

تطوير نموذج للتعلم العميق بالشبكات العصبونية الاصطناعية لاستخراج المناطق

العمرائية من صور الاستشعار عن بعد - منطقة الدراسة: حمص - طرطوس

د.م. حنان كامل درويش* د.م. عدنان أحمد محمد*

د.م. فادي عز الدين شعبان**

المخص

تعتبر عملية تصنيف صور الاستشعار عن بعد من العمليات الأساسية المستخدمة في إنشاء خرائط استعمالات الأراضي وخرائط الغطاء الأرضي، استخراج فئة محددة أو الكشف عن التغييرات بعد الكوارث أو مع مرور الزمن. ويستخدم لتحقيق ذلك خوارزميات مطورة خصيصاً وذلك للوصول إلى أفضل طريقة تمكن من استخلاص البيانات المكانية والمعالم من هذه الصور بحيث تمثل الواقع الحقيقي للأرض رقمياً وبدقة كبيرة.

يمثل البحث المقدم مقارنة جديدة في استخراج فئة محددة تمثل المناطق العمرائية اعتماداً على الذكاء الاصطناعي وتحديداً تعلم الآلة Machine Learning والتعلم العميق Deep learning من خلال الشبكات العصبونية الاصطناعية (ANNs). تم تطبيق المنهجية على صورة لاندسات 8 متعددة الأطياف لمدينة حمص مأخوذة في العام 2017 وبناء نموذج اعتماداً على بياناتها ومن ثم التنبؤ من خلال تطبيق هذا النموذج على صورة لاندسات 8 لمدينة طرطوس في العام 2018 لاستخراج المناطق العمرائية والتأكد من صحة النموذج.

تم الاعتماد في كل مراحل المعالجة وبناء الشبكة وتدريبها والتنبؤ على عدة مكثبات بايثون حرة ومفتوحة المصدر وخاصة مكثبات التعلم العميق وأيضاً على أنظمة المعلومات الجغرافية. دلت نتائج الدراسة على تحسن كبير في الدقة والوقت والجهد من خلال مقارنتها مع طرق التصنيف التقليدية المعتمدة على البيكسل وتحديداً طريقة الاحتمالية العظمى وأيضاً طرق التصنيف القائمة على الكائن.

كلمات المفتاحية: تصنيف صور الاستشعار عن بعد، تعلم الآلة، التعلم العميق، الشبكات العصبونية الاصطناعية، أنظمة المعلومات الجغرافية.

* أستاذ مساعد في قسم الهندسة الطبوغرافية - كلية الهندسة المدنية - جامعة البعث - حمص - سورية.

✉ hanan.darwisha@hotmail.com, ✉ ad.moh4@gmail.com

** أستاذ مساعد في قسم الهندسة الطبوغرافية - كلية الهندسة المدنية - جامعة تشرين - اللاذقية - سورية.

✉ fadi.chaaban@tishreen.edu.sy

Developing a Model of Deep Learning by ANNs for Urban Areas Extraction from Remote Sensing Images – Study Area: Homs- Tartous

Dr.Eng. Hanan DARWISHE* Dr.Eng. Adnan Mohammad*
Dr.Eng Fadi CHAABAN**

Abstract

Remote sensing images classification is one of the basic processes used in creating of land use/cover maps, extracting a specific category or detecting changes after disasters or with time. To achieve this, specially developed algorithms are used to find out the best way to extract spatial data and features from these images, and to ensure that they represent the reality of the Earth digitally with high level of accuracy.

This research represents a new approach for extracting a specific category of features that represents urban areas, depending on artificial intelligence, in particular Machine Learning and Deep Learning (Artificial Neural Networks (ANNs)).

The suggested methodology was applied to the Landsat 8 multi-spectral image of Homs city captured in 2017 to build a model for urban areas extraction. To evaluate the validity of the model, it was applied to the Landsat 8 image of Tartous city captured in 2018 to extract similar areas.

Several free and open source Python libraries, especially deep learning libraries, and geographic information systems were used in all stages of processing, network building, training, and prediction.

The results of the study indicated a significant improvement in accuracy, time and effort comparing with the traditional pixel-based classification methods, specifically the Maximum likelihood method, and object-based classification methods.

