

## تحسين عملية التصنيف في النموذج VGG-16 باستخدام تقنية نقل التعلم وخوارزمية الاختيار السلبي

أ.د. يعرب ديوب \*

م. رنيم عديا \*\*

(تاريخ الإيداع ٩/١٠/٢٠٢٣ - تاريخ النشر 10/12/2023)

### □ ملخص □

تُعد أنظمة المناعة الاصطناعية وخوارزمياتها من أكثر التقنيات المستخدمة في مجالات التصنيف، اكتشاف الكائنات والتعرف على النماذج وذلك بناء على طبيعتها المستوحاة من نظام المناعة البشري. حيث تم استخدامها في تطوير وتحسين العديد من المشاكل الموجودة في مجالات عديدة وذلك انطلاقاً من الدقة الموجودة لدى هذه الأنظمة. وقد اقترح البحث استخدام هذه الأداة لتطوير أداء نموذج الشبكة العصبونية الالتفافية VGG16، حيث يعتبر هذا النموذج من أكثر الأدوات المستخدمة في العديد من المجالات والتطبيقات، لكن التعقيد الحسابي الذي تفرضه بنية هكذا أنواع من النماذج يضع العديد من التحديات لدى استخدامها كما أن ازدياد كلفة بناء هذه الشبكات نتيجة التعقيد الحاصل خلق نوع من التحدي عند استخدامها، مما جعل الحاجة ملحة لوجود آلية تقلل من الكلفة والزمن عند استخدام هذه الشبكات.

تم في هذا البحث دراسة عمل الشبكة العصبونية الالتفافية (CNN) Convolutional neural network وذلك من خلال النماذج المدربة مسبقاً pre-trained models باستخدام تقنية نقل التعلم حيث تم اعتماد نموذج الشبكة VGG-16 والعمل على إجراء بعض التعديلات على طبقة الخرج في النموذج واستخدام خوارزمية الاختيار السلبي أحد خوارزميات أنظمة المناعة الاصطناعية. وتم تقييم أداء الخوارزمية من خلال إجراء سلسلة من التجارب على مجموعات البيانات المرجعية المستخدمة على نطاق واسع من أجل مهام تصنيف الصور ومقارنة النتائج مع عدة نماذج سابقة من الشبكات العصبونية الالتفافية ومع بنية النموذج الأساسية. حققت هذه الخوارزمية أفضل دقة بين جميع النماذج التي تمت المقارنة معها وذلك على مجموعة البيانات CIFAR10. الكلمات المفتاحية: الشبكات العصبونية الالتفافية، CNN، أنظمة المناعة الاصطناعية، خوارزمية الاختيار السلبي، التعلم العميق، تصنيف الصور، التعرف على النماذج، VGG16.

\* أستاذ دكتور في جامعة طرطوس - كلية هندسة تكنولوجيا المعلومات والاتصالات - قسم هندسة تكنولوجيا المعلومات-جامعة طرطوس- سورية.

\*\* طالبة دراسات عليا (ماجستير) في قسم هندسة تكنولوجيا المعلومات-كلية هندسة تكنولوجيا المعلومات والاتصالات-جامعة طرطوس- سورية.

## Improving the classification process in the VGG-16 model using transfer learning technique and negative selection algorithm

Prof. Yaroyb Dayoub\*

Eng.Raneem Adba\*\*

(Received 9/10/2023.Accepted 10/12/2023)

### □ABSTRACT □

The Artificial immune systems and their algorithms are one of the most used technologies in the fields of classification, organism detection and pattern recognition based on their nature inspired by the human immune system. This technique was used in the development and improvement of many problems in many fields, based on the good results and accuracy of these tool. In this research, we propose using this tool to develop the performance of VGG16 convolutional neural network, as these networks are considered one of the most used tools in many fields and applications, but the complexity in the structure of these networks imposes many challenges when using them, with the increase in the cost of building these networks. Making it a challenging task to use them, which made an urgent need for a mechanism that reduces cost and time when using these networks.

In this research, the work of convolutional neural networks (CNN) VGG16 was improved, where pre-trained models were utilized using transfer learning technology. The research works on improving the classification process in VGG16 model by modifying the output layer and through the use of the negative selection algorithm, one of the immune systems algorithms. The performance of the algorithm was evaluated by conducting a series of experiments on reference datasets widely used for image classification tasks and comparing the results with several traditional CNN models and with the basic model structure. This algorithm achieved the best accuracy of all the modern algorithms compared on the Cifar10 dataset.

**Keywords:** conventional neural networks, CNN, artificial immune systems, negative selection algorithm, deep learning, image classification, pattern recognition, VGG16.

\* Professor in Information and Communication Technology Engineering Faculty, Tartous University, Syria.

\*\* Student Master, Information Technology Engineering Department, Information and Communication Technology Engineering, Tartous University, Syria

## ١ - مقدمة:

تعد الرؤية الحاسوبية من مجالات علوم الحوسبة الحديثة وشكل من أشكال الذكاء الاصطناعي، تساعد هذه التقنية على رؤية العالم وتحليل البيانات المرئية لاستخدامها في اتخاذ القرارات أو اكتساب فهم حول البيئة والعالم بالإضافة إلى تحديد ومعالجة الأشياء مثل الصور ومقاطع الفيديو بنفس الطريقة التي يفعلها البشر [1].

