

وحي الأندلس

مجلة سنوية علمية محكمة جامعة، تعنى بالتراث الليبي الأندلسي
تصدر عن الجمعية الليبية الأندلسية

العدد الأول
جمادى الأولى 1443هـ = ديسمبر 2021م



نوفيتا أبي البقاء الرندي ومحمد الفطيسي.



قراءة في شعر الغربة والحنين لابن سعيد
الأندلسي مع إضاءة حول بانيته في مصر،



علماء الأندلس المهاجرون إلى شمال أفريقيا
واسهامهم في حركة الترجمة.



خوارزمية ذكية للتعرف على معالم أندلسية
باستخدام نموذج التعلم العميق.



السعاية التي هدمت عرش الإسلام ومجده
في الأندلس.



الجمعية الليبية الأندلسية



مجلة وحي الأندلس – العدد الأول

مجلة سنوية علمية محكمة، جامعة، تعنى بالتراث الليبي الأندلسي
تصدر عن الجمعية الليبية الأندلسية

①

السنة الأولى - العدد الأول
جمادى الأولى 1443هـ = ديسمبر 2021م

رقم الإيداع القانوني: 2021/536 دار الكتب الوطنية

ما ورد في المجلة يعبر عن آراء الباحثين ولا يعبر بالضرورة عن رأي المجلة

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ



المشرف العام:

أ. د. عبد الله محمد الزيات

رئيس الجمعية الليبية الأندلسية

هيئة التحرير:

د. رضا محمد جبران

أ. د. عبد الستار العريفي بشية

أ. د. نوري أحمد عبيريد

د. خديجة أحمد البدوي

د. علاء الدين محمد الأسطى

د. طارق ساسي الشيباني

رئيس هيئة التحرير

مدير التحرير

عضوًا

عضوًا

عضوًا

عضوًا

الهيئة الاستشارية:

أ. د. عبد الحميد عبد الله الهرامة

أ. د. محمد فرج دغيم

أ. د. رمضان سعد القحاطي

أ. د. عبد الواحد محمد شعيب

مجمع اللغة العربية - ليبيا

جامعة بنغازي

جامعة طرابلس - ليبيا

جامعة طرابلس - ليبيا

المراجعة اللغوية:

أ. د. خليفة محمد بديري

د. نجاة عمار الهالي

كلية الدعوة الإسلامية - ليبيا

جامعة طرابلس - ليبيا

التنسيق الفني والإخراج:

د. طارق ساسي الشيباني

جامعة طرابلس - ليبيا

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

التعريف بالمجلة

مجلة علمية سنوية محكمة، جامعة، تُعنى بالتراث الليبي الأندلسي.

رؤية المجلة:

نشر الدراسات المتنوعة في التراث الأندلسي بكافة أشكاله لغة وتاريخاً وحضارة.

رسالة المجلة:

- التعريف بالحضارة الأندلسية وأثرها في الاهتمام بالمجالات البحثية ذات الصلة بالتراث الأندلسي الليبي.

أهداف المجلة:

- نشر الوعي في ما يتعلق بالتراث الأندلسي وأثره في التراث الليبي.
- الاهتمام بالمجالات البحثية التراثية منها والمعاصرة، والعمل على التعريف بها، ودعوة ذوي الاختصاص لخدمتها دراسةً وتحقيقاً وطباعةً ونشرًا.
- التعريف بعلماء البلاد الأندلسية وصلاتهم بالبلاد الليبية ونشر تراثهم والوقوف على جهودهم وآثارهم العلمية والعملية.
- التعريف بجهود الليبيين المعاصرين الذين خدموا التراث الأندلسي تأليفاً وتحقيقاً.
- إبراز جانب التأثير والتأثير في الحياة الاجتماعية الأندلسية الليبية.
- إظهار جانب التأثير والتأثير في علم العمارة (فن الزخرفة، تخطيط المدن....).
- التعريف بمختلف مظاهر الحضارة الأندلسية (تاريخ، عمارة، اقتصاد، مجتمع، إصدارات، مخطوطات، ندوات، موسيقى).
- دعم الحركة العلمية بالبلاد الليبية، والمشاركة بالكلمة والقلم في القضايا التراثية الأندلسية الليبية.
- التواصل مع شرائح المجتمع المختلفة من خلال تنوع موضوعات المجلة وحسن اختيارها.

محاور الكتابة في المجلة: (ذات الصلة بالموضوعات الأندلسية الليبية)

1- التاريخ والحضارة الأندلسية.

2- الأدب الأندلسي وأدب الرحلات.

3- الأبحاث الفقهية الأندلسية.

4- التعريف بالمؤلفات الأندلسية.

5- التعريف بالأعلام الأندلسيين.

6- التعريف بالعارة والفنون.

قواعد النشر في المجلة:

1. أن يكون البحث المقدم مهتماً بالجانب الليبي الأندلسي وألا يخرج عن هذا السياق.
2. أن يكون البحث مستوفياً شروط النشر وفق منهج الكتابة العلمية للأبحاث.
3. أن يكون البحث مرقوناً على جهاز حاسوب ببرنامج وورد (word) بخطوط (المتن) وحجم الخط 16 للمتن و 12 للمهامش.
4. أن تكون هوامش البحث في أسفل الصفحة.
5. ينبغي عدم ذكر اسم الباحث في متن البحث أو هوامشه، أو قائمة هوامشه صراحة أو بأي إشارة تكشف عن هويته، وتستخدم بدلاً من ذلك كلمة الباحث.
6. يتحمل الباحث مسؤولية مراجعة بحثه والتزام التعديلات المقدمة من طرف المحكم، وفي حالة عدم التزامه بالملاحظات فإن البحث لا يتم نشره.
7. ألا يقل البحث عن عشر صفحات وألا يزيد على ثلاثين صفحة، وإذا تجاوز البحث ثلاثين صفحة ورأت المجلة أحقيته بالطبع فلها نشره في عدد واحد، أو تقسيمه على أعداد من المجلة.
8. إذا كان البحث يتعلق بتحقيق نص مخطوط، فعلى الباحث تزويد المجلة بنسخة من هذا المخطوط.
9. ألا تكون البحوث المقدمة مستقلة من أطروحة جامعية، وغير منشورة من قبل.
10. في حالة قبول البحث بعد استكمال التقييم والتصحيحات يقدم الباحث نسخة مصححة من البحث بصيغته النهائية، مع دفع أجور النشر.
11. البحوث التي تصل إلى المجلة لا ترد لأصحابها نشرت أو لم تنشر.
12. إرفاق السيرة الذاتية والعلمية للباحث الذي يتقدم لأول مرة بالنشر في المجلة.
13. ترسل البحوث إلى العنوان البريدي الخاص برئيس التحرير ونائبه.