Key Words: Remote Sensing Images classification, Deep Learning, Machine Learning, Artificial Neural Networks, Geographic Information Systems.

* Associate Professor, Department of Topographic Engineering, Faculty of Civil Engineering, Al-Baath University, Homs, Syria.

✉ hanan.darwishe@hotmail.com

✉ ad.moh4@gmail.com

** Associate Professor, Department of Topographic Engineering, Faculty of Civil Engineering, Tishreen University, Lattakia, Syria.

✉ fadi.chaaban@tishreen.edu.sy

1 مقدمة

يعتبر الاستشعار عن بعد من التقنيات الفعالة لتصوير سطح الأرض ورصدها بتكلفة منخفضة وفي وقت قصير. ومع ذلك، عندما يتم استخلاص المعلومات من الصور وإجراء تقييم للدقة، فإن النتائج التي يتم الحصول عليها لا تحقق دائماً دقة عالية، مما جعل تطوير أساليب التحليل والتصنيف أمراً حتمياً.

توفر طرق الذكاء الاصطناعي وخصوصاً تعلم الآلة والتعلم العميق إمكانية التصنيف الفعال لصور الاستشعار عن بُعد [1]، لأن من بين نقاط قوة هذه الطرق القدرة على التعامل مع البيانات ذات الأبعاد الكبيرة وتعيين الفئات ذات الخصائص المعقدة للغاية. لكن تطبيق التصنيف بالتعلم الآلي ليس بالأمر السهل نظراً لأن الأدبيات تقدم نصائح متضاربة فيما يتعلق بالعديد من القضايا الرئيسية، مما أدى إلى تطوير العديد من النماذج المستخدمة والتي تعتمد على خوارزميات تعلم مختلفة مثل Support Vector Machine شعاع دعم الآلة، Decision Tree شجرة القرار، Neural Networks الشبكات العصبونية، Random Forests الغابات العشوائية، k-Nearest Neighbours (k-NN) الجار الأقرب، Boosted DTs شجرة القرار المعززة وغيرها من الخوارزميات. استخدمت الشبكات العصبونية لتحليل صور الاستشعار عن بعد منذ بداية التسعينيات وأعطت نتائج واعدة [2] [3]، ومن ثم تطورت بشكل كبير خلال السنوات الماضية باعتبارها مقرب عام أو شامل لكل أنواع التحليلات Universal Approximator، وتتمتع بالعديد من المزايا فهي لديها القدرة على تمثيل أي نوع من أنواع الظواهر بالإضافة إلى أنه يمكن استخدامها كنوع من "الصندوق الأسود" وبالتالي سهولة الاستخدام.

يقوم البحث المقدم على بناء نموذج اعتماداً على الشبكات العصبونية الاصطناعية، مهمته تصنيف صور الأقمار الصناعية متعددة الأطياف، ومن ثم مقارنة النتائج مع طرق التصنيف التقليدية المعتمدة على البيكسل وتلك المعتمدة على الكائن.

وستتم المقارنة على أساس حساب دقة التصنيف الكلية، دقة المستخدم، دقة المنتج ومعامل كابتا للحصول على الفروقات بين أداء طرق تصنيف الصورة المختلفة، وسيتم تحديد الأداء الأمثل من خلال التحقق من صحة نتائج التصنيف مع بيانات الواقع.

2 هدف البحث وأهميته

استحوذ الذكاء الاصطناعي على غالبية المجالات في حل المشكلات المعقدة، ولا يعد المجال الجغرافي المكاني استثناءً من ذلك. وبالتالي، تهدف هذه الدراسة للاستفادة من التعلم العميق في مجال تصنيف صور الأقمار الصناعية متعددة الأطياف ومتوسطة الدقة المكانية والعمل على تحسين دقة التصنيف مقارنة بالطرق التقليدية في استخلاص الظواهر المختلفة وإنشاء خرائط الغطاء الأرضي.

تكمن الأهمية الخاصة للبحث في توفير الوقت والجهد اللازم لإجراء التصنيف مع تفوق في الدقة للمنتج النهائي.