تعد أنظمة المناعة الاصطناعية (Artificial Immune Systems(AIS) من أشهر أدوات الذكاء الاصطناعي في وقتنا الحاضر حيث أظهرت هذه الأنظمة في السنوات القليلة الماضية نجاحاً كبيراً في مجال الرؤية الحاسوبية وتحديداً في مهام التصنيف والتعرف على النماذج، حيث وفّرت درجة عالية جداً من الدقة مقارنة بطرق التعلم الآلي الأخرى وذلك نظراً لمرونتها ومحاكاتها لنموذج الطبيعة البشرية بالإضافة إلى استخدامها معالجة أولية قليلة نسبياً مقارنة بخوارزميات تصنيف الصور الأخرى. من ناحية أخرى، واجه الباحثون بعض المشاكل في التعامل مع الشبكات العصبونية التقليدية حيث تكون الدقة Accuracy محدودة عند معالجة بعض المشاكل وغير قابلة للتحسين حتى مع زيادة حجم بيانات التدريب Training set أو عدد الطبقات المخفية hidden layers لذلك حاول الباحثون تحسين أداء هذه الشبكات من خلال استخدام تقنيات عديدة [2]. ويعد تطوير أداء الشبكات العصبونية الالتفافية ومحاولة تقليل كلفتها الحسابية حاجة لا بد منها نظراً لاستخدام هذه الأداة في العديد من التطبيقات.

تم تطبيق العديد من الدراسات لتحسين عمل الشبكات العصبونية الالتفافية نظراً لأهمية هذه الأداة في العديد من المجالات حيث اعتمدت الدراسات على استخدام تقنيات مختلفة. وقد تناولت الدراسات السابقة العديد من الأدوات لتقليل التعقيد الحاصل في الشبكات العصبونية الالتفافية. وفي محاولة لتقليل الوقت الذي يقضيه الباحث في بناء الشبكة العصبونية الالتفافية قامت أحد الدراسات ببناء نموذج يقوم باختيار بنية الشبكة العصبونية المناسبة لمشكلة البحث بشكل تلقائي وذلك عن طريق استخدام أحد خوارزميات المناعة الاصطناعية وقد تناول البحث إنشاء فضاء من بنى الشبكات العصبونية الالتفافية ومحاولة اختيار البنية الأمثل من هذه البنى المقترحة ولكن عملية إعادة التدريب تتطلب محاكاة عدة شبكات عصبونية بدلاً من شبكة واحدة الأمر الذي يضيف نوع من التعقيد في النموذج المقترح [3]، وقد حل الباحثون منهجية عمل الشبكة العصبونية الالتفافية وذلك لتحسين دقة عمل هذه الشبكات وذلك باستخدام أحد خوارزميات المناعة الاصطناعية حيث كانت نسبة الخطأ مقبولة ولكن محدودية بيانات التدريب شكلت نوع من التحدي ولاسيما أن المقارنة تتم مع قاعدة البيانات الكبيرة MNIST [4]. كما اعتمد الباحثون استخدام نموذج هجين يعتمد على مصنف ضبابي وتدريبه باستخدام خوارزمية الاختيار النسلي وهي أحد خوارزميات المناعة الاصطناعية وذلك لتحسين عملية التصنيف وفق قاعدة البيانات المقترحة ولكن النموذج المقترح يتسم بالتعقيد لاسيما أن الشبكات العصبونية الالتفافية بطبيعتها عملها وبنيتها المكونة من العديد من الطبقات المخفية تحتوي على نوع من التعقيد وبالتالي تمت إضافة تعقيد حسابي ناتج عن دمج جميع هذه التقنيات مع بعضها [5]، وقد تم دمج خوارزميتان من خوارزميات المناعة الاصطناعية وذلك لتحسين عمل الشبكة العصبونية الالتفافية للتعرف على الصور الشعاعية حيث قامت الدراسة على استخدام الشبكة العصبونية الالتفافية Alex Net وتم إضافة طبقة خرج معدلة إلى الشبكة وذلك من خلال تقنية نقل التعلم التي تعتمد على استخدام النماذج المدربة مسبقاً ولكن محدودية بيانات التدريب في الدراسة لاسيما عند التعامل مع هذا النوع من الصور ساهم بضعف النموذج المقترح [6].

## ٢ - مشكلة البحث:

تعد بنية الشبكة العصبونية الالتفافية عاملاً رئيسياً في تحديد أدائها وغالباً ما تؤثر آلية تكوينها وتوزع الطبقات خلالها على السرعة والدقة في تنفيذها للمهام المختلفة. يعتبر النموذج VGG16 واحداً من أكثر نماذج الشبكات العصبونية الالتفافية انتشاراً واستخداماً. كما أنّ تطوير آلية عمل هكذا نوع من النماذج يعتبر خطوة هامة نتيجة تزايد استخدامها في العديد من المجالات، حيث أنّ على الرغم من كفاءة هذه الأداة إلا أن اختيار البنية المناسبة غالباً ما يشكل نوع من التحدي وذلك لتنوع هذه النماذج واختلافها من حيث التكوين والتركييب وعدد الطبقات. تعد مهمة تصنيف الصور مهمة رئيسية لهكذا نوع من النماذج حيث تعتمد الطريقة التقليدية على استخدام بنية النموذج بشكل مباشر في عملية التصنيف. ولذلك نحن بحاجة إلى تطوير هذه النماذج لتقدم كفاءة أعلى في مهامها المختلفة كالتصنيف وغيرها وذلك من خلال تحسينها عن طريق اعتماد خوارزميات مساعدة لها تساهم في تطوير أدائها.

## ٣ - أهمية البحث وأهدافه

يستمد هذا البحث أهميته من ظهور أنظمة المناعة الاصطناعية كنماذج رائدة في معالجة العديد من المهام بالإضافة إلى فعاليتها ومرونة استخدامها وخوارزمياتها المتنوعة. نهدف في هذا البحث إلى دراسة عيوب النموذج VGG16 وتحديد أبرز المشاكل التي يعاني منها وتحسين أداء هذه الأداة المستخدمة في العديد من المهام عن طريق دراسة التعقيد الحسابي للشبكات وتحسين دقة النتائج وذلك باستخدام خوارزميات المناعة الاصطناعية. حيث تقوم أنظمة المناعة الاصطناعية على تعزيز أداء الشبكات العصبونية الالتفافية وتستمر بتطويرها من خلال العمل على تحسين عملية التصنيف التي تقوم بها الشبكة. ومما يجعل هذه الأنظمة أداة قوية لتحسين أدوات الذكاء الاصطناعي بشكل عام نظراً لتنوع استخداماتها.

