caglayan, A., Horsanali, M. O., Kocadurdu, K., Ismailoglu, E., & Guneyli, S. (2022). Deep learning model-assisted detection of kidney stones on computed tomography. *International braz j urol*, 48, 830-839.
- [4] Yildirim, K., Bozdog, P. G., Talo, M., Yildirim, O., Karabatak, M., & Acharya, U. R. (2021). Deep learning model for automated kidney stone detection using coronal CT images. *Computers in biology and medicine*, 135, 104569.
- [5] Islam, M. N., Hasan, M., Hossain, M. K., Alam, M. G. R., Uddin, M. Z., & Soylu, A. (2022). Vision transformer and explainable transfer learning models for auto detection of kidney cyst, stone and tumor from CT-radiography. *Scientific Reports*, 12(1), 11440.
- [6] Islam, M. CT kidney dataset: Normal-cyst-tumor and stone 2021. [Online]. Available: <https://www.kaggle.com/nazmul0087/ctkidney-dataset-normal-cyst-tumor-and-stone>.
- [7] Bingol, H., Yildirim, M., Yildirim, K., & Alatas, B. (2023). Automatic classification of kidney CT images with relief based novel hybrid deep model. *PeerJ Computer Science*, 9, e1717.
- [8] Kokil, P., & Sudharson, S. (2019). Automatic detection of renal abnormalities by Off-the-shelf CNN features. *IETE Journal of Education*, 60(1), 14-23.
- [9] LI, Shaojuan, et al. Image classification algorithm based on improved AlexNet. In: *Journal of Physics: Conference Series*. IOP Publishing, 2021. p. 012051. <https://iopscience.iop.org/article/10.1088/1742-6596/1813/1/012051/meta>
- [10] Wu, Y., & Wang, S. (2004). A new algorithm of improving the learning performance of neural network by feedback. *Journal of Computer Research and Development*, 41(9), 1488–1492.
- [11] Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85–117. <https://doi.org/10.1016/j.neunet.2014.09.003>.
- [12] Zeiler M D, Fergus R. Visualizing and Understanding Convolutional Networks[J]. 2013
- [13] Hinton G E. Rectified Linear Units Improve Restricted Boltzmann Machines Vinod Nair[C]// International Conference on International Conference on Machine Learning. Omnipress, 2010
- [14] YANG, Tingting, et al. Prediction of Chronic Kidney Disease Progress Based on Two-Dimensional Convolutional Neural Networks. Available at SSRN 4058799. https://papers.ssrn.com/sol3/papers.cfm?abstract_id=4058799