3 مواد وطرائق البحث

3.1 تصنيف صور الاستشعار عن بعد

لتحليل صور الاستشعار عن بعد واستخراج عناصر الغطاء الأرضي منها يتم عادةً استخدام توابع وخوارزميات محددة تدعى خوارزميات التصنيف Classification، وهي عملية يتم من خلالها ترتيب خلايا الصورة في مجموعات من الأصناف أو الفئات المحددة حسب معايير تصنيف معينة.

تم تطوير عدد كبير من طرق وخوارزميات التصنيف من قبل الباحثين، وتقسم هذه الطرق بشكل أساسي إلى تقنيات تعتمد على البيكسل كوحدة تحليل أساسية Pixel-based Classification، وتقنيات تعتمد على الكائن كوحدة تحليل Object-based Classification ويتفرع ضمن هذه التقنيات خوارزميات عديدة ومنوعة.

استخدمت تقنيات التصنيف بالاعتماد على البيكسل بشكل واسع في العديد من الأبحاث [4]، وهي تناسب الصور ذات الطبيعة غير المعقدة والتي تمتلك دقة مكانية متوسطة. لكن مع التطور التقني للمستشعرات وازدياد الدقة المكانية لصور الاستشعار عن بعد أصبحت

نتائج هذه الخوارزميات غير كافية، وتوجّه الباحثون إلى تطوير خوارزميات جديدة مبنية على مبادئ تحليل الصور بالاعتماد على الكائن ضمن برامج الرؤية الحاسوبية computer vision والتي تجمع بين المعلومات الطيفية، الشكل، القياس، النسيج والموقع المكاني والجغرافي لاستخلاص العناصر والكائنات المختلفة من صور الاستشعار عن بعد [5].

تتطلب طرق التصنيف السابقة الذكر الوقت والجهد في تنفيذها مما جعل البحث عن طرق أسرع وأسهل مع الحفاظ على دقة مقبولة للنتائج أمراً ضرورياً. ومع تطور برامج الرؤية الحاسوبية وظهور خوارزميات الذكاء الاصطناعي والتعلم العميق بالشبكات العصبونية في تصنيف الصور والتعرف على الأشكال والأشياء فيها ظهرت أهمية استخدام هذه الخوارزميات في تصنيف صور الاستشعار عن بعد سواء متوسطة أو عالية الدقة المكانية. ويمكن تصنيف الشبكات العصبونية للتعلم العميق ضمن ثلاثة أنواع رئيسية وهي تشكل الأساس لمعظم النماذج المدربة مسبقاً [6]:

- 1- الشبكات العصبونية الاصطناعية (ANNs) Artificial Neural Networks
- 2- الشبكات العصبونية الالتفافية (CNNs) Convolution Neural Networks
- 3- الشبكات العصبونية المتكررة (RNNs) Recurrent Neural Networks

وستقوم في هذا البحث بالاعتماد على النوع الأول واختبار نتائجه.

3.2 الشبكات العصبونية الاصطناعية ANNs

صممت الشبكات العصبونية الاصطناعية، بوصفها نماذج رياضية، لمحاكاة قدرة العقل البشري على التنبؤ عن طريق عملية التعلم [7].

تتكون شبكة ANN من عدد من الخلايا العصبونية الاصطناعية التي تسمى "العقد" أو "الخلايا العصبونية" «nodes» أو «neurons». وعادةً ما يتم تنظيم عناصر الشبكات العصبونية الاصطناعية في طبقات: طبقة المدخلات؛ وطبقة المخرجات؛ وواحدة أو أكثر من الطبقات الوسيطة تسمى "الطبقات المخفية"، وتتكون كل طبقة من مجموعة من الخلايا العصبونية الفردية كما يظهر في (الشكل 1).