المراحل التي يمر بها البحث بعد وصوله إلى المجلة:

1. تكون عملية التقييم سرية؛ وذلك لرفع الحرج عن الباحث والمحكم؛ ليكون الرأي أكثر موضوعية.
2. يحال البحث لمحكم موضوعي، وتكون توصية المحكم على النحو التالي:

- صالح للنشر دون ملاحظات.
- صالح للنشر بملاحظات.
- غير صالح للنشر، مع ذكر الأسباب.

تعود الملاحظات إلى أصحاب البحوث في الحالتين الأخيرتين لتعديل البحث على وفقها، وللباحث رفض الملاحظات برّدٍ علمي آخر يدحض فيه ملاحظات المحكم ويبين أسباب الرفض. وفي هذه الحالة يحال البحث إلى محكم من درجة علمية أعلى تكون له مهمة ترشيح البحث للنشر أو عدمه، على أن يكون لهيئة التحرير رأياً في تقييم البحث بحسب المعايير التي وضعتها لقبول البحوث المنشورة.

الأسس العامة للتحكم العلمي للأبحاث:

- (1) تقييم المادة العلمية وفحصها.
- (2) تقدم الملاحظات المنهجية والموضوعية في نموذج معدّ.
- (3) يُعطي المحكم البحث درجةً من مئة في حال صلاحيته للنشر، بملاحظات أو بدون ملاحظات بناءً على ما توفر في البحث من معايير النشر وقواعده بالمجلة وفق الأسس الآتية:
 - أ- الإبداع والتجديد: 30%.
 - ب - المنهجية والأسلوب العلمي: 30%.
 - ج - المصادر وقيمتها العلمية: 20%.
 - د - الجهد المبذول: 20%.
- (4) تأمل المجلة وترجو من المحكمين الالتزام بالسرية والموضوعية ولين القول في التحكم.

للتواصل:

- بريد المجلة: wahiandalusw@gmail.com

- هاتف: (00218)0914900032

- عناوين التواصل الاجتماعي:

- (الجمعية الليبية الأندلسية) (فيس بوك).

فهرس المحتويات

مجلة وحي الأندلس – العدد الأول.....	1
فهرس المحتويات.....	9
طالعة العدد الأول لمجلة (وحي الأندلس).....	11
أولاً: البحوث المحكّمة.....	13
نونيتا أبي البقاء الرندي ومحمد الفطيسي دراسة موازنة.....	15
أ. د. عبد الله الزيات	
قراءة في شعر الغربية والحنين لابن سعيد الأندلسي مع إضاءة حول بآئته في مصر،	
وقافيته في ليبيا دراسة تحليلية.....	39
د. محمد عثمان الكيلاني الزيداني	
موسوعيّة المقرري من خلال مقدّمة كتابه (التّفح).....	55
أ. د. عبد الواحد عبد السلام شعيب	
السعاية التي هدمت عرش الإسلام ومجده في الأندلس دوافعها وآثارها في السياسة	
والأدب.....	99
د. رضا محمد جبران	
علماء الأندلس المهاجرون إلى شمال أفريقيا وإسهامهم في حركة الترجمة.....	131
د. نزيهة أبو القاسم الرجبي	
نسب أندلسي ونسبةٌ محيرة (نص جديد وتسأؤلات).....	157
أ. د. عبد الحميد عبد الله الهرامة	
رسالة في طرق حديث النبي ﷺ (ليس من أميرٍ أمصيامٍ في أمسَفَرٍ).....	173
د. طارق ساسي الشيباني	
القرطبي ومنهجه من خلال (الجامع لأحكام القرآن المتضمن من السنة وآي القرآن)	
.....	211
د. محمد عبد الله محمد سلامة	

- اللغات السائدة في الأندلس من الفتح وحتى عصر ملوك الطوائف (92-484هـ/711-1091م).....257
- د. سامية سالم عياد
- تجليات التناسخ في شعر ابن الجَنّان الأندلسي قراءة نقدية.....273
- د. خديجة البدوي
- الخرافات في الأندلس (484-897هـ/1091-1492م).....329
- أ.م. د. عدنان خلف سرهيد، والباحثة: نور مكي جاسم
- خوارزمية ذكية للتعرف على معالم أندلسية باستخدام نموذج التعلم العميق.....377
- د. رضوان علي حسين، د. عبد الحميد الفلاح الواعر، م. عائشة محمود فياض
- ثانياً: المقالات.....403
- حكاياتي مع الإسكوريال.....405
- د. عبد العاطي الورفلي
- لمحات أندلسية في معمار مدينة طرابلس (الأبواب نموذجاً).....427
- المهندس: حسام عبدالسلام باش إمام
- حول تصحيح نسبة كتاب أندلسي.....449
- أ. د خليفة محمد بديري

أولاً: البحوث المحكّمة

خوارزمية ذكية للتعرف على معالم أندلسية باستخدام نموذج التعلم العميق

د. رضوان علي حسين، د. عبد الحميد الفلاح الواعر، م. عائشة محمود فياض

قسم هندسة البرمجيات، كلية تقنية المعلومات – جامعة طرابلس

الملخص⁽¹⁾:

تقنيات الذكاء الاصطناعي تُسخر الآن لخدمة كافة مجالات الحياة، اقتصادية كانت أو طبية، أو تعليمية، أو عسكرية أو سياحية، وهي تقنيات تتميز باستمرارية تطورها وتستوحي بناء نماذج خوارزميات ذكائها من خلال الطبيعة التي نحيا فيها، في أسلوب التعامل مع العضلات وحلها، وهي متعددة المنهجيات في الذكاء الاصطناعي، وأشهرها في هذه الحقبة، منهجية تعلم الآلة (Machine Learning) التي يتفرع منها أسلوب حديث يعرف بالتعليم العميق (Deep Learning)، وهو الذي بناؤه مستوحى من مفهوم شبكة الخلايا العصبية الدماغية (Artificial Neural Networks).