## ٤ - طرق البحث ومواده:

تم تنفيذ هذا البحث باستخدام لغة البرمجة بايثون (Python) وهي واحدة من أشهر لغات البرمجة المستخدمة في مجال الذكاء الاصطناعي والتعلم العميق وتتضمن العديد من المكتبات التي تساعد في إظهار وتحسين العديد من النقاط المطروق إليها في البحث. كما تم اختيار منصة غوغل كولايب ( Google Collaboratory) كبيئة عمل لإنجاز عملية المحاكاة حيث تعتبر هذه المنصة واحدة من أشهر المنصات السحابية التي تؤمن آلية للتخزين السحابي وإجراء عملية المحاكاة المختلفة في الزمن الحقيقي كما تتيح استخدام المحرر (Jupyter Notebook) من دون الحاجة إلى تنصيب مكتباته وبيئته على الحاسب المحلي. كما تم استخدام العديد من المكتبات مثل Keras , Tensor Flow لإنجاز عملية المحاكاة. ومن أجل رسم واستعراض المخططات تم استخدام المكتبة Matplotlib والمكتبة Numpy من أجل التعامل مع المعادلات الرياضية [7].

يساعد استخدام منصة غوغل كولايب على إنجاز عملية المحاكاة بمرونة، كما يضمن دقة النتائج المدروسة. ومن أجل ضمان الوصول إلى نتيجة أفضل تمت معالجة البيانات قبل إدخالها إلى النموذج المقترح. حيث تم استخدام قاعدة البيانات المعيارية CIFAR-10 من موقع Tenser Flow [8].

## ٥- منهجية البحث المقترحة

تقوم منهجية البحث المقترحة على تحسين آلية عمل الشبكة العصبونية الالتفافية عن طريق تعديل طبقة الخرج حيث تم الاعتماد على خوارزمية الاختيار السلبي ضمن عملية التصنيف وذلك للوصول لأفضل دقة ممكنة. كما تم استخدام مبدأ نقل التعلم للعمل مع بنية الشبكة العصبونية الالتفافية VGG-16، وقد اتسمت الدراسات السابقة بقلّة بيانات التدريب من جهة ومن ناحية أخرى وجود بعض التعقيد في دراسات أخرى. يحاول النهج المقترح الوصول إلى الأداء الأفضل بأقل تعقيد ممكن.

يقدم النهج المقترح نموذج هجين لتحقيق مستوى أفضل من التصنيف مقارنة بالأساليب التقليدية المتبعة وذلك من خلال الدمج مع خوارزمية الاختيار السلبي. يتميز هذا النهج المقترح بموائمته لعمليات التصنيف المختلفة وإمكانية إعداده بسهولة دون الحاجة إلى استهلاك الكثير من الموارد المتاحة.

تمت دراسة بعض النماذج التقليدية للشبكات العصبونية الالتفافية: ResNet5, VGG16, InceptionV3 واستخدامها في تصنيف قاعدة البيانات المختارة ومقارنة النتائج مع النموذج المقترح.

يحتوي النهج المقترح في الشكل (١) على عدة مراحل تبدأ بتجميع وتجهيز البيانات ومن ثم تجهيز الشبكة VGG-16 وتعديل طبقة الخرج فيها وتدريبها وتنتهي باستخدام خوارزمية الاختيار السلبي التي تتضمن عدة مراحل متتالية وصولاً إلى نتيجة التصنيف النهائية:



الشكل (١) مخطط يمثل منهج العمل المقترح

### ١-٥ مرحلة تجميع وتجهيز البيانات:

تعتبر الشبكات العصبونية الالتفافية أحد الأدوات الرائدة في مجالات عديدة كالتعرف على النماذج واكتشاف الكائنات في الصورة ولذلك تعتبر الصور أحد أهم نماذج البيانات التي تتعامل معها هذه الشبكات. تم اختيار قاعدة البيانات المعيارية CIFAR-10 للعمل عليها ودراستها في النموذج المقترح. وتتكون قاعدة البيانات CIFAR-10 من ٦٠ ألف صورة ملونة مقسمة إلى ست فئات وكل فئة تحتوي على ١٠٠٠٠ صورة [8]. حيث أن قاعدة البيانات المختارة مقسمة إلى مجموعتين من حيث الاستخدام ودراسة فعالية النموذج:

(a) مجموعة التدريب training set: هي المجموعة التي يتم تدريب النموذج عليها وتحتوي على ٥٠٠٠٠ صورة تم اختيارها بشكل عشوائي.

(b) مجموعة الاختبار test set: مجموعة صغيرة تُستخدم فقط لتقييم أداء النموذج النهائي. وتتضمن هذه المجموعة الصور المتبقية والتي يبلغ عددها ١٠٠٠٠ صورة. نرى في الشكل (٢) نماذج الصور المكونة لقاعدة البيانات CIFAR-10 حيث لدينا عشر أصناف مختلفة مكونة لقاعدة البيانات:



الشكل (٢): قاعدة البيانات المعيارية CIFAR-10 [8]

تمت دراسة حجم الصورة الموجودة ضمن قاعدة البيانات وتعديلها بما يتناسب مع الشبكة العصبونية الالتفافية وذلك لأنه في نموذج الشبكة VGG-16 يكون حجم الصورة المدخلة فيها هو: (٣\*٢٢٤\*٢٢٤) لذلك يجب أن تكون صورة الدخل ضمن قاعدة البيانات المستخدمة مطابقة للحجم الذي يتعامل معه نموذج الشبكة. وقد تمت دراسة حجم الصورة وتعديلها من خلال مكتبة Keras المتاحة في لغة البايثون.