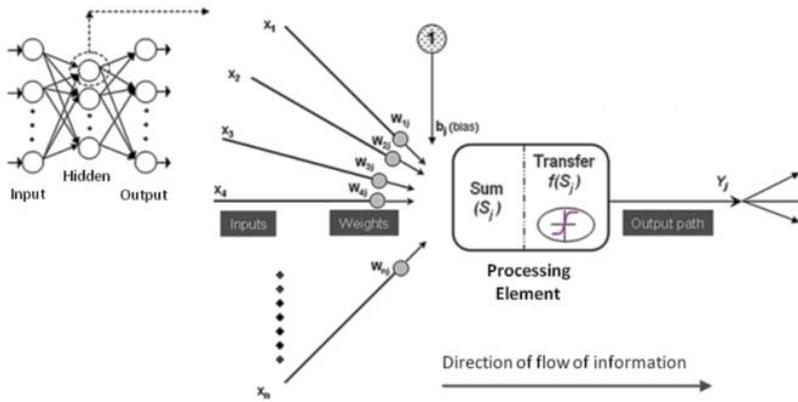
ووفقاً لـ McCulloch et Pitts الذي اقترح النموذج الرسمي الأول للخلايا العصبونية عام 1943 ، تتلقى كل خلية مدخلات في شكل ناقلات (X)، وتقوم بتنفيذ مجموع موزون

(WX + b)، وتولد باستخدام تابع خطي أو غير خطي نتيجة فعلية (Y) كما هو موضح في المعادلة (1).

$$Y = f(WX + b) \quad (1)$$

حيث: $W = (w_{i,1}, w_{i,2}, \dots, w_{i,N})$ هي أوزان الخلايا العصبونية i (مصنوفة الأوزان)، $X = (x_1, x_2, \dots, x_N)$ هي المدخلات للخلايا العصبونية i، b هي انحراف قيم الخلايا العصبونية.

(WX + b) هي المجموع الموزون للمدخلات i، f هي تابع التفعيل أو النقل (تابع التنشيط) للخلايا العصبونية.



الشكل 1 : العناصر الأساسية للشبكات العصبونية الاصطناعية

وهناك أنواع مختلفة من الشبكات العصبونية الاصطناعية وفقاً لبنيتها وطريقة التعلم مع وجود شكلين رئيسيين حسب البنية: الشكل المتداخل recursive مع "Feedback" (كلياً أو جزئياً ضمن حلقة [8] [9])، ونموذج يسمى "feedforward" وهذا النوع من الشبكات لا يوجد لديها تغذية عكسية "Feedback" بين الخلايا العصبونية. تُعد الشبكات العصبونية الأمامية (feedforward) هي النوع الأول والأبسط. في هذه الشبكة تنتقل المعلومات من طبقة الإدخال مباشرة عبر أي طبقات مخفية إلى طبقة الإخراج بدون دورات أو حلقات.

التعلم هو مرحلة من مراحل تطور الشبكة العصبونية التي يتم تغيير سلوك الشبكة فيها حتى الحصول على السلوك المطلوب، وهو يتألف من مرحلة تحديد الوزن للحصول على نتيجة Y_0 المطلوبة والمشابهة للمدخل X ، ويتم أثناء التعلم تعديل متكرر للأوزان عموماً عن طريق مجموعة من بيانات التدريب. وهناك عدد كبير من قواعد التعلم، والتي يمكن تصنيفها في ثلاث فئات: قواعد التعلم المراقبة، قواعد التعلم غير المراقبة وقواعد التعلم المعززة. قواعد التعلم المراقبة هي الأكثر شيوعاً: حيث يكون المطلوب أن يتوافق الإدخال مع ناتج أو خرج محدد مسبقاً، لذلك نعطي الأمثلة (عينات التدريب) للشبكة التي ستضبط ومن خلال خوارزمية التعلم أوزانها للحد من الأخطاء، ويمكن اعتبار الشبكة منضبطة عند الوصول إلى خطأ مسموح [10].

التعلم غير المراقب هو نوع من التعلم الآلي الذي يبحث عن أنماط محددة في مجموعة بيانات بدون عينات تدريب موجودة مسبقاً وبعدها أدنى من الإشراف البشري، وهو يستخدم في حالة عدم إمكانية الحصول على قاعدة التعلم، وفيها يكون المطلوب بناء الشبكة غير معروفة الناتج مسبقاً، حيث تقدم المدخلات إلى الشبكة ويسمح لها بالتحرك بحرية حتى تستقر [11].

يختلف التعلم المعزز عن التعلم المراقب في عدم الحاجة إلى تقديم أزواج من المدخلات/المخرجات، وفي عدم الحاجة إلى تصحيح القرارات (الاختيارات) غير المثالية بشكل مباشر. بدلاً من ذلك، ينصب التركيز على إيجاد توازن بين استكشاف (منطقة مجهولة) واستغلال (المعرفة الحالية) [12].

3.3 تقييم الدقة

3.3.1 تقييم الدقة ضمن نماذج الشبكات العصبونية الاصطناعية

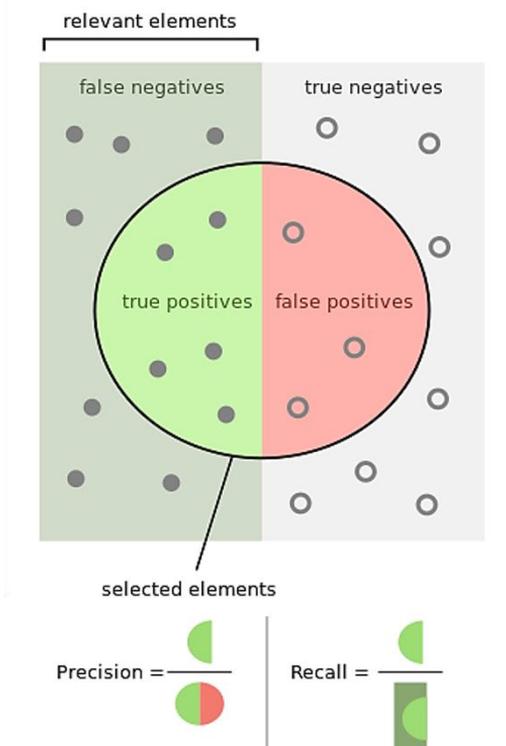
عند التصنيف اعتماداً على التعلم الآلي، يتم حساب الدقة اعتماداً على مجموعة من المعايير أهمها دقة الاسترجاع ودقة الصحة ودقة القياس (F- Recall, Precision, F) (measure) [13].

على سبيل المثال، بالنسبة للبحث عن فئة المباني في صورة يوجد فيها فئتين مباني وأشجار، فإن دقة الاسترجاع هي عدد النتائج الصحيحة للمباني مقسوماً على عدد المباني الكلي التي كان ينبغي استرجاعها (معادلة 2).

من السهل تحقيق دقة استرجاع بنسبة 100% من خلال استخلاص كافة المباني من الصورة. لذلك، لا تكفي دقة الاسترجاع وحدها، ولكن نحتاج إلى قياس عدد الكائنات التي تم استخلاصها مع المباني وهي الأشجار في هذا المثال، عن طريق حساب دقة الصحة وهي عدد النتائج الصحيحة للمباني مقسوماً على عدد الكائنات الكلي التي تم استرجاعها (معادلة 3) (الشكل 2).

$$recall = \frac{|{\text{relevant documents}} \cap {\text{retrieved documents}}|}{|{\text{retrieved documents}}|} \quad (2)$$

$$precision = \frac{|{\text{relevant documents}} \cap {\text{retrieved documents}}|}{|{\text{retrivied documents}}|} \quad (3)$$

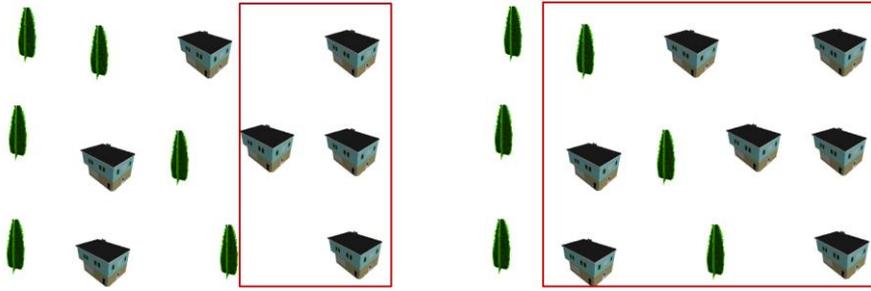


الشكل 2: دقة الاسترجاع ودقة الصحة

أما بالنسبة لمعيار دقة القياس F-measure ويسمى أيضاً F1 score فهو المقياس الذي يجمع بين دقة الاسترجاع ودقة الصحة ويمثل المتوسط التوافقي للاثنين معاً (المعادلة 4).

$$F = 2 \cdot \frac{\text{precision} \cdot \text{recall}}{\text{precision} + \text{recall}} \quad (4)$$

يبين (الشكل 3) نتيجة تطبيق تصنيفين مختلفين لاستخلاص فئة المباني، في الصورة اليسارية تم استخلاص أربعة مباني صحيحة (ضمن المربع) وبدون أي كائن خطأ فهنا دقة الصحة عالية ولكن لم يتم استخلاص كافة المباني من الصورة فدقة الاسترجاع منخفضة، أما الصورة اليمينية فإن كافة المباني تم استخلاصها ولكن يوجد أيضاً أشجار تم استخلاصها بشكل خاطئ مع فئة المباني فهنا دقة الاسترجاع عالية ولكن دقة الصحة منخفضة.



high precision/ low recall

high recall/low precision

دقة استرجاع عالية ودقة صحة منخفضة دقة استرجاع منخفضة ودقة صحة عالية

الشكل 3: دقة الاسترجاع ودقة الصحة

3.3.2 تقييم الدقة بعد التصنيف

تقييم الدقة هو الجزء الأهم في التصنيف، حيث تقوم من خلاله بمقارنة الصورة المصنفة بمصدر بيانات آخر يعتبر بيانات دقيقة أو صحيحة كالصور عالية الدقة المكانية أو الصور المصنفة الموجودة مسبقاً أو طبقات بيانات GIS [14]. وهو الإجراء المستخدم لتحديد مدى موثوقية الصورة المصنفة. تتمثل الطريقة الأكثر شيوعاً لتقييم دقة الخريطة المصنفة بإنشاء مجموعة من النقاط العشوائية من بيانات صحيحة وواقعية ومقارنتها بالبيانات المصنفة، حيث يتم بناء "مصفوفة الخطأ" (الجدول 1)، وهي مصفوفة مربعة تمثل فيها الصفوف فئات الغطاء الأرضي من الصورة المصنفة والأعمدة فئات الغطاء الأرضي من الصورة المرجعية، ومن خلالها يتم حساب معايير الدقة المختلفة كدقة التصنيف الكلية A (overall accuracy) (المعادلة 5)، دقة تصنيف المستخدم U_i (producer's accuracy) P_j (المعادلة 6)، ودقة تصنيف المنتج (المعادلة 7)، ومعامل كبا (Kappa) (المعادلة 8)، والذي يستخدم لقياس العلاقة بين الاتفاق المتوقع لاحقاً (beyond chance agreement) وعدم الاتفاق (الاختلاف) المتوقع (expected disagreement)، وتستخدم في إيجاده كل عناصر مصفوفة الخطأ وليس فقط العناصر القطرية في المصفوفة، ويمكن أن يأخذ قيمة من 0 إلى 1. إذا كان معامل كبا يساوي 0، فلا يوجد اتفاق بين الصورة المصنفة والصورة المرجعية. إذا كان معامل كبا يساوي 1، فإن الصورة المصنفة وصورة الواقع متطابقتان تماماً. لذلك، كلما زاد معامل كبا، زادت دقة التصنيف.

وتعتبر قيمة كابا بين 0.20-0 عن اتفاق ضعيف، وبين 0.21-0.40 مقبول، وبين 0.41-0.60 متوسط، وبين 0.61-0.80 مهم، وبين 0.81-1 تقريباً مثالي.

الجدول 1: مصفوفة الخطأ

		Reference				
		Class 1	Class 2	Class 3	Class 4	Total
Map	Class 1	P ₁₁	P ₁₂	P ₁₃	P ₁₄	P _{1.}
	Class 2	P ₂₁	P ₂₂	P ₂₃	P ₂₄	P _{2.}
	Class 3	P ₃₁	P ₃₂	P ₃₃	P ₃₄	P _{3.}
	Class 4	P ₄₁	P ₄₂	P ₄₃	P ₄₄	P _{4.}
	Total	P _{.1}	P _{.2}	P _{.3}	P _{.4}	1

$$A = \sum_{j=1}^q p_{jj} \quad (5)$$

$$U_i = p_{ii}/p_{i.} \quad (6)$$

$$P_j = p_{.j}/p_{.} \quad (7)$$

$$kappa = \frac{n \sum_{i=1}^q p_{ii} - \sum_{i=1}^q p_{i.} p_{.i}}{n^2 - \sum_{i=1}^q p_{i.} p_{.i}} \quad (8)$$

يجب اختيار حجم العينة لكل فئة بحيث نضمن أن يكون حجم هذه العينة كبيراً كفاية لإنتاج تقدير دقيق وكافٍ لمساحة الصنف.

يمكن حساب حجم العينات الكلي المناسب لأخذ العينات العشوائي والذي يمكن توزيعه بين الفئات المختلفة حسب المعادلات 9 و 10 [15].

$$n = \frac{(\sum W_i S_i)^2}{[(S(\hat{O}))^2 + (\frac{1}{N}) \sum W_i S_i^2]} \approx \left(\frac{\sum W_i S_i}{S(\hat{O})} \right)^2 \quad (9)$$

$$S_i = \sqrt{U_i(1 - U_i)} \quad (10)$$

N هو عدد البكسلات الكلية، $S(\hat{O})$ هو الخطأ المعياري لدقة التقدير الكلية المراد الوصول إليها، W_i هو قسم المساحة الموضوع على الخريطة من الصنف، و S_i هو الانحراف المعياري للطبقة i.

3.4 البرامج والأدوات المستخدمة

- برنامج ArcGIS

تم الاعتماد بشكل أساسي في هذا البحث على برنامج ArcGIS 10.7 المكتبي والمطور من قبل شركة ESRI [16]، وهو عبارة عن برنامج متكامل من برمجيات أنظمة المعلومات الجغرافية. يتكون ArcGIS المكتبي من أربعة تطبيقات متكاملة: ArcMap، ArcCatalog، ArcGlobe و ArcScene. في هذا البحث تم العمل ضمن ArcMap لتشكيل الصور الملونة وقص الصور حسب منطقة الدراسة ومن ثم عرض نتائج النموذج. كما تم إجراء التصنيف المراقب ضمنه بطريقة الاحتمالية العظمى (Maximum likelihood classification) وإجراء تقييم الدقة بالطرق المختلفة.

- مكتبات TensorFlow, Keras, pyrsgis, scikit-learn, numpy

TensorFlow: هي عبارة عن منصة مفتوحة المصدر شاملة للتعلم الآلي وتمثل مكتبة بايثون Python للحساب الرقمي السريع والتي أنشأتها وأصدرتها Google. وهي مكتبة أساسية لإنشاء نماذج التعلم العميق مباشرة أو باستخدام مكتبات مجمعة تبسط العملية المبنية على TensorFlow [17].

Keras: هي مكتبة مفتوحة المصدر توفر واجهة Python للشبكات العصبونية الاصطناعية. وتعمل كواجهة لمكتبة TensorFlow [18]، وقد تم استخدامها لبناء الشبكة العصبونية الاصطناعية للتعلم العميق.

Scikit-Learn: والمعروفة أيضاً باسم sklearn عبارة عن وحدة نمطية (module) للتعلم الآلي مبنية على مكتبة SciPy [19]. وقد تم استخدامها لمعالجة وتحضير البيانات وإجراء تقييم الدقة.

Pyrsgis: هي وحدة نمطية قوية لقراءة البيانات الجغرافية المخزنة بالصيغة المترسية ومعالجتها وتصديرها. وهي مبنية على مكتبة GDAL، وهي فعالة للغاية لتحليلات جغرافية مكانية متعددة [20]. وقد استخدمت لقراءة البيانات المخزنة بالصيغة المترسية من النوع GeoTIFF.

Numpy: هي مكتبة بايثون تستخدم للعمل مع المصفوفات. كما أن لديها وظائف للعمل في مجال الجبر الخطي وتحويل فورييه والمصفوفات. تم إنشاء NumPy في عام 2005 بواسطة Travis Oliphant [21]. وقد استخدمت في العمليات الأساسية التي تجرى على المصفوفات.

- Spyder

هي بيئة تطوير متكاملة مفتوحة المصدر (IDE : integrated development environment) للبرمجة العلمية بلغة Python. يتكامل Spyder مع عدد من الحزم العلمية، مثل: Cython, SymPy, IPython, pandas, Matplotlib, SciPy ، بالإضافة إلى المكتبات المذكورة سابقاً. تم إنشاء وتطوير Spyder في البداية بواسطة Pierre Raybaut في عام 2009، ومنذ عام 2012 تم الحفاظ على Spyder وتحسينه باستمرار من قبل فريق من مطوري Python العلميين [22].

- برنامج eCognition Developer

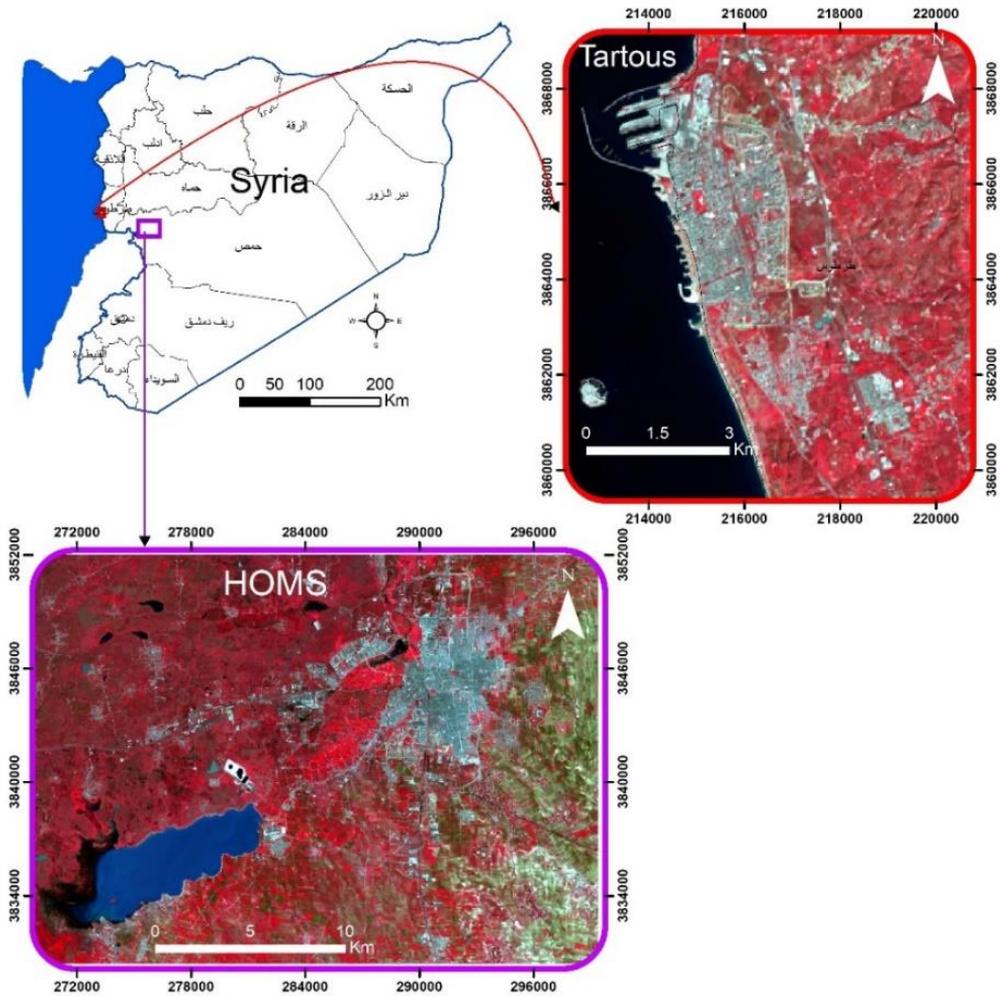
برنامج eCognition هو برنامج مختص بتحليل الصور اعتماداً على الكائن (object based classification)، تم تطويره من قبل الباحث جيرد بينيغ Gerd Binnig الحائز على جائزة نوبