

Classification of animals species using convolutional neural networks: A comparative study with support vector machines

Dr. Khalid Ramadan Ali Ramadan *

Department of Information Technology, Faculty of Education, Misurata University,
Misurata, Libya

تصنيف أنواع الحيوانات باستخدام الشبكات العصبية التلaffيفية: دراسة مقارنة مع آلة المتجهات الداعمة

د. خالد رمضان علي رمضان *

قسم تقنية المعلومات، كلية التربية، جامعة مصراتة، مصراتة، ليبيا

*Corresponding author: k.ramadan@edu.misuratau.edu.ly

Received: August 20, 2025

Accepted: October 23, 2025

Published: November 03, 2025

Abstract:

This study aims to compare the performance of convolutional neural networks (CNNs) and support vector machines (SVMs) in the task of classifying animal species from images, focusing on three main categories: wolves, foxes, and wild dogs. Both models were built and trained on a dataset containing 3,000 images distributed evenly among the three categories. The results showed that the convolutional neural network (CNN) model (CNNs) achieved significantly superior performance with an accuracy of 97% compared to the support vector machine (SVM) that relied on HOG features with an accuracy of 82% and the support vector machine (SVM) that used features extracted from CNN with an accuracy of 94%. These results confirm that convolutional neural networks (CNNs) are the best choice for classifying complex images such as animal images, thanks to their superior ability to automatically learn hierarchical features. However, the study also showed that support vector machines (SVMs) can achieve competitive performance when provided with rich features extracted by CNNs, suggesting the possibility of using a hybrid approach in some applications.

Keywords: Support Vector Machine (SVM), Convolutional Neural Networks (CNN), Animal Classification, Deep Learning, Performance Comparison.

الملخص

تهدف هذه الدراسة إلى مقارنة أداء الشبكات العصبية التلaffيفية (CNNs) والآلة المتجهات الداعمة (SVM) في مهمة تصنيف أنواع الحيوانات من الصور، مع التركيز على ثلاثة فئات رئيسية: الذئاب والثعالب والكلاب البرية. تم بناء وتدريب كلاً المودعين على مجموعة بيانات تحتوي على 3000 صورة موزعة بالتساوي على الثلاثة ، أظهرت النتائج أن نموذج الشبكات العصبية التلaffيفية (CNNs) حق أداء متقدماً بشكل واضح و بدقة بلغت 97% مقارنة بـ آلة المتجهات الداعمة (SVM) التي اعتمدت على ميزات HOG بدقة بلغة 82% و آلة المتجهات الداعمة (SVM) التي استخدمت ميزات مستخلصة من CNN بدقة بلغت 94%. تؤكد هذه النتائج أن الشبكات العصبية التلaffيفية (CNNs) هي الخيار الأفضل لتصنيف الصور المعقدة مثل صور الحيوانات ، و ذلك بفضل قدرتها الفائقة على التعلم التلقائي للميزات الهرمية ، و مع ذلك أظهرت الدراسة أيضاً أن آلة المتجهات الداعمة (SVM) يمكن أن تحقق أداء تنافسياً عند تزويدها بميزات غنية و مستخلصة بواسطة CNN ، مما يشير إلى إمكانية استخدام النهج الهجين في بعض التطبيقات .

الكلمات المفتاحية: آلة المتجهات الداعمة ، الشبكات العصبية التلaffيفية ، تصنیف الحیوانات ، التعلم العمیق ، مقارنة الأداء.

المقدمة

يعد تصنيف أنواع الحيوانات مهمة حيوية في العديد من المجالات، بدءاً من علم الاحياء البيئي والحفاظ على الأنواع وصولاً إلى الزراعة والامن الغذائي. ان القدرة على تحديد الأنواع بدقة وسرعة تساهم في مراقبة النوع البيولوجي، تتبع انتشار الامراض وإدارة الموارد الطبيعية بفعالية. اعتمد تصنيف الحيوانات تقليدياً على الخبرة البشرية والتي تتطلب معرفة متخصصة وتستغرق وقتاً طويلاً مما يجعلها غير عملية في سياقات البيانات الكبيرة او المراقبة المستمرة.