### ٢-٥ تجهيز الشبكة العصبونية الالتفافية VGG-16:

يتم في هذه المرحلة بناء الشبكة العصبونية الالتفافية VGG-16 وذلك من خلال تقنية نقل التعلم وتعتمد هذه التقنية على استخدام نماذج مدربة مسبقاً من البيانات الأمر الذي يقلل من حدوث مشكلة over-fitting، حيث يقوم البحث على معالجة هذه المشكلة التي تظهر أثناء تدريب الشبكات العصبونية، ويمكن

التعبير عن حدوث هذه الحالة عندما يكون النموذج قادر على التصنيف أو التنبؤ بالبيانات المضمنة في قاعدة بيانات التدريب (training set) ولكنه غير جيد في تصنيف بيانات لم يدرب عليها مسبقاً. ويمكن استخدام هذه التقنية لتقليل حدوث مشكلة over-fitting.

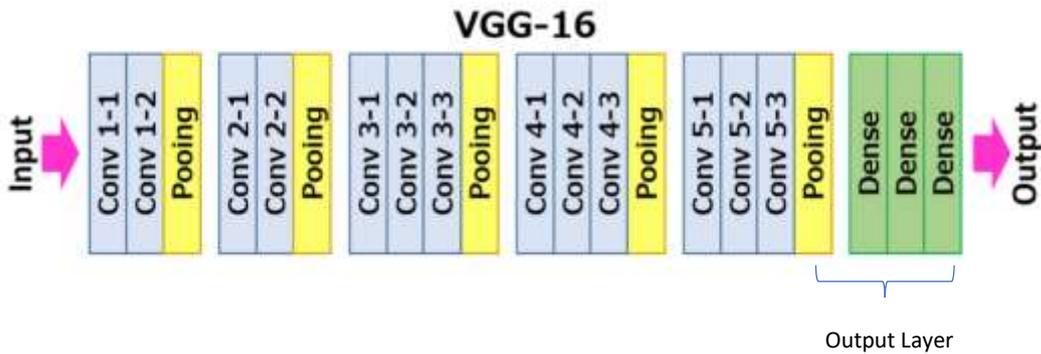
ويتم في هذه التقنية تدريب النموذج بشكل مسبق على نطاق واسع جداً من مسائل تصنيف الصور ضمن قاعدة بيانات imagenet (وهي قاعدة بحثية ضخمة تضم أكثر من ١٤ مليون صورة تنتمي لأكثر من ٢٠٠٠٠ صنف) لذلك تميل هذه النماذج المعتمدة في هذه التقنية على تعلم مزايا تمييزية فاصلة جيدة للغاية لأنه تم تدريبها على عدد كبير من الصور وإنّ تطبيقها يساعد في حل مهام أو مسائل أخرى غير المهام التي تدربت عليها سابقاً وبشكل ذلك نقطة بداية مفيدة جداً على اعتبار أنّ المزايا التي تمّ تعلّمها أثناء التدريب على المهمة القديمة ستكون مفيدة للمهمة الجديدة، وذلك عن طريق استخدام الطبقات الالتفافية لهذه النماذج لاستخراج الخصائص ثم تدريب مصنف يعتمد على الخصائص المستخرجة، وبالإضافة إلى ذلك إنّ استخدام هذه التقنية يفيد في تقليل زمن التدريب [9] الأمر الذي تعاني منه الشبكات العصبونية الالتفافية.

تتقسم بنية نموذج الشبكة العصبونية الالتفافية VGG-16 الذي يقوم بمهمة تصنيف الصور image classification إلى قسمين:

- ١- استخلاص الخصائص: وتقوم بهذه المهمة الطبقات الالتفافية وما بينها من طبقات ثانوية مثل طبقات التجميع (pooling layers).
- ٢- التصنيف: وتقوم به الطبقات الأخيرة وهي طبقات الاتصال الكامل وخاصة طبقة الخرج (output layer).

### ٥-٣ تعديل طبقة الخرج في نموذج الشبكة العصبونية الالتفافية VGG-16:

يحتوي النموذج VGG-16 بتكوينه على ١٦ طبقة متتالية وهي تتمثل ب ١٣ طبقة من طبقات الالتفاف والتجميع وتليها ثلاث طبقات تمثل طبقة الخرج (الطبقة الكاملة الاتصال)، حيث تعتبر هذه الطبقة مسؤولة عن عملية التصنيف وذلك من خلال التعامل مع مخرجات الطبقات السابقة.



الشكل (٣): بنية الشبكة العصبونية الالتفافية VGG-16

نرى في الشكل (٣) طبقة الخرج في النموذج VGG-16 مكونة من ثلاث طبقات متتالية، في الطبقتين الأولى والثانية من طبقة الخرج يتم التعامل مع مخرجات الطبقات الالتفافية السابقة من الميزات المستخرجة وإرسالها إلى الطبقة الثالثة التي ستقوم بمهمة التصنيف. تم في البحث دراسة مكونات الطبقة الثالثة وإجراء بعض التعديلات عليها بما يتناسب مع مهمة التصنيف المطلوبة كما هو مبين في الجدول (١):

جدول (1) مكونات الطبقة الأخيرة من طبقة الخرج في النموذج VGG-16 والتعديلات التي تمت عليها

Output layer	Number of units	Activation Function
VGG16 model	1000	Linear activation function
VGG16 modified model	10	Softmax activation function