إن هذا المجال المتطور يبشر بحل مشاكل كانت ضرباً من الخيال يوماً ما، وانتشرت تطبيقاته المبتكرة الجديدة بشكل كبير جداً مؤخراً، وفي هذه الورقة سيتم بناء نموذج تعلم عميق يعمل على التعرف على بعض المعالم الأندلسية الشهيرة، والنموذج سيكون بمثابة العقل المفكر في تطبيق الهاتف المحمول الذي يلتقط صورة المعلم الأندلسي، فيحلل جزئيات الصورة محاولاً التعرف عليها وذكر اسم ذلك المعلم، والنظام المتطور لهذا التطبيق الذكي سيستخدم تقنية خدمات الويب (Web Services) للتواصل مع قاعدة بيانات النظام، والرد بالمعلومات التي يحتاجها المستخدم، كما يعتبر هذا المجال من بصريات الحاسوب (Computer

- (1) الخوارزمية: مفهوم الخوارزمية مُستوحى من علوم الرياضيات، ففي برمجيات الحاسبات: يُعبر عن سلسلة محدودة من الأوامر التي ينفذها الحاسوب لتحقيق غرض معين. أوامر الخوارزمية لها بداية ونهاية، وفيها تكرار وتفرعات، وهي تعتمد على العمليات الحسابية والمنطقية لمعالجة البيانات وإجراء التفكير الآلي في مقدار محدد من الزمن، وباستخدام لغة برمجة معينة.

(Vision) التي تعنى بقدرة الحواسيب على تمييز الصور والأشكال.

كلمات مفتاحية: تعلم الآلة، تعلم عميق، بصريات الحاسوب، معالم أندلسية.

1. المقدمة:

إن قدرة الأجهزة الحاسوبية، المختلفة الحجم والقدرة، والثابتة والمتنقلة، في التعرف على الأشكال والصور وتمييزها، هي خاصية تميز مدى تطور تقنيات الحواسيب⁽¹⁾، ولكن دعم هذه القدرة البصرية بالذكاء الاصطناعي هو ما يفتح الآفاق أمام مجال فسيح من التطبيقات الحديثة التي تخدم الإنسان حيثما كان. وفي عصر ازدهار البيانات، وعلى وجه الخصوص البيانات البصرية، التي تشهد نمواً هائلاً مع تنامي مقدرة تحليل هذه البيانات باستخدام الأساليب الحديثة المادية والبرمجية، يمنحنا تقدم التكنولوجيا وتوافر مثل هذا الكم الهائل من البيانات فرصاً لاستخدامها بطرق يمكن أن تغير حياتنا وتسهم في تيسيرها⁽²⁾⁽³⁾. ومن أهم تقنيات الاستفادة من البيانات الهائلة هو مجال تعلم الآلة. فهو يشكل الآلية الأساسية لاستخراج المعلومات من البيانات ثم استخلاص الحكمة وراء تلك المعلومات، فإن تطبيقات هذه التقنيات عندما تتكامل مع بعضها تصبح غير محدودة، وآفاقها تزداد اتساعاً⁽⁴⁾⁽⁵⁾.

-
- (1) J. Magic and M. Magic, Image Classification: Step-By-step Classifying Images with Python and Techniques of Computer Vision and Machine Learning (2; Python. Amazon Digital Services LLC - Kdp Print Us, 2019.
- C. Termritthikun, S. Kanprachar, and P. Muneesawang, "NU-LiteNet : (2) Mobile Landmark Recognition using Convolutional Neural Networks," no. 1, pp. 3–8, 2012.
- K. Yap, Z. Li, D. Zhang, and Z. Ng, "Efficient mobile landmark (3) recognition based on saliency-aware scalable vocabulary tree," 2012, p. 1001
- K. Bulkunde, A. Chakraborty, S. Kazi, and K. Dhumal, "Landmark (4) Recognition using Image processing with MQTT protocol," pp. 2405–2407, 2017.
- T. Chen, K. Yap, and D. Zhang, "Discriminative Soft Bag-of-Visual (5)

وتقليدياً كان التعلم الآلي يقتصر على معالجة مجموعات البيانات الصغيرة فقط، وهذا يعني أنه كان من العسير تطبيق أفكار البصريّات من مجال معالجة الصور الرقمية لحل مشاكل العالم الحقيقي، ولم يكن ممكناً أساساً لمحدودية القدرة الحاسوبية مقارنة بكم المعلومات التي تحتويها البيانات التصويرية، إضافةً إلى ذلك بيانات الصور الرقمية التي لم تكن متاحة بدقة كافية لاستخلاص معلوماتها، فتلكم الدقة ضرورية لتدريب الآلات الحاسوبية، ولم تتوفر قوة حاسوبية كافية لتشغيل خوارزميات التعلم⁽¹⁾⁽²⁾. أما في السنوات الأخيرة نمت قدرة الحوسبة بشكل كبير، وأصبحت كميات هائلة من البيانات متاحة، وتم اكتشاف خوارزميات جديدة لمعالجة البيانات. كل هذه التطورات مهدت الطريق لنشر البرامج والأجهزة ذات التعقيد الذي يصعب جداً تخيله.

نتيجة للتقدم في التعلم الآلي، والتعلم العميق، شهد مجال رؤية الكمبيوتر تقدماً كبيراً مؤخراً، أدى إلى تطوير خوارزميات جديدة، منها التعرف على بعض المهام الواقعية التي كان البشر يقومون بها يدوياً في السابق، ورؤية الكمبيوتر لديها إمكانيات هائلة ليتم تطبيقها في سياقات مختلفة، حيث يمكن للنظام البصري البشري فقط القيام بهذه المهام في الماضي، كذلك التعرف على الصور مثلاً بالنسبة للإنسان، وتبدو المهمة بسيطة؛ لأن النظام البصري البشري قد تطور لملايين السنين، وتعود على هذا النوع من المهام الأساسية، وأيضاً تطور فهم الإنسان لآليات البصر وأساليب تعامل العقل البشري مع بياناته مما أسهم في فهم عمل النظام البصري البشري جيداً، وهو الأمر الذي أسهم في بناء خوارزميات حاسوبية لمعالجة الصور، وتحديد تطور أدوات التقاط الصور والرفع من كفاءتها.

Phrase for Mobile Landmark Recognition.

J. Schmidhuber, "Deep Learning in neural networks: An overview," (1)

Neural Networks, vol. 61, pp. 85–117, 2015.

A. Krizhevsky and G. E. Hinton, "ImageNet Classification with Deep (2)

Convolutional Neural Networks," pp. 1–9.

فالصورة الرقمية التي تخزن في الحواسيب هي مجرد مجموعة من النقاط المصفوفة (pixels) غير المترابطة من حيث المعنى الذي تحمله أي نقطة، وإن كانت النقاط متجاورة في المكان، ومن وجهة نظر الكمبيوتر كل نقطة مستقلة بذاتها، وكان الإنسان وحده القادر على استنباط الترابط بين نقاط الصورة، وأصبح من الصعب جعل الآلات «تفهم» التغييرات التي تحدث فيما بين نقاط الصور لتشكيل معالم الأشياء المصورة، ما يؤدي إلى تغير فهم الكائنات المجسدة في الصور، وأي تغير بين نقاط الصور تعتبر تغييرات لها تأثير على ما ترويه بيانات الصورة.

فإدراك الآلات لهذا التباين بين مكونات الصور يتطلب براعة هائلة، وقوة حساب ضخمة عالية، لتمكن الآلة من أداء هذه المهمة بنجاح، ولم يتحقق ذلك إلا حين تمكنت الحواسيب من هذا النوع من الإدراك، عندها تفوقت على البشرية في استيعاب مكونات الصور، وتنافسوا في التمييز بين تفاصيلها التي قد لا تدركها العين البشرية، ولم يتمرس العقل البشري على إدراك تفاصيلها.

2. الأعمال المناظرة:

في البحث⁽¹⁾ تم استخدام أسلوب يعرف بآلة دعم المتجه (Support Vector Machine)⁽²⁾ كخوارزمية تستعمل للتعرف على بعض المعالم الأندلسية. هذا الأسلوب يتعرف على الصور بطريقة توافق المحتوى حيث يتم استخلاص المعلومات من الصور بناءً على حقيبة من نماذج الكلمات وذلك لتقليل التكلفة الحاسوبية. بالرغم من ذلك، نموذج حقيبة الكلمات لديها عيبان كبيران، أولهما:

(1) K. Banlupholsakul, J. Ieamsaard, and P. Muneesawang, "Re-ranking approach to mobile landmark recognition," in 2014 International Computer

Science and Engineering Conference (ICSEC), 2014, pp. 251–254.

(2) K.-H. Yap, Z. Li, D.-J. Zhang, and Z.-K. Ng, "Efficient Mobile Landmark Recognition Based on Saliency-aware Scalable Vocabulary Tree," in Proceedings of the 20th ACM International Conference on Multimedia, 2012, pp. 1001–1004.

الحقيبة التي تتجاهل التوزيع المكاني للمعلومات في صورة المعالم. وثانيهما: أن هذا الأسلوب لا يستطيع التمييز بين الواجهات المتعددة التي قد تحتويها الصورة.

والعمل المنجز في المرجع⁽¹⁾، لكي يتم التعرف على المعالم المختلفة ويستخلص معلومات من الصور، فالصورة تصنف إلى معالم شاملة، ومعالم جزئية، متعددة، محلية، وهذا للتفرقة بين مكونات الصورة، من حيث اللون، والاتجاه النسيجي لنقاط الصورة.

إن خوارزمية ما يعرف بثبات المقياس لتحويل المعالم (Scale-Invariant Feature Transform) هي طريقة لاستخلاص المعالم من الصور، وهي التي حسنت دقة استخلاص المعالم كما حسنت في فترة الحوسبة. ولقد استخدم مبدأ آلة دعم المتجه (SVM) في⁽²⁾، لأجل التدريب على بيانات الصور، ولمعرفة حزمة البيانات التدريبية لا بد أن تحتوي على بيانات متجهة مضافة لبيانات الصورة الأصلية؛ لكي تدعم الآلية لتمييز ملاحظها، ولاستخلاص معالم الصورة يجب بناء مخطط هيستغرام توزيع ألوان الصورة⁽³⁾. وهذا عيبه أنه لا يتكيف مع ثبات توجه الصور. في هذه الورقة البحثية، سيتم تطوير نظام لتمييز بعض المعالم الأندلسية باستخدام منهجية التعلم العميق وهذا الأسلوب مبني على تقنية الشبكات العصبية الدماغية الالتفافية (Convolutional Neural Networks) لكي يتم

-
- (1) D. G. Lowe, "Object recognition from local scale-invariant features," in Proceedings of the Seventh IEEE International Conference on Computer Vision, 1999, vol. 2, pp. 1150–1157 vol.2.
 - (2) T. Chen, K. Yap, and D. Zhang, "Discriminative Soft Bag-of-Visual Phrase for Mobile Landmark Recognition.
 - (3) N. Dalal and B. Triggs, "Histograms of Oriented Gradients for Human Detection," in Proceedings of the 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05) - Volume 1 - Volume 01, 2005, pp. 886–893.
-

استخلاص ملامح الصور وبالتالي التعرف على المعالم التي تجسدها الصورة⁽¹⁾. باستخدام هذه التقنية متمثلة في شبكة رزنت (ResNet)⁽²⁾، سيكون ممكناً الوصول إلى أفضل اختيارات لتصنيف المعالم بدقة تصل إلى 96.53% من خلال مختلف فئات الصور التي سيتتدرب عليها النظام ويتعلم ملامحها فيتعرف عليها كلما التقط صورة مقارنة لتلك العينة⁽³⁾.

3. تقنية الشبكات العصبية الدماغية الالتفافية للتعلم العميق:

مفهوم الشبكة العصبية الدماغية هو مستوى من تركيبة شبكة الخلايا العصبية بمخ الإنسان. من خلال تواصل تلكم الخلايا العصبية مع بعضها واستمرار تقوي ترابطها مع دوام التواصل بينها لاستيعاب المعلومات وتحليلها، بُني نظام حاسوبي يتكون من مجموعة من العقد التي تسمى الخلايا العصبية (Neurons) يتم تنظيمها في طبقات. تشكل تلك الوحدات العصبية المتصلة شبكة واسعة ذات طبقات عديدة يعطيها اسمها الذي يصفها بالعميقة. وكل اتصال بين الخلايا العصبية ينقل إشارة من خلية عصبية إلى أخرى.


تقوم الخلايا العصبية المستقبلية بمعالجة الإشارة وترسل إشارة إلى الخلايا العصبية المتصلة بها داخل شبكة الخلايا والروابط بينها تتجسد في مصفوفات رقمية تحوي أرقاماً تمثل قوة الترابط بين الخلايا العصبية المتمثلة في صيغتها الرياضية غير الخطية. فكلما تعلمت الشبكة معلومات جديدة ضَبَطَتْ أوزان

(1) M. K. Benkaddour and A. Bounoua, "Feature extraction and classification using deep convolutional neural networks, PCA and SVC for face recognition," Trait. du Signal, vol. 34, no. 1–2, pp. 77–91, 2017.

(2) G. A. Hembury, V. V. Borovkov, J. M. Lintuluoto, and Y. Inoue, "Deep Residual Learning for Image Recognition Kaiming," Cvpr, vol. 32, no. 5, pp. 428–429, 2003.

(3) J. Deng, W. Dong, R. Socher, L. Li, K. Li, and L. Fei-fei, "ImageNet : A Large-Scale Hierarchical Image Database," pp. 2–9.

الروابط بين خلاياها العصبية. الشكل (1) يوضح مخطط لشبكة الخلايا العصبية.



شكل (1): مخطط لشبكة الخلايا العصبية الذكية

مثل هذه الأنظمة تتعلم لأداء المهام من خلال النظر في الأمثلة المقدمة لها، وبشكل عام، دون أن تكون مبرمجة مسبقاً مع أي قواعد خاصة بالمهمة الموكلة إليها، فإن المهمة الرئيسية لها أنها تستقبل مجموعة من المدخلات، ثم تؤدي الحسابات المعقدة، ثم تنتج المخرجات لحل مشكلة، وأما طبقة المدخلات فتأتيها البيانات الأولية لتدخل إلى النظام، مع مزيد من المعالجة، بواسطة طبقات لاحقة متعددة، من الخلايا العصبية الاصطناعية، وأما الطبقات الوسطية المخفية المتعددة، فتقع بين طبقة المدخلات، وطبقة المخرجات، حيث تأخذ خلاياها العصبية الاصطناعية مجموعة ما، وتعمل على معالجتها في مستوى المدخلات، وتنتج مخرجات من معالجة البيانات، في دوال غير خطية تفعيلية، وأما طبقة خلايا المخرجات فتشكل الطبقة الأخيرة من الخلايا العصبية الاصطناعية التي تنتج

مخرجات نموذج النظام الذكي العميق⁽¹⁾⁽²⁾⁽³⁾⁽⁴⁾.

تتميز هذه الشبكات عن الشبكات العصبية ذات الطبقة المخفية المفردة من حيث عمقها، وهنا يكمن سر التعليم العميق المتمثل في تعدد الطبقات، وكثرة الخلايا فيها، إلى عدة طبقات تمر خلالها البيانات في عملية متعددة الخطوات، فهي قادرة على حل مهام التصنيف، والتعرف على الأنماط الأكثر تعقيداً، بفضل الطبقات المخفية المتعددة، وكانت الإصدارات السابقة من الشبكات العصبية مؤلفة من طبقة إدخال واحدة، وطبقة إخراج واحدة، مع طبقة واحدة مخفية بينهما.

4. نظرية تعلم الشبكة العصبية:

في شبكات التعلم العميق يتم تدريب كل طبقة من العقد، على مجموعة مميزة من الملامح، استناداً إلى مخرجات الطبقة السابقة، وكلما تقدمت في الشبكة العصبية ازدادت تعقيدات الملامح التي يمكن للعقد التعرف عليها؛ وذلك نظراً لأنها تقوم بتجميع وإعادة تجميع ميزات الملامح من الطبقات السابقة، ومن يتدرب على نموذج لشبكة عصبية عميقة، فهو يحاول تحسين أوزان النماذج المتجسدة في الروابط بين عقد الخلايا العصبية، والهدف من التدريب هو العثور على الأوزان التي تحدد بدقة بيانات المدخلات، إلى فئة الإخراج الصحيحة، وهذا

(1) A. Krizhevsky and G. E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," pp. 1-9.

(2) C. Szegedy et al., "Going Deeper with Convolutions," 2014.

(3) K. Simonyan and A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition," pp. 1-14, 2014.

(4) G. A. Hembury, V. V. Borovkov, J. M. Lintuluoto, and Y. Inoue, "Deep Residual Learning for Image Recognition Kaiming," Cvpr, vol. 32, no. 5, pp. 428-429, 2003.

التعيين هو ما يجب أن تتعلمه الشبكة ويمثل المعرفة التي تكتسبها⁽¹⁾.

وبداية التعلم تبدأ بما يعرف بالانتشار الأمامي وهو عملية تغذية الشبكة العصبية بمجموعة من المدخلات، مع أوزان القوة بين الروابط البينية للخلايا، ثم تغذيتها عبر دوال غير خطية، تمثل عقدة الخلية العصبية، لأن الشبكة العصبية تولد جاهلة في البداية، أي لا تعرف ما هي الأوزان التي ستقوم بترجمة المدخلات لإجراء التنبؤات الصحيحة، فيجب أن تبدأ بتخمين قيم عشوائية للقوة الرابطة بين أي خليتين، ومن ثم محاولة إجراء تنبؤات أفضل مع الوقت، لأنها تتعلم باستمرار؛ لتحسين قوة وزن روابط الخلايا من خلال أخطائها السابقة، واختبار الفرضيات والمحاولة مرة أخرى، وهنا يكمن مبدأ التعلم والتحسين المستمر⁽²⁾.

يقاس فاقد المعرفة للشبكة من خلال التنبؤات غير الصحيحة التي تحاولها الشبكة، أي أن الفاقد هو رقم يشير إلى مدى سوء تنبؤ النموذج، وهذا الفاقد هو الذي يقرر به زيادة، أو نقصان قوة وزن روابط الخلايا، فإذا كان تنبؤ النموذج مثاليًا، فيكون الفاقد صفرًا، وخلاف ذلك إن كان الفاقد أكبر أو أصغر من الإجابة الصحيحة، والهدف من تدريب نموذج هو العثور على مجموعة من الأوزان التي تصف قوة ترابط الخلايا التي تحسب من دقة تعلم الشبكة، ويحتاج النظام لتقليل الفاقد في التعلم المحسوب في شبكة عصبية، يتم ذلك باستخدام مفهوم الانتشار الخلفي، الذي يعمل عن طريق تحديد الفاقد في المخرجات ثم نشرها مرة أخرى إلى الخلف، نحو طبقة سابقة في الشبكة، حيث يتم استخدامه لتعديل الأوزان بطريقة تقلل من الخطأ في الناتج.

وشبكات التعلم العميق مفيدة للغاية للتعرف على الأشياء في الصور،

(1) J. Schmidhuber, "Deep Learning in neural networks: An overview,"

Neural Networks, vol. 61, pp. 85–117, 2015.

(2) K. Simonyan and A. Zisserman, "Very Deep Convolutional Networks for

Large-Scale Image Recognition," pp. 1–14, 2014.


والوجوه، والكائنات، وما إلى ذلك، فبالنظر إلى مجموعة بيانات الصور أحادية اللون الرمادية ذات الحجم القياسي 32×32 نقطة، فإن الشبكة العصبية التقليدية تتطلب 1024 مدخلاً في طبقة المدخلات، وهذا يفقد الميزة المكانية للملامح، أما منهجية الشبكة الالتفافية (CNN) فهي استخراج ميزات ملامح الصورة كمدخلات للشبكة العصبية، وليس مجرد نقاط منعزلة من الصورة.

إن هذا الأسلوب يحافظ على العلاقة المكانية بين نقاط الصورة، مما يفيد في تعلم ميزات الصورة وملاحظتها، ويتم ذلك بتجزئة الصورة المصدرة إلى مربعات صغيرة، تؤلف مصفيات الطبقات الالتفافية وهي مدخلات الخلايا العصبية للطبقة الأولى، وحجم المدخلات هو مصفٍ بمربع ثابت، إذا كانت الطبقة عبارة عن طبقة الإدخال، فسيكون الإدخال هو قيم من نقاط الصورة، وإذا كان القيم داخلة للطبقات العميقة في بنية الشبكة، فإن الطبقة ستأخذ المدخلات من الطبقة السابقة لها.

ومن أهم الميزات التي يمكن للمربعات المصفيات اكتشافها في الصورة، هي تلكم الحواف، أو قد تكتشف الزوايا، أو قد يكتشف البعض من الدوائر، أو مربعات، وكلما زاد عمق الشبكة أصبحت المصفيات أكثر تطوراً، وبالتالي تزداد تعلماً في الطبقات التالية، فيتطور التعرف بدلاً من الحواف والأشكال البسيطة في الطبقات اللاحقة، فقد تتمكن من اكتشاف كائنات محددة، مثل العينين، والأذنين، والشعر وتفاصيل الوجه، في الطبقات الأعمق، وتكون قادرة على اكتشاف كائنات أكثر تطوراً.

5. المعالم الأندلسية بيانات تدريبية:

فئة بيانات المعالم الأندلسية التي تستخدم لتعليم هذا النظام، تتألف من مئات الصور التي تجسد مناطق، ومشاهد مختلفة، للقصور، والمباني، والحدائق، والكثير من الآثار الأندلسية، وهذه المعالم يتم تجميعها من خلال محركات البحث عبر الإنترنت، والشكل (2) يبين عينة من صور المعالم الأندلسية.



شكل (2): عينات من المعالم الأندلسية يتعلم النظام الذكي للتعرف عليها. من أعلى اليمين: نافورة السباع، ومحراب إشبيلية، وقصر الحمراء، وعمود مكتوب فيه لا غالب إلا الله، وباب ونقوش إن تجميع بعض صور المعالم الأندلسية وحفظها، على أنها بيانات يتعلمها النظام، فيمر بمراحل مختلفة، حيث تجمع الصور بطريقة آلية من خلال تعليمات برمجية، تعمل على البحث الذاتي، عن صور بصفات معينة، وتحديدتها من خلال

خوارزمية ذكية للتعرف على معالم أندلسية (باستخدام نموذج التعلم العميق)

كلمات مفتاحية تساق مع التعليمات البرمجية⁽¹⁾، وبعد الحصول على الصور، تصنف إلى مجموعات، حسب اسم المعلم الذي تصوره، وكل صنف من الصور يقسم إلى ثلاثة أقسام بنسبة 60٪، لتدريب نموذج خوارزمية التعلم العميق، وبنسبة 20٪ لاختبار صحة تعلم الخوارزمية، و20٪ من صنف صور المعالم بمصادقة تعلم الخوارزمية.



Flickr, "Flickr Services. The App Garden. API Documentation." [Online]. (1)
Available: <https://www.flickr.com/services/api/>. [Accessed: 01-Dec-2018].



شكل (3): صور متعددة الإضاءات والإسقاطات لنافورة السباع

من المهم جدًا الحصول على كم كبير من صور المعالم المستهدفة، والصور يجب أن تكون عن المعالم لتحاكيها من جوانب مختلفة، وزوايا متعددة، أضف إلى ذلك اختلافات الليل، والنهار، والإضاءات، وتعدد إسقاطات التقاط الصور. فكلما تباينت الملامح في الصورة، وزاد التمييز بينها تعلّم النظام التعرف عليها بصورة أسرع وأدق. (الشكل (3) يعرض عدة صور لنافورة السباع)


مهما اغتنت شبكة المعلومات الدولية بالصور، فإنها لن تغطي كل المعالم باختلاف أوقات الليل والنهار، واختلاف فصول السنة، وزوايا النظر للكائنات وتصويرها، لذلك يلجأ المطورون والمبرمجون إلى أسلوب تعزيز البيانات كالصور وغيرها (Data Augmentation) لزيادة كمها ونوعها لغرض تدريب الأنظمة الذكية ورفع مستوى معرفتها.

6. تعزيز البيانات لتعويض الصور المستهدفة المفقودة:

لكي تتدرب الشبكة العصبية بكفاءة أعلى، على نموذج التعلم العميق، فتحتاج للكثير من الصور المختلفة عن المعلم الواحد، وهذا يجنب نموذج الشبكة العصبية ما يعرف بتخمة الأوزان (Overfitting)، التي تحدث نتيجة تكرار تدريب النموذج على فئة محدودة من البيانات، فيتشبع النظام بها ويضبط أوزان قوة الترابط بين الخلايا، بناءً على فئة قليلة من المعلومات، فلا يميز غيرها، ظنا منه بأنه تعلم تمييز تلك الملامح، ولتعزيز البيانات استخدم من قبل لزيادة فئة الصور في حزمة بيانات التدريب⁽¹⁾، والاختبار والمصادقة، وهو أساس لتعويض المفقود من بيانات الصور، وتستعمل تقنيات مختلفة لتعزيز البيانات التصويرية، فيقوم النظام بتحويلات على الصور الرقمية، لإنتاج صور جديدة، وهذه التحويلات تشمل الدوران العشوائي، من قلب الصور، وتكبيرها أو تصغيرها، وتغيير الإضاءات، وتباين الألوان، وإزاحة محتويات الصورة، وغيره كثير. الشكل

C. Shorten and T. M. Khoshgoftaar, "A survey on Image Data Augmentation for Deep Learning," J. Big Data, vol. 6, no. 1, p. 60, 2019.

التالي (4) يعطي لمحة عن تعزيز البيانات التصويرية لإنتاج آلاف الصور الجديدة التي تدعم عملية التعلم في الشبكة العصبية.




شكل (4): إنتاج صور جديدة لتعزيز بيانات تدريب نموذج الشبكة العصبية العميقة

7. بناء الشبكة العصبية وتدريبها:

هذه الورقة البحثية تبني شبكة للتعلم العميق، بنموذج لشبكة عصبية التلافيفية، مستوحاة من شبكة المجموعة الافتراضية الفراغية (Virtual Geometry Group)، وتعرف بفجيجي نت (VGGNet). والشبكة المتعددة الطبقات العصبية،

خوارزمية ذكية للتعرف على معالم أندلسية (باستخدام نموذج التعلم العميق)

وتسبقها طبقات عمليات تصفية للصور الداخلة في مرحلة الالتفاف، التي تصفي صور المعالم الأندلسية من خلال تجزئتها لقطع متساوية، تحوي ملامح جزئيات تلك المعالم المصورة، وبهذا الأسلوب تُمكن خوارزمية النظام المطور الشبكة العصبية العميقة من التعلم أكثر فأكثر من الملامح الغنية بالمعلومات، عن المعالم المستهدفة، الشكل التالي (5) يعرض البنية العامة لهيكلية شبكة التعلم العميق، التي تتدرب على التعرف على ملامح معلم نافورة السباع.



شكل (5): هيكلية نموذج الشبكة العصبية الالتفافية للتعلم العميق المستخدم للتعرف على المعالم الأندلسية

الشبكة تحتوي على فئتين من طبقات مصفيات جزئيات الصورة، تتبعها فئة من الطبقات المتعددة للخلايا العصبية العميقة، مع طبقة المصفيات الأولى، وستتعلم من 32 مصفيا، كل بحجم 3×3 نقاط. والطبقة الثانية للمصفيات سوف تتعلم بمصفيات عددها 64 مصفيا، كل بحجم 3×3 نقاط. يتلوها مصفيات بنافذة منزلة بحجم 2×2 نقاط. والتفاصيل التقنية لطبقات الشبكة موضحة في الجدول (1) التالي.

جدول (1): مواصفات تقنية للشبكة العصبية متعددة الطبقات

نوع الطبقة	حجم المخرجات	حجم نافذة المصفي
INPUT IMAGE	$64 \times 64 \times 3$	
CONV	$64 \times 64 \times 32$	$3 \times 3, K = 32$
ACT	$64 \times 64 \times 32$	

نوع الطبقة	حجم المخرجات	حجم نافذة المصفي
BN	$64 \times 64 \times 32$	128
CONV	$64 \times 64 \times 32$	$3 \times 3, K = 32$
ACT	$64 \times 64 \times 32$	
BN	$64 \times 64 \times 32$	128
MAX POOL	$32 \times 32 \times 32$	2×2
DROPOUT	$32 \times 32 \times 32$	
CONV	$32 \times 32 \times 64$	$3 \times 3, K = 64$
ACT	$32 \times 32 \times 64$	
CONV	$32 \times 32 \times 64$	$3 \times 3, K = 64$
ACT	$32 \times 32 \times 64$	
MAX POOL	$16 \times 16 \times 64$	2×2
DROPOUT	$16 \times 16 \times 64$	
FLATTERN	16384	
FC	512	
ACT	512	
BN	512	
DROPOUT	512	
FC	5	
SOFTMAX		5

8. التجارب والنتائج:

صُممت الشبكة، ودُرِبت في جهاز حاسوب على الأداء، ومواصفات الحاسوب تتلخص في وجود معالج من نوع إنتل آر آي 7 (Intel R i7 CPU) وبسرعة 2.2 قيقا هيرتز، ويحتوي على 8 أقطاب، بذاكرة 16 جيجا بايت. والحاسوب يعمل بنظام تشغيل ويندوز 10 بهيئة 64 بت. والصور الداخلة لخوارزمية نموذج الشبكة تم تجهيزها لتكون بحجم 64×64 نقطة لكل صورة من

صور المعالم الستة المستهدف تعلمها وموضحة في الشكل (2) أعلاه. كل معلم منح رمزاً رقمياً خاصاً به، وبقيمة بين 0 و 1 ليكون عدد مخارج الشبكة العصبية 6 مخارج، كل منها مخصص لمعلم معين. كما أن بيانات الصور المجمعة والمعززة، تم تقسيمها لثلاث فئات. 60٪ من صور أي معلم تستخدم لتدريب الشبكة، 20٪ من صور المعلم تستخدم لاختبار الشبكة، و20٪ الباقية تستخدم للمصادقة على دقة تعلم الشبكة لمعلم الأندلسي.


مبدأ تبادل القصور (Cross-Entropy) حسب المرجع⁽¹⁾ تم استخدامه على أنه وظيفة دالة حساب مفقود التعلم، ومعدل تزايد التعلم (Learning Rate) وكان بقيم ابتدائية 0.006 ثم يتولى النظام ضبطها حسب صحة وخطأ التعرف، وبها يتم ضبط قوة أوزان الروابط بين الخلايا العصبية، وإن الشبكة دُرِبَت لمائة (100) جولة باستخدام حزم بيانات بحجم 32. والجدول (2) يعرض تقرير دقة تعلم نموذج الشبكة في تصنيف صور المعالم بدقة تصل إلى 99٪.

جدول (2): تقييم أداء الشبكة العصبية العميقة

تكرار التعلم	تذكر المعلم	الدقة	المعلم
270	0.99	1.00	نافورة السباع
260	0.97	0.98	قصر الحمراء
300	1.00	1.00	عمود لا غالب إلا الله
255	1.00	0.99	المحراب
284	0.96	0.97	باب ونقوش
265	1.00	0.96	قصر إشبيلية
1634	0.99	0.98	الدقة العامة للشبكة

K. Janocha and W. M. Czarnecki, "On Loss Functions for Deep Neural Networks in Classification," CoRR, vol. abs/1702.0, 2017. (1)

فمعدل مفقود التعلم، ودقة تدريب الشبكة، مع مرور الزمن، موضحة في منحنيات جولات تدريب الشبكة المرسومة في الشكل (6). على المحور الأفقي السيني، يوجد عدد جولات التعلم تتزايد مع مرور الزمن لتصل إلى 100 جولة. على المحور العمودي التصاعدي يوجد المفقود ودقة التعلم. بالنظر لسلوك المنحنيات يظهر جلياً تعلم الشبكة لتلك المعالم المستهدفة. بعد حوالي 20 جولة تعلم الشبكة بدأت تصل لدقة تصنيف للمعالم الأندلسية الستة بنسبة 0.98%. وهذه دقة عالية ممتازة. والمفقود في التدريب والمصادقة على دقة التمييز يتنازل باستمرار مع فترة تذبذبات محدودة تبينها نبضات المنحنى، وهذا يرجع لمعدل التعلم الابتدائي المفترض بقيمة 0.006 ثم يتحسن الأداء مع ضبط معدل التعلم الذاتي. تقريباً مع الجولة 22 أو 23 يصل النظام لدقة 0.99 أو 1.00 أي تقريباً نسبة دقة 100%.



شكل (6): منحنيات جولات تدريب الشبكة العصبية لتعلم تمييز المعالم الأندلسية

الشكل (7) التالي يبين مكونات النظام النهائي الذي يتألف من تطبيق نقال أندرويد، ويعتمد على نموذج الشبكة العصبية العميقة التي تم تدريبها للتعرف

خوارزمية ذكية للتعرف على معالم أندلسية (باستخدام نموذج التعلم العميق)

على بعض المعالم الأندلسية، ويمكن للنظام العمل بشكل مستقل ما دام حجم البيانات يتلاءم مع إمكانيات الهواتف النقالة، والنظام يمكنه التواصل مع خدمة ويب، التي تحفظ نموذجا معقدا ضخمة البيانات، يحافظ على خادم شبكة إنترنت، وليقوم بدور التحليل والتعرف على المعالم، ثم إرسال نتيجتها للمستخدم على هاتفه المحمول، الصور التقطت من الهاتف المحمول لمشاهد حقيقية للمعالم أم لصور ورقية أو ضوئية على شاشات الحواسيب أو التلفاز.



شكل (7): النظام العام لتمييز المعالم الأندلسية

9. الخلاصة:

يزداد انتشار استخدام تقنيات الذكاء الاصطناعي مع تطور برمجيات وأعداد الحواسيب، وأيضًا مع إدراك الناس للفوائد الجمة التي تدرك بتوظيف هذه التقنيات الحديثة المتجددة، وشبكات التعلم العميق من أحدث تطورات أدوات الذكاء الاصطناعي، وقد يعود سبب تزايد انتشارها إلى المزايا الرئيسية التي تجعلها أكثر ملاءمة لحل المشاكل التي كانت عصية على البشر، والخوارزميات، والمعدات التقليدية القديمة، وأيضًا يعود تزايد استخدامها إلى القدرة على تعلم ونمذجة العلاقات غير الخطية والمعقدة، وهو أمر مهم للغاية؛ لأن في الحياة الواقعية تكون

أغلب العلاقات بين المدخلات والمخرجات، وهي علاقات غير خطية، وهي أيضا معقدة، كما يمكن القول إن بعد التعلم العميق من المدخلات الأولية وعلاقاتها ببعض، ويكون النموذج قادرا على التنبؤ بماهية البيانات الجديدة التي تمر عليه، ولعل أكبر قيود على نماذج التعلم العميق هي أنها تتعلم من خلال الملاحظات، وهذا يعني أنهم يعرفون فقط ما كان في البيانات التي تم تدريبهم عليها. إذا كان لدى المستخدم كمية صغيرة من البيانات فلن تتعلم النماذج بطريقة يمكن تعميمها.

في هذه الورقة تم تطوير نموذج شبكة عصبية عميقة التعلم من خلال أدوات لغة بايثون (Python) ومكتبة كيراس (Keras API) الذي يمكنه التعرف على بعض المعالم الأندلسية، وتم تدريبه واختباره على مجموعة بيانات الصور الرقمية وتعزيز نقص الصور بإجراء تحويلات برمجية على الصور المتاحة لإنتاج صور جديدة. تم تدريب النموذج على حزمة البيانات، وأظهرت خوارزمية شبكة التعلم العميق نموذجا يتمكن من التعرف على المعالم الأندلسية بدقة تصل إلى 99%. يمكن استمرار تطوير الخوارزمية لإنتاج نموذج يتعرف على أكبر قدر من المعالم ولكن بزيادة المعالم تزداد الحاجة لإمكانيات حاسوبية أكبر قدرة من حيث سعة الذاكرة وسرعة المعالجة.

10. المصادر والمراجع

- [1] J. Magic and M. Magic, *Image Classification: Step-By-step Classifying Images with Python and Techniques of Computer Vision and Machine Learning (2; Python*. Amazon Digital Services LLC - Kdp Print Us, 2019.
- [2] C. Termritthikun, S. Kanprachar, and P. Muneesawang, "NU-LiteNet: Mobile Landmark Recognition using Convolutional Neural Networks," no. 1, pp. 3–8, 2012.
- [3] K. Yap, Z. Li, D. Zhang, and Z. Ng, "Efficient mobile landmark recognition based on saliency-aware scalable vocabulary tree," 2012, p. 1001.
- [4] K. Bulkunde, A. Chakraborty, S. Kazi, and K. Dhumal, "Landmark Recognition using Image processing with MQTT protocol," pp. 2405–2407, 2017.
- [5] T. Chen, K. Yap, and D. Zhang, "Discriminative Soft Bag-of-Visual Phrase for Mobile Landmark Recognition."
- [6] J. Schmidhuber, "Deep Learning in neural networks: An overview," *Neural Networks*, vol. 61, pp. 85–117, 2015.
- [7] A. Krizhevsky and G. E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," pp. 1–9.
- [8] C. Szegedy *et al.*, "Going Deeper with Convolutions," 2014.
- [9] K. Simonyan and A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition," pp. 1–14, 2014.
- [10] G. A. Hembury, V. V. Borovkov, J. M. Lintuluoto, and Y. Inoue, "Deep Residual Learning for Image Recognition Kaiming," *Cvpr*,

-
- vol. 32, no. 5, pp. 428–429, 2003.
- K. Banlupholsakul, J. Ieamsaard, and P. Muneesawang, “Re- [11]
ranking approach to mobile landmark recognition,” in *2014
International Computer Science and Engineering Conference
(ICSEC)*, 2014, pp. 251–254.
- K.-H. Yap, Z. Li, D.-J. Zhang, and Z.-K. Ng, “Efficient Mobile [12]
Landmark Recognition Based on Saliency-aware Scalable
Vocabulary Tree,” in *Proceedings of the 20th ACM International
Conference on Multimedia*, 2012, pp. 1001–1004.
- D. G. Lowe, “Object recognition from local scale-invariant [13]
features,” in *Proceedings of the Seventh IEEE International
Conference on Computer Vision*, 1999, vol. 2, pp. 1150–1157 vol.2.
- N. Dalal and B. Triggs, “Histograms of Oriented Gradients for [14]
Human Detection,” in *Proceedings of the 2005 IEEE Computer
Society Conference on Computer Vision and Pattern Recognition
(CVPR’05) - Volume 1 - Volume 01*, 2005, pp. 886–893.
- M. K. Benkaddour and A. Bounoua, “Feature extraction and [15]
classification using deep convolutional neural networks, PCA and
SVC for face recognition,” *Trait. du Signal*, vol. 34, no. 1–2, pp.
77–91, 2017.
- J. Deng, W. Dong, R. Socher, L. Li, K. Li, and L. Fei-fei, [16]
“ImageNet : A Large-Scale Hierarchical Image Database,” pp. 2–9.
- Flickr, “Flickr Services. The App Garden. API Documentation.” [17]
[Online]. Available: <https://www.flickr.com/services/api/>.
[Accessed: 01-Dec-2018].
- C. Shorten and T. M. Khoshgoftaar, “A survey on Image Data [18]
-

Augmentation for Deep Learning,” *J. Big Data*, vol. 6, no. 1, p. 60, 2019.

K. Janocha and W. M. Czarnecki, “On Loss Functions for Deep [19]
Neural Networks in Classification,” *CoRR*, vol. abs/1702.0, 2017.



الجمعية الليبية الأندلسية