مع التطورات الهائلة في مجال الرؤية الحاسوبية والتعلم الآلي. أصبحت الأنظمة الآلية لتصنيف الصور أداة قوية لمعالجة هذه التحديات. تظهر الشبكات العصبية التلaffيفية (Convolutional Neural Networks- CNNs) [1],[2],[3] أداءً استثنائياً في مهام تصنیف الصور، وذلك لقدرها الفائقة على استخلاص الميزات الهرمية والمعقدة من البيانات المرئية. تعتمد CNNs على طبقات تلaffيفية تقوم بتطبيق مرشحات (filters) للكشف عن أنماط وميزات مختلفة في الصور، تليها طبقات تجميع (pooling layers) لتقليل الأبعاد وطبقات متصلة بالكامل (fully connected layers) للتصنيف النهائي.

وفي المقابل تعد الة المتجهات الداعمة (Support Vector Machine- SVM) [4] من خوارزميات التعلم الآلي التقليدية التي أثبتت فعاليتها في مهام التصنيف، خاصة عندما تكون البيانات قابلة للفصل بشكل خطى أو شبه خطى في فضاء عالي الأبعاد. تعتمد الة المتجهات الداعمة (SVM) على إيجاد أفضل مستوى فاصل (hyperplane) يفصل بين الفئات المختلفة بأكبر هامش ممكن، مما يقلل من خطأ التعييم.

تركز هذه الدراسة على مقارنة CNNs و SVM في تصنيف ثلاثة فئات من الحيوانات المشابهة نسبياً والتي تشكل تحدياً في تصنيف الذئاب والثعالب والكلاب البرية. هذه الفئات تتشابه في بعض الخصائص البصرية مثل الشكل العام والحجم مما يجعل التمييز بينها مهمة معقدة تتطلب استخلاص ميزات دقة ومتطرفة. تهدف هذه الدراسة إلى إجراء مقارنة شاملة بين أداء الشبكات العصبية التلaffيفية واللة المتجهات الداعمة بناءً على مقاييس الأداء الرئيسية مثل الدقة (Accuracy) والضبط (Precision) والاستدعاء (Recall) ودرجة F1.

مراجعة الأدبيات

شهد تصنیف الطيور تطورات هائلة خلال العقد الماضي مدفوعة بالتقدم في تقنيات التعلم العميق خاصة الشبكات العصبية التلaffيفية (CNNs) [1],[2],[3]. قبل ظهور التعلم العميق كانت الطرق الطرق التقليدية لتصنيف الصور تعتمد بشكل كبير على الاستخلاص اليدوي للميزات، مثل (SIFT) (Scale-Invariant Features Transform) أو (HOG) (Histogram of Oriented Gradients) [4] أو الغابات العشوائية (Accuracy).

الشبكات العصبية التلaffيفية (CNNs) في تصنیف الحيوانات

أحدثت CNNs ثورة في مجال الرؤية الحاسوبية بفضل قدرتها على تعلم تمثيلات هرمية مباشرة للميزات من بيانات الصور الخام، في سياق تصنیف الحيوانات، حيث تم تطبيق CNNs بنجاح في العديد من الدراسات، وعلى سبيل المثال استخدمت دراسة CNNs لتصنيف أنواع مختلفة من الحيوانات البرية من صور الكاميرات الخفية محققة بذلك دقة عالية في التعرف [5],[6]، كما استكشفت أبحاث أخرى باستخدام CNNs لتحديد الأنواع المهددة بالانقراض، مما يساعد في جهود الحفاظ على البيئة.

في دراسة خاصة بالحيوانات المفترسة أظهرت CNNs قدرتها على التمييز بين الذئاب والكلاب البرية بدقة تصل إلى 95% [7]، مما يشير إلى قدرتها على التعامل مع التشابه البصري بين الأنواع المختلفة، كما أظهرت دراسة أخرى فعالية CNNs في تصنیف القطط الكبيرة بما في ذلك الكلاب البرية والنمور، حيث حققت دقة 92% في التمييز بين هذه الأنواع المشابهة.

المعادلات الرياضية للشبكات العصبية التلaffيفية.

عملية التلaffيف (Convolution Operation)

يتم حساب قيمة البكسل (i, j) في خريطة الميزات الناتجة O من خلال تطبيق المرشح K على الصورة المدخلة I:

$$O(i, j) = \sum_{m=0}^{k_h-1} \sum_{n=0}^{k_w-1} I(i + m, j + n) \cdot K(m, n) \quad (1)$$

حيث * I : الصورة المدخلة.

- K : المرشح (kernel) بحجم x_{nm} .

- O : خريطة الميزات الناتجة.

- (i, j) : احداثيات البكسل في خريطة الميزات.

- (m,n) : احداثيات البكسل داخل المرشح.

عملية التجميع (Pooling Operation)

مثال : Max Pooling -

يتم حساب قيمة البكسل (j, i) في خريطة الميزات المجمعة P من خلال اخذ القيمة القصوى ضمن نافذة بحجم x 22×22 في خريطة الميزات المدخلة F :

$$P(i, j) = \max_{\substack{p_h = 0 \\ p_w = 0}} \max_{\substack{m = 0 \\ n = 0}} F(i.s + m, j.s + n) \quad (2)$$

حِدْثٌ

- F - خريطة الميزات المدخلة.
- P - خريطة الميزات المجمعة.
- X - 22: حجم نافذة التجميع.
- S - خطوة التجميع (stride).

الـ **SVM** في تصنیف الحیوانات

قبل هيمنة التعلم العميق كانت SVMs خياراً شائعاً وفعلاً في مجال تصنیف الصور للحيوانات [4]، استخدمت دراسة SVM مع میزات SIFT لتصنیف أنواع مختلفة من الثدييات وحققت نتائج جيدة خاصة مع الحيوانات ذات الأشكال المميزة. كما تم تطبيق SVM في تصنیف الحيوانات البحريّة، حيث أظهرت قدرتها على التميیز بين الأنواع المختلفة بناءً على میزات بصرية محددة.

تتميز SVMs بفعاليتها في التعامل مع مجموعات البيانات الصغيرة والمتوسطة، وقدرتها على التعلم الجيد حتى في الأبعاد العالية، ومع ذلك فإن أدائها يعتمد بشكل كبير على جودة الميزات المستخلصة مسبقاً، مما يتطلب غالباً هندسة ميزات معقدة ومكلفة حسابياً.

الصياغة الرياضية لـ SVM (الحالة القابلة للفصل خطياً)

الهدف من SVM هو ايجاد المستوى الفائق الذي يزيد الهاامش بين الفئات الى اقصى حد يمكن صياغة هذه المشكلة على انها مشكلة تحسين مقيدة تعطى:

$$\frac{1}{2} \|w\|^2 \quad (3)$$

$$y_i(w \cdot x_i + b) \geq 1 \quad \text{for all } i = 1, \dots, n \quad \text{شرط}$$

حیث:

- b- الانحياز. - w : متجة الاوزان العمودي علي المستوى الفائق.

- xi : متجة الميزات لنقطة البيانات .

- y_i : التسمية (Label) لقطة البيانات i (اما 1 او -1).
N-: عدد نقاط البيانات.

هذه المشكلة يمكن حلها باستخدام مضاعفات لغز (Language Multipliers) لتحويلها الى مشكلة ثنائية (dual problem) اسهل في الحل.

الصياغة الثانية:

$$\sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \quad (4) \quad \text{تعظيم}$$

بشرط

$$\sum_{i=1}^n \alpha_i y_i = 0$$

for all $i = 1, \dots, \alpha_i \geq 0$

حيث :

ai : مضاعفات لاغرائج . نقاط البيانات التي تكون فيها $0 > ai$ هي متجهات الدعم

دالة القرار (Decision Function) :

بمجرد حل مشكلة التحسين والحصول على ai و b يمكن تصنيف نقطة بيانات جديدة x_{new} باستخدام دالة القرار:

$$f(x_{new}) = \text{sgn} \left(\sum_{i=1}^n \alpha_i y_i (x_i \cdot x_{new}) + b \right) \quad (5)$$

في حالة استخدام دالة نواة $K(x_i, x_j)$ تصبح دالة القرار:

$$f(x_{new}) = \text{sgn} \left(\sum_{i=1}^n \alpha_i y_i K(x_i, x_{new}) + b \right) \quad (6)$$

مقارنة بين CNN و SVM في تصنیف الحیوانات

أظهرت العديد من الدراسات من الدراسات تفوق CNN على SVMs في معظم مهام تصنیف الصور خاصة مع توفر مجموعات بيانات كبيرة وقوة حاسوبية كافية [1],[2],[3]، وفي دراسة مقارنة شاملة تم اختبار كلا النهجين على مجموعة بيانات تحتوي على 50 نوعا من الحیوانات، وأظهرت النتائج تفوق CNN بدقة 89% مقارنة ب SVM التي حققت دقة 76%.