- ١- عدد الوحدات المستخدمة: حيث يحتوي النموذج الأساسي على ١٠٠٠ وحدة في طبقة الخرج وبالتالي قمنا بإنقاص عدد الوحدات ليتوافق مع قاعدة البيانات المستخدمة التي تتضمن ١٠ صنف حيث سيتم استخدام ١٠ وحدات في بنية النموذج الجديدة. ويعتبر تحديد عدد الوحدات خطوة مهمة وذلك لتحسين أداء نموذج لاسيما في مهام التصنيف المتعددة الفئات.
- ٢- تم استخدام تابع التنشيط softmax: تم اعتماد تابع التنشيط softmax في عملية التصنيف حيث يعتبر هذا التابع ملائم لمشاكل التصنيف متعددة الفئات والتي تناسب حالة قاعدة التي يتم التعامل معها في البحث الذي يعمل وفق مبدأ التوزيعات الاحتمالية:

$$\sigma(\vec{z})_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (1)$$

Zk

شعاع الدخل من Z0 حتى

Zi: يمثل أي عنصر من شعاع الدخل.

e<sup>Zi</sup>: يتم تطبيق التابع الأسّي على كل عنصر من شعاع الدخل.

K: عدد العناصر في الشعاع.

ويعتبر التابع softmax أكثر مرونة في مهام التصنيف المتعددة الفئات كما في حالة قاعدة البيانات المراد تصنيفها وبالتالي لديه فعالية أكثر من تابع التنشيط الخطي Linear Activation.

٥-٤ تدريب الشبكة:

تم تدريب الشبكة العصبونية الالتفافية VGG-16 والقيام بعملية التصنيف الأولية، حيث تم تجميد جميع طبقات النموذج ما عدا الطبقات الثلاث الأخيرة حيث الطبقات الالتفافية الأولى من النموذج تستخلص الخصائص المحلية الأكثر عمومية مثل الحواف والألوان والشكل أما الطبقات الأكثر عمقاً في النموذج تستخلص الخصائص الأكثر خصوصية [9] أي أن درجة العمومية للخصائص في كل طبقة تعتمد على عمق الطبقة وموقعها بالنسبة إلى طبقات النموذج لذلك يتم استخدام الطبقات الأولى من النموذج لاستخلاص الخصائص الأكثر عمومية أما الطبقات الأعلى المدربة على الخصائص أو المزايا الأكثر خصوصية تحتاج إلى إعادة تدريب وضبط لملائمة مهمة التصنيف المطلوبة.

**٥-٥ استخدام خوارزمية الاختيار السلبي:**

يتم استخدام خوارزمية الاختيار السلبي التي تقوم بالتصنيف وفق عدة مراحل من المطابقة والمراقبة للوصول بعدها إلى نتيجة التصنيف النهائية.

تعتمد هذه الخوارزمية في آلية عملها على اختيار وتحديد السلوك الشاذ (غير الذاتي) في النظام حيث تعمل بمبدأ مشابه لعمل الخلايا للمفاوية في الجسم من حيث توليد كواشف مناعية، حيث تتمثل هذه الكواشف في البحث بسلسلة من الأصفار والوحدات تم توليدها عشوائياً من مجموعة البيانات المستخلصة من خرج النموذج VGG-16، حيث تمكن الطريقة العشوائية في توليد الكواشف من تغطية مساحات أعلى بالبحث واستخدام الموارد الحسابية بكفاءة أعلى.

وتعتبر هذه الخوارزمية الأكثر شيوعاً لمشاكل التصنيف من خوارزميات أنظمة المناعة الاصطناعية وهي خوارزمية فعالة وتستهلك ذاكرة قليلة وتستخدم على نطاق واسع في تطبيقات التعلم العميق [10] وتم تحديد دالة الانتروبيا للخسارة التي تقوم بحساب الخطأ وقياس الدقة accuracy لاختبار الأداء. تعمل الخوارزمية وفق المراحل التالية:

١- تعريف البيانات الذاتية (self-data): والتي تمثل مدخلات النظام وسيتم تمثيلها وفق ثنائيات من الأصفار والوحدات حيث أن الدخل لدينا عبارة عن صورة والتي تتكون من تسلسل من البكسلات.  
٢- توليد الكواشف: تتم عملية توليد الكواشف بالاعتماد على البيانات الذاتية التي يتم الحصول من خرج النموذج VGG-16.

٣- المراقبة: ويتم في هذه المرحلة التحقق من عمل الكواشف التي تم توليدها من خلال استخدام مسافة هامينغ وهي مقياس يستخدم لقياس التشابه أو الاختلاف بين سلسلتين ثنائيتين متساويتين في الطول. فهو يحسب عدد المواضع التي تختلف فيها البتات المقابلة في السلسلتين. وتعطى بالعلاقة التالية [11]:

$$d(x, y) = \frac{1}{n} \sum_{i=1}^{n} |x_i - y_i| \quad (2)$$

$d$ : مسافة هامينغ بين السلسلتين  $x, y$

$y_i$ : تعبر عن السلسلة الأولى

$x_i$ : تعبر عن السلسلة الثانية

$n$ : عدد مرات التكرار

٤- التصنيف: تقوم الخوارزمية بعملية التصنيف ويتم الوصول إلى نتيجة التصنيف النهائية. وقد تم تضمين الخوارزمية عن طريق استخدام المكتبات المتوفرة بلغة البايثون ومحاكاتها على قاعدة البيانات المختارة CIFAR-10.

**٥-٦ تقييم النموذج وحساب الدقة:**

يقوم النموذج بتصنيف الصور وفق قاعدة البيانات المختارة وبعد تجهيز النموذج وتدريبه يتم اختباره على بيانات التحقق ثم يتم حساب مصفوفة الارتباك confusion matrix لكل نموذج حيث تحتوي هذه المصفوفة على عدد

الحالات الإيجابية والسلبية الصحيحة والكاذبة ويرمز لها بالرموز True Positive (TP) و False Negative (FN) و False Positive (FP) و True Negative (TN)، يظهر الجدول (٢) مصفوفة الارتباك:

جدول (٢) مصفوفة الارتباك confusion matrix

	(No) Predicted	Predicted (yes)
Actual (No)	TP	FN
Actual (yes)	FP	TN

وبناء على هذه الأرقام يتم حساب مجموعة من القيم التي تقيم أداء النموذج وهي [12]:

▪ **الدقة accuracy**: هي عدد الحالات التي تم تصنيفها بشكل صحيح على

جميع الحالات وتعطى بالمعادلة:

$$\text{Accuracy} = \frac{\text{Number of correct assessments}}{\text{Number of all assessments}} = \frac{TN+TP}{TN+TP+FN+FP} \quad (٣)$$

▪ **الحساسية sensitivity**: تسمى أيضاً بالاسترجاع recall وهي مجموع

الحالات الإيجابية المصنفة بشكل صحيح على جميع الحالات الإيجابية .

$$\text{Sensitivity} = \frac{\text{Number of true positive assessment}}{\text{Number of all positive assessment}} = \frac{TP}{TP+FN} \quad (٤)$$

▪ **الضبط Precision**: هي مجموع الحالات الإيجابية المصنفة بشكل صحيح

على مجموع الحالات السلبية والحالات الإيجابية .

$$\text{Precision} = \frac{\text{Number of true positive assessment}}{\text{Number of true and negative assessment}} = \frac{TP}{TP+FP} \quad (٥)$$

▪ **Fscore**: ويعبر عن الأداء العام لعملية التصنيف ويتم حسابه وفق مزيج من

الحساسية والضبط.

$$Fscore = \frac{2x(\text{Precision} \times \text{Sensitivity})}{(\text{Precision} + \text{Sensitivity})} \quad (٦)$$

يعد معيار الخسارة (Loss) أحد المعايير المهمة لتحديد أداء النموذج حيث يجب على النموذج الحصول على قيم صغيرة ليحقق أداء أفضل. ومن أجل قياس الخسارة في النموذج المستخدم في البحث تم الاعتماد على دالة الانتروبيا للخسارة حيث تعتبر هذه الطريقة مناسبة وفعالة لحساب الخسارة لاسيما في مشاكل التصنيف المتعددة الفئات كحالة التصنيف الموجودة في البحث.

## ٦- النتائج والمناقشة

تم اختيار أكثر نماذج الشبكات العصبونية الالتفافية شهرة في مجال التعلم العميق والتي تستخدم في مجالات مختلفة حيث تختلف هذه النماذج من حيث البنية وعدد الطبقات والمعاملات المطلوبة وقد تم تطبيقها

على قاعدة البيانات المختارة ومقارنتها مع النموذج VGG-16 والنهج المقترح في البحث الذي تم تحسينه وفق خوارزمية الاختيار السلبي:

(a) النموذج ResNet50 : يتألف من ٥٠ طبقة ومن خلال هذا النموذج تم اثبات إمكانية تدريب الشبكات الأكثر عمقاً حيث تم تجاوز عتبة الإشباع في الدقة عند زيادة عدد الطبقات وذلك من خلال تقنية تسمى الكتلة المتبقية residual block وهي كتلة من طبقتين التفاضليتين لهما نفس عدد المرشحات حيث يضاف خرج الطبقة الثانية مع دخل الطبقة الأولى وبعدها يجمع دخل هذه الوحدة مع خرجها ويسمى وصلة الاختصار shortcut connection [13].

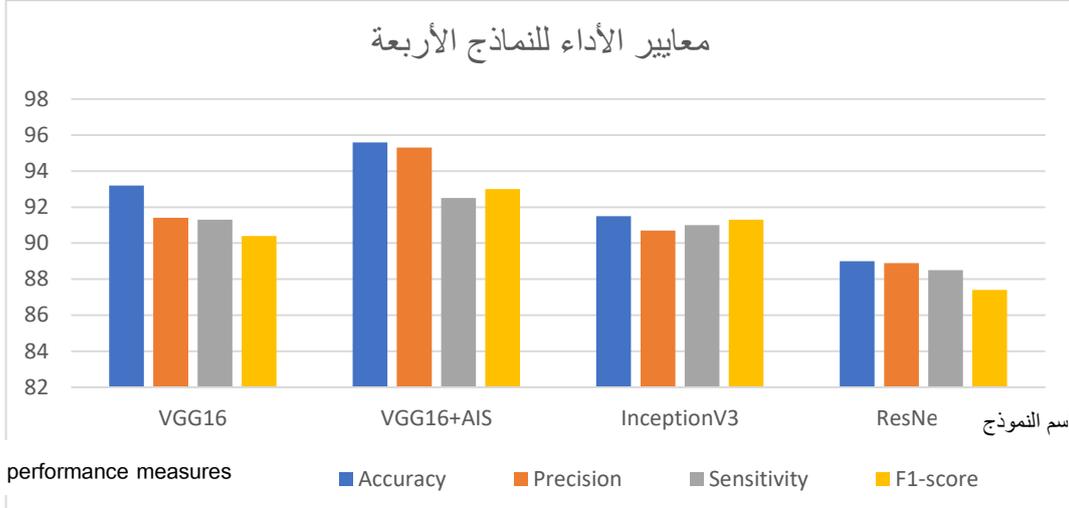
(b) النموذج InceptionV3: يتألف من ٤٨ طبقة مكونة للنموذج ويتضمن وحدات بناء أساسية تسمى inception module وهي كتلة من طبقات التفاضلية ذات أحجام مرشحات مختلفة وطبقة تجميع وفق القيمة الأكبر ثم يتم جمع نتائج جميع الطبقات مما يؤدي لتقليل كمية العمليات الحسابية المطلوبة [13].

يظهر الجدول (٣) مقارنة بين قيم معايير الأداء للنماذج المستخدمة حيث تم اعتماد النموذج VGG16 ودراسته خلال البحث وتحسينه من خلال إجراء بعض التعديلات على طبقة الخرج وتحسين التصنيف باستخدام خوارزمية الاختيار السلبي (VGG16+AIS)، كما تم استخدام نماذج الشبكة العصبونية الالتفافية وهي VGG16 ResNet50 و InceptionV3 وتطبيقهما على قاعدة البيانات CIFAR-10 وذلك على منصة غوغل كولا ب ( Google Collaboratory) باستخدام لغة البرمجة بايثون ومن الواضح أن النهج المقترح (VGG16+AIS) قد أعطى أفضل دقة وهي ٩٥.٦% بين النماذج المختارة.

جدول (٣) مقارنة بين قيم معايير الأداء للنماذج المستخدمة

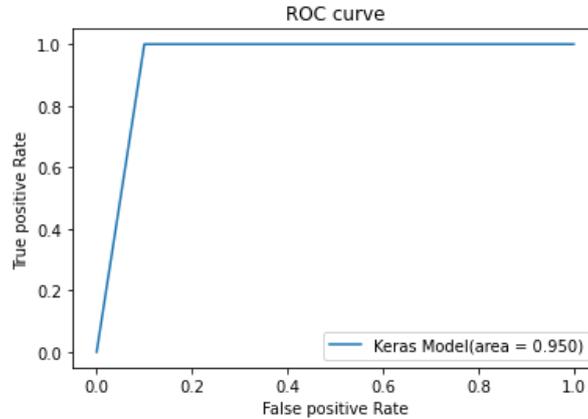
Base model	Accuracy	Precision	Sensitivity	F1-score
VGG16	93.2%	91.4%	91.3%	90.4%
VGG16+AIS	95.6%	9٥.3%	92.5%	93%
InceptionV3	91.5%	90.7%	91%	91.3%
ResNet50	89%	88.9%	88.5%	87.4%

ويعتبر استخدام الأسلوب الهجين المعتمد في هذا البحث كما هو ملاحظ قد زاد من كفاءة الشبكات العصبونية الالتفافية حيث وفق المقارنة بين أداء نماذج الشبكة العصبونية الالتفافية التقليدية: VGG-16، ResNet50، InceptionV3 والنموذج المقترح (VGG16+AIS) تبين أن استخدام خوارزمية الاختيار السلبي وتقنيات أنظمة المناعة الاصطناعية يزيد من دقة وأداء النموذج.



الشكل (٤): مقارنة النموذج المقترح والنماذج التقليدية وفق معايير الأداء المختارة

في الشكل (٤) نرى معايير الأداء للنماذج التقليدية الثلاث المختارة والنموذج المقترح (VGG16+AIS) حيث من الواضح تفوق النموذج المقترح بأدائه على النماذج الأخرى. في الشكل (٥) تم رسم مخطط خاصية تشغيل المستقبل (ROC) receiver operating characteristic وهو مخطط بياني يوضح القدرة التشخيصية لنظام تصنيف متعدد الفئات عن طريق رسم المعدل الإيجابي الحقيقي (True Positive Rate (TPR) (المحور الشاقولي) مقابل المعدل الإيجابي الخاطئ (False Positive Rate (FPR) (المحور الأفقي).



الشكل (٥): مخطط ROC

يعرف المعدل الإيجابي الحقيقي TPR أيضاً بالحساسية أو احتمال الاكتشاف [14]

$$TPR = \frac{TP}{TP+FN} = \text{Sensitivity} \quad (7)$$

يعرف المعدل الإيجابي الكاذب FPR باحتمال الإنذار الخاطئ [14]

$$FPR = \frac{FP}{TN+FP} = 1 - \text{Specificity} \quad (8)$$

تسمى المنطقة الواقعة تحت منحنى ROC ب (Area under the ROC Curve (AUC) وتعد هذه المنطقة مقياساً جيداً للأداء [14] حيث تقيس مدى جودة تنبؤات النموذج عبر جميع عتبات التصنيف الممكنة حيث أنه كلما كان منحنى ROC أقرب إلى الزاوية اليسرى العليا كان أداء المصنف أفضل وهي قيمة بين

٠ و١ وقد حصلنا على  $AUC=0.95$ . وهذا يعني أن الشبكة قد عممت بشكل جيد فعندما يتم تدريب شبكة عصبونية فإن أداء هذه الشبكة يتوقف على قابليتها على التعميم (generalization) وهو مدى قدرة الشبكة على التعلم من البيانات المقدمة لها وتطبيق ما تعلمته على بيانات أخرى مختلفة أي قدرتها على معالجة بيانات جديدة لم تتدرَّب عليها من قبل. لذا من الواضح أن اعتماد تقنيات مساعدة لنماذج الشبكات العصبونية الالتفافية يزيد من كفاءتها بالإضافة إلى اعتماد تقنية نقل التعلم التي تساعد في تقليل الزمن المطلوب في تدريب الشبكة الأمر الذي لطالما تعاني منه هذه الشبكات.

### الاستنتاجات:

- (١) تعطي أنظمة المناعة الاصطناعية دقة عالية من خلال خوارزمياتها المتنوعة وهي خوارزميات منخفضة التعقيد لأنها تعمل وفق خطوات متتالية.
- (٢) تؤدي أنظمة المناعة الاصطناعية دوراً هاماً في مشاكل التصنيف المتعدد الفئات، حيث تقوم خوارزمياتها على تحديد المشكلة ومعاينتها بشكل تلقائي وذلك بناءً على دراسة قيمة تابع التقارب فيها يتم انشاء مخرجات التصنيف.
- (٣) أظهرت النتائج أن استخدام النماذج المدربة مسبقاً كنقطة بداية في عملية التدريب بدلاً من تدريب نماذج جديدة من الصفر يفيد في تقليل زمن التدريب هذه الشبكات والحصول على دقة أعلى.
- (٤) كما أن اختيار بنية نموذج يتناسب مع طبيعة المشكلة المدروسة أمر هام للغاية، فبعد مقارنة العديد من النماذج المستخدمة يمكن ملاحظة أن النموذج VGG-16 نموذج مناسب لحل المشكلة المطروحة وقد وصلنا إلى دقة عالية نسبياً من خلال استخدام خوارزمية الاختيار السلبي لتحسين عملية التصنيف.

### الآفاق المستقبلية:

- ١- إمكانية اختبار خوارزمية الاختيار السلبي على عدة نماذج مختلفة من الشبكات العصبونية ومعالجة مشاكل مختلفة مثل اكتشاف الكائنات والتعرف على النماذج وغيرها.
- ٢- تطوير النماذج المدربة مسبقاً والتعديل عليها للاستفادة من مزايا هذه النماذج.
- ٣- اختبار الخوارزمية على قواعد بيانات متنوعة وكبيرة وتكوين نماذج مدربة مسبقاً من خلالها.
- ٤- دمج عدة خوارزميات مناعة اصطناعية مثل خوارزمية الاختيار النسلي بالإضافة لخوارزمية الاختيار السلبي للحصول على دقة أعلى وتحسين عملية التدريب بالنموذج المدرب.
- ٥- يعد تصميم بنى مختلفة من الشبكات الالتفافية موضوع اهتمام كبير نظراً لأن اختيار البنية الصحيحة يعد من الصعوبات التي تواجه هذا النوع من الشبكات لذلك يُقترح دراسة مفصلة أكثر لهذه النماذج والتعديل على بنية طبقاتها الأساسية لكن تدريب شبكات مؤلفة من عشرات الطبقات من الصفر يحتاج إلى أجهزة حاسوبية بموارد كبيرة ووقت طويل يصل إلى أسابيع أو أشهر بالإضافة إلى قواعد بيانات كبيرة جداً حيث أن إيجاد المعاملات غير المعروفة لشبكات CNN بدقة يتطلب الكثير من البيانات ولا يوجد قواعد ومعايير ثابتة لإيجاد المعاملات وإنما تعتمد على طبيعة المشكلة ونوع البيانات وتعقيدها وغيرها.

### المراجع

[1] Felsberg, M. (2017). *Five years after the Deep Learning revolution of computer vision: State of the art methods for online image and video analysis.*

- [2] LeCun, Y., Kavukcuoglu, K., & Farabet, C. (2010, May). Convolutional networks and applications in vision. In *Proceedings of 2010 IEEE international symposium on circuits and systems* (pp. 253-256). IEEE.
- [3] Frachon, L., Pang, W., & Coghill, G. M. (2019). Immunecs: Neural committee search by an artificial immune system. *arXiv preprint arXiv:1911.07729*.
- [4] Choudhury, Chirodip Lodh; Mahanty, Chandrakanta; Kumar, Raghvendra(2020), *A Novel Hybrid CNN-AIS Visual Pattern Recognition Engine*, IEEE, 2020 International Conference on Computer Science, Engineering and Applications (ICCSEA),
- [5] Korablyov, M., Axak, N., Fomichov, O., & Chuprina, A. (2020, September). *Hybrid Neuro-Fuzzy Model with Immune Training for Recognition of Objects in an Image*. In *ICST* (pp. 267-281).
- [6] Tao Gong, Tiantian Fan, Jizheng Guo, Zixing Cai.2016, *GPU-based parallel optimization of immune convolutional neural network and embedded system. Engineering Applications of Artificial Intelligence China, Vol.62,NO.384-395*  
<https://ieeexplore.ieee.org/abstract/document/8933016>
- [7] Google Colab Platform . Accessed: Feb. 25, 2022. [Online] .URL <https://colab.research.google.com/#scrollTo=UdRyKR44dcNI>.
- [8] Cifar-10 database . Accessed: May. 17, 2022. [Online] .URL <https://www.tensorflow.org/datasets/catalog/cifar10>
- [9] Chollet, François(2018), *Deep Learning with Python*, No 11964 ,New york- the United States of America,Manning Publications.
- [10] MOHI-ALDEEN, S; MOHAMAD, R; DERIS, S. *Application of Negative Selection Algorithm (NSA) for test data generation of path testing*. Applied Soft Computing, Vol. 49, 2016, 1118-1128.
- [11] Lasisi, A., Ghazali, R., & Herawan, T. (2014). Negative selection algorithm: a survey on the epistemology of generating detectors. In *Proceedings of the First International Conference on Advanced Data and Information Engineering (DaEng-2013)* (pp. 167-176). Springer Singapore.
- [12] Stralen, Karlijn J. van; Stel, Vianda S; Reitsma, Johannes; Dekker, Friedo; Zoccali, Carmine; Jager, Kitty (2009), *Diagnostic methods I: sensitivity, specificity, and other measures of accuracy*, *Kidney International*, V 75,pp 1257–1263.
- [13] Sotiropoulos, D., & Tsihrintzis, G. A. (2016). Machine learning paradigms: Artificial immune systems and their applications in software personalization.
- [14] Stralen, Karlijn J. van; Stel, Vianda S; Reitsma, Johannes; Dekker, Friedo; Zoccali, Carmine; Jager, Kitty (2009), *Diagnostic methods I: sensitivity, specificity, and other measures of accuracy*, *Kidney International*, V 75,pp 1257–1263.