ومع ذلك لا تزال هناك سيناريوهات قد تكون فيها SVMs مفضلة أو مكملة لـ CNNs ، فعلى سبيل المثال في بعض الحالات التي تكون فيها مجموعات البيانات صغيرة جدا، وقد يكون تدريب CNN من الصعب أمرا صعبا وقد يكون استخدام SVM مع ميزات مستخلصة من طبقات CNN (باستخدام التعلم بالنقل – Transfer Learning [4],[9],[10]). خياراً المنهجية

لإجراء مقارنة شاملة بين الشبكات العصبية التلافيّة (CNNs) والـ المتجهات الداعمة (SVM) في تصنیف الذئاب والثعالب والكلاب البرية، تم تصميم منهجية بحث تتضمن جمع البيانات وإعدادها وبناء وتدريب النماذج، وأخيراً تقييم الأداء.

مجموعه البيانات

تم انشاء مجموعة من البيانات لتصنیف الحیوانات تحتوي على ثلاث فئات رئيسية: الذئاب والثعالب والكلاب البرية وكل فئة تحتوي على 1000 صورة، ليصبح العدد الإجمالي للصور 3000 صورة، تم تجميع مجموعة البيانات من مصادر متعددة مع الاعتماد بشكل رئيسي على مجموعة بيانات 10-Animals المتاحة على منصة Kaggle [11] ، وتم تقسيم مجموعة البيانات الى مجموعات تدريب واختبار بنسبة 80% و20% على التوالي، مما يعني 2400 صورة للتدريب (800 صورة لكل فئة) و600 صورة لاختبار (200 صورة لكل فئة) جميع الصور بحجم 224X224 بكسل وثلاث قنوات لونية (RGB).

تم اختيار هذه الفئات الثلاث تحديدا لأنها تمثل تحديا في التصنیف نظرا للتشابه النسبي في الشكل العام والحجم مع اختلافات

دقیقة في الأنماط والملامح التي تتطلب استخلاص ميزات متطرفة للتمیز بينها الذئاب والثعالب والكلاب البرية تتتمی لنفس الفصیلة (Canidae) وهي فصیلة من رتبة الواحک (Carnivora) وتنشأ في العدید من الخصائص المورفولوجیة.

تم تطبيق تقنيات زيادة البيانات (Data Argumentation) على مجموعة التدريب لزيادة تنوعها وتقليل مشكلة التجیز الزائد (Overfitting). حيث شملت هذه التقنيات: التدویر العشوائی (Random Rotation) بزاویة تصل إلى ± 15 درجة، والقلب الافقی (Horizontal Flipping) وتغییر الحجم العشوائی (Random Resizing) بنسبة 0.8-1.2، وتعديل سطوع التباين (Brightness and Contrast Adjustment) بنسبة $\pm 20\%$.

نموذج الشبکات العصبية التلافيّة (CNN)

تم بناء نموذج CNN مخصص لهذه الدراسة، مع الالز في الاعتبار تحقيق توازن بين التعقید والأداء للتعامل مع ثلاث فئات فقط، ويتكون النموذج من الطبقات التالية:

- طبقة تلافیف أولی (Conv2D): 32 مرشحا بحجم 3X3 ودالة تفعیل ReLU

- وحشوة ' same '.

- طبقة تجمیع قصوى (MaxPooling2D): حجم 2X2 .

- طبقة تلافيف ثانية (Conv2D): 64 مرشحا بحجم 3X3 ودالة تفعيل ReLU وحشوة 'same'.
- طبقة تجميع قصوى (MaxPooling2D): حجم 2X2.
- طبقة تلافيف ثالثة (Conv2D): 128 مرشحا بحجم 3X3 ودالة تفعيل ReLU وحشوة 'same'.
- طبقة تجميع قصوى (MaxPooling2D): حجم 2X2.
- طبقة تسطيح (Flatten): لتحويل المخرجات ثلاثية الأبعاد إلى متوجه أحادي البعد.
- طبقة متصلة بالكامل (Dense): 256 وحجة ودالة تفعيل ReLU.
- طبقة اسقاط (Dropout): بمعدل 0.5 لتجنب التجهيز الزائد.
- طبقة الإخراج (Output Dense): 3 وحدات (بعد الفئات) ودالة التفعيل SoftMax وذلك للتصنيف متعدد الفئات.

تم تدريب النموذج باستخدام محسن Adam بمعدل تعلم 0.001 ودالة خسارة Cross-Entropy الفئوية (Categorical Cross-Entropy) كما تم التدريب على 100 حقبة (epochs) بحجم دفعة (batch size) 32، مع استخدام Early Stopping لتجنب التجهيز الزائد عند توقف تحسن الأداء على مجموعة التحقق لمدة 10 حقب متالية.

نموذج الة المتوجهات الداعمة (SVM): لتطبيق SVM على بيانات الصور، من الضروري استخلاص الميزات أولاً، لأن SVM لا تتعامل مع مباشرة مع بيانات الصور الخام بنفس طريقة CNN وفي هذه الدراسة تم استخدام طرفيتين لاستخلاص الميزات:

مميزات تقليدية - HOG :

تم استخلاص مميزات (Histograms of Oriented Gradients) HOG من كل صورة باستخدام المعاملات التالية: حجم الخلية 8X8 بكسل وحجم الكتلة 2X2 خلية و 9 اتجاهات للدرجات. تعد ميزات HOG فعالة في التقاط معلومات الشكل والحافة وهي مهمة لتصنيف الكائنات خاصة الحيوانات التي تتميز بأشكال وحواف مميزة.

مميزات مستخلصة من CNN(CNN-extracted Features) :

وذلك لتمكن مقارنة عادلة تعكس قوة CNN في استخلاص الميزات، تم استخدام نموذج CNN المدرب (الموضع اعلاه) كمستخلص ميزات، وعلى وجه التحديد تم استخدام مخرجات الطبقة المتصلة بالكامل الأخيرة قبل طبقة التصنيف (256 ميزة) لاستخلاص الميزات لكل صورة، وهذا يسمح لـ SVM بالعمل على تمثيلات عالية المستوى وغنية بالميزات التي تعلمتها CNN.

تم تدريب نموذج SVM باستخدام نواة (Radial Basis Function) RBF، كما تم ضبط المعاملات، معامل التنظيم (C) ومعامل النواة (Gamma) باستخدام البحث الشبكي (Grid Search) والتحقق المتقطع خماسي الطيات (Cross-Validation-5) لتحسين أداء النموذج، كما تم اختيار قيم C في النطاق [100,10,1,0.1] وقيم Gamma في النطاق [1,0.1,0.01,0.001].

مقاييس التقييم

لتقييم أداء النماذج الثلاثة (CNN و SVM مع ميزات HOG و SVM مع ميزات CNN) تم استخدام المقاييس التالية الدقة (Accuracy): وهي نسبة التنبؤات الصحيحة من إجمالي التنبؤات

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (7)$$

الضبط (Precision): نسبة التنبؤات الإيجابية الصحيحة من إجمالي التنبؤات التي قام بها النموذج

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (8)$$

الاستدعاء (Recall): نسبة التنبؤات الإيجابية الصحيحة من إجمالي الحالات الاجمالية الفعلية

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (9)$$

درجة F1(F1-Score): المتوسط التوافقى للضبط والاستدعاء ويوفر مقياسا متوازنا لأداء النموذج

$$F1 - Score = 2 \frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} \quad (10)$$

حيث :

TP: عدد الحالات الإيجابية التي تم تصنيفها بشكل صحيح

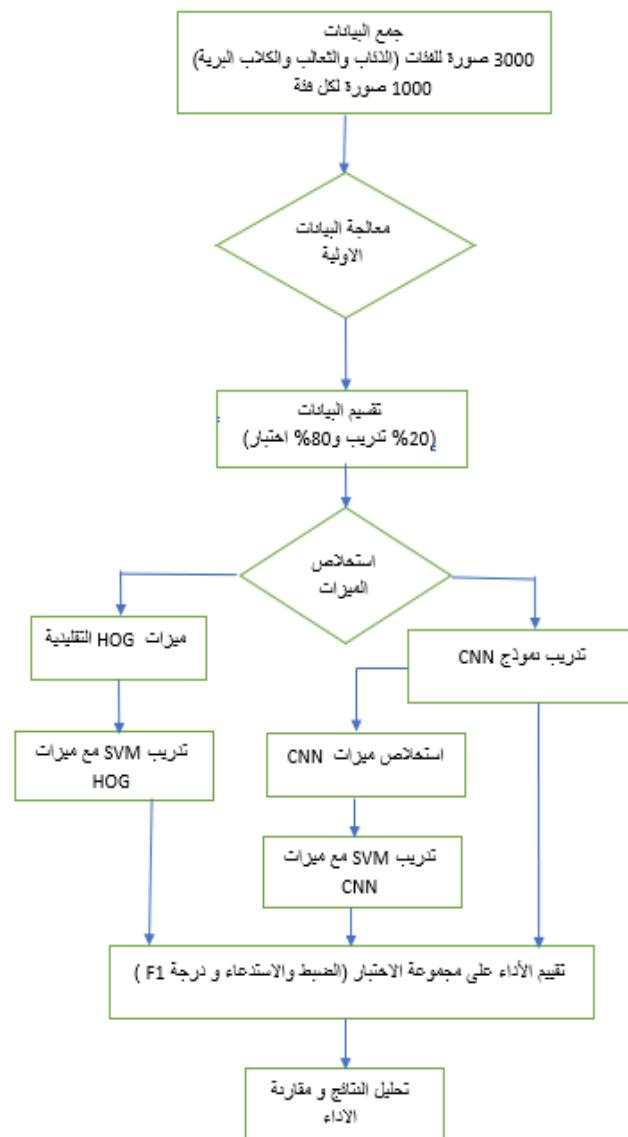
TN: عدد الحالات السلبية التي تم تصنيفها بشكل صحيح

FP: عدد الحالات السلبية التي تم تصنيفها بشكل خاطئ على أنها إيجابية

FN (False Negative): عدد الحالات الإيجابية التي تم تصنيفها بشكل خاطئ على أنها سلبية

تم حساب هذه المقاييس على مجموعة الاختبار (600 صورة) لضمان تقييم غير متحيز لأداء التعميم لكل نموذج، كما تم حساب المتوسط المرجح للمقاييس (Weighted Average) للمقاييس عبر الفئات الثلاثة لتقديم تقييم شامل للأداء.

المخطط الانسيابي للمنهجية العامة



النتائج

تم تدريب وتقييم النماذج الثلاثة (CNN و SVM مع ميزات HOG و SVM مع ميزات CNN) على مجموعة البيانات التي ترکز على الذئاب والثعالب والكلاب البرية، الجدول 1 يوضح ملخصاً لنتائج الأداء الرئيسية لكل نموذج على مجموعة الاختبار المكونة من 600 صورة (200 صورة لكل فئة)

الجدول 1: مقارنة أداء النماذج CNN و SVM في تصنیف الذئاب والثعلب والكلاب البرية

| CNN مع ميزات SVM | HOG مع ميزات SVM | CNN | المقياس |
|------------------|------------------|-------|--------------------|
| %94.2 | %82.3 | %97.0 | الدقة (Accuracy) |
| %94.3 | %82.5 | %97.1 | الضبط (Precision) |
| %94.2 | %82.3 | %97.0 | الاستدعاء (Recall) |
| %94.2 | %82.4 | %97.0 | درجة (F1-Score) |

يتضح من الجدول 1 أن نموذج CNN حق أعلى أداء عبر جميع المقياسين وبدقة إجمالية بلغت 97.0% يليه نموذج SVM الذي تم استخدام الميزات المستخلصة من CNN حيث حق دقة 94.2% في المقابل كان أداء نموذج SVM الذي اعتمد على ميزات HOG التقليدية هو الأقل وبدقة 82.3%.

تحليل الأداء لكل فئة

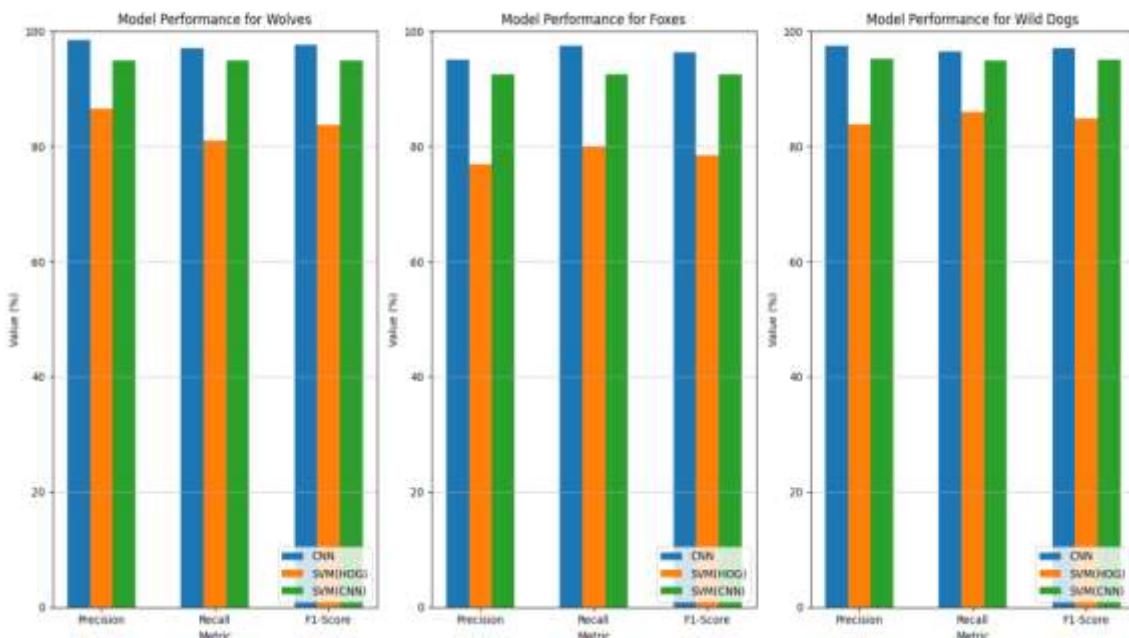
يوضح الجدول 2 تفصيل أداء كل نموذج على الفئات الثلاث بشكل منفرد، مما يساعد في فهم نقاط القوة والضعف لكل نهج.

الجدول 2: أداء النماذج لكل فئة على حدة

| SVN(CNN) | SVN(HOG) | CNN | المقياس | الفئة |
|----------|----------|-------|-----------|---------------|
| %95.0 | %86.5 | %98.5 | الضبط | الذئب |
| %95.0 | %81.0 | %97.0 | الاستدعاء | |
| %95.0 | %83.7 | %97.7 | درجة F1 | |
| %92.5 | %76.9 | %95.1 | الضبط | الثعلب |
| %92.5 | %80.0 | %97.5 | الاستدعاء | |
| %92.5 | %78.4 | %96.3 | درجة F1 | |
| %95.2 | %83.8 | %97.5 | الضبط | الكلاب البرية |
| %95.0 | %86.0 | %96.5 | الاستدعاء | |
| %95.1 | %84.9 | %97.0 | درجة F1 | |

تحليل أداء النماذج

فيما يلي رسم بياني يوضح أداء النماذج CNN و SVM(CNN) و SVM(HOG) من خلال المقياسات المختلفة (الضبط والاستدعاء و F1 درجة) لكل فئة من الحيوانات (الذئاب والثعلب والكلاب البرية) يوفر الرسم البياني مقارنة واضحة لأداء كل نموذج لفئة محددة



الخلاصة

في المقابل أظهرت الـ SVM (المتجهات الداعمة) أداءً متفاوتاً اعتماداً على نوع الميزات المستخدمة، فعند استخدام ميزات HOG التقليدية كان أداء SVM الأضعف بدقة 82.3% مما يؤكد محدودية الميزات اليدوية في التعامل مع تعقيد تصنيف الصور الحيوانية، ومع ذلك عندما تزويه SVM بميزات مستخلصة من نموذج CNN المدرب تحسن أداؤها بشكل كبير ليصل إلى دقة 94.2%， مما يشير إلى أن قوة CNN لا تكمن فقط في قدرتها على التصنيف النهائي، بل أيضاً فعاليتها كمستخلص للميزات الغنية والقوية التي يمكن أن تعزز أداء الخوارزميات التقليدية.

تؤكد هذه الدراسة أن الشبكات العصبية التلايفية هي النهج الأكثر فعالية لتصنيف الصور المعقدة مثل صور الحيوانات، خاصة عندما تكون هناك فروقات بصرية دقيقة بين الفئات، كما تسلط على إمكانية استخدام النهج الهجين، حيث يمكن الاستفادة من قدرة CNN على استخلاص الميزات لتخفيذ خوارزميات تصنيف أخرى مثل SVM مما قد يكون مفيداً في سيناريوهات معينة (مثل مجموعة البيانات الصغيرة جداً حيث قد يكون تدريب CNN من الصعب تحدياً).

Compliance with ethical standards

Disclosure of conflict of interest

The authors declare that they have no conflict of interest.

المراجع

- [1] Mohammad Hairil Anuar, Habibah Ismail, and Ismail Ahmedy. 2025. Animal Species Classification using Convolutional Neural Network. Management (ICSIM 2025), January 10–12, 2025, Singapore, Singapore. ACM, New York, NY, USA, 7 pages. <https://doi.org/10.1145/3725899.3725936>
- [2] Kimly Y, Malis Lany, Vitou Soy, Sokchea Kor. 2023. Animal Classification using Convolutional Neural Network . Conference: The 2nd Student Conference on Digital Technology 2023
- [3] P Kanaga Priya; T Vaishnavi; N Selvakumar; G Ramesh Kalyan; A Reethika.. 2023. An Enhanced Animal Species Classification and Prediction Engine using CNN . Conference: 2023 2nd International Conference on Edge Computing and Applications (ICECAA)
- [4] Manohar, N., Kumar, Y.H.S., Rani, R., Kumar, G.H. (2019). Convolutional Neural Network with SVM for Classification of Animal Images. Emerging Research in Electronics, Computer Science and Technology. Lecture Notes in Electrical Engineering, vol 545. Springer, Singapore. https://doi.org/10.1007/978-981-13-5802-9_48
- [5] Hurtado, S., Luisa, M., Real, R., & F., J. (2025). Addressing significant challenges for animal detection in camera trap images: a novel deep learning-based approach. *Scientific Reports*, 15(1), 1–18. <https://doi.org/10.1038/s41598-025-90249-z>
- [6] Norouzzadeh, M. S., Nguyen, A., Kosmala, M., Swanson, A., Palmer, M. S., Packer, C., & Clune, J. (2018). Automatically identifying, counting, and describing wild animals in camera-trap images with deep learning. *Proceedings of the National Academy of Sciences*, 115(25), E5716–E5725. <https://doi.org/10.1073/pnas.1719367115>
- [7] Cui, Y., Tang, B., Wu, G., Li, L., Zhang, X., Du, Z., & Zhao, W. (2024). Classification of Dog Breeds Using Convolutional Neural Network Models and Support Vector Machine. *Bioengineering*, 11(11), 1157. <https://doi.org/10.3390/bioengineering11111157>
- [8] Battu, T., & Reddy Lakshmi, D. S. (2023). Animal image identification and classification using deep neural networks techniques. *Measurement: Sensors*, 25, 100611. <https://doi.org/10.1016/j.measen.2022.100611>

[9] Bingquan Cai, Chuwei Chen, Jiawei Zhao, Xiaowei Ge, Yuxiang Wan. (2022). Improving classification accuracy with better feature extraction by CNN-SVM. GitHub. <https://github.com/sunshineatnoon/Two-Layer-CNN-on-MNIST.git>

[10] Khairandish, M., Sharma, M., Jain, V., Chatterjee, J., & Jhanjhi, N. (2022). A Hybrid CNN-SVM Threshold Segmentation Approach for Tumor Detection and Classification of MRI Brain Images. *IRBM*, 43(4), 290-299. <https://doi.org/10.1016/j.irbm.2021.06.003>

[11] G. Silvano. "Animals-10". Kaggle, 2020. [Online]. Available: <https://www.kaggle.com/datasets/alessiocorrad099/animals10>

Disclaimer/Publisher's Note: The statements, opinions, and data contained in all publications are solely those of the individual author(s) and contributor(s) and not of **AJAPAS** and/or the editor(s). **AJAPAS** and/or the editor(s) disclaim responsibility for any injury to people or property resulting from any ideas, methods, instructions, or products referred to in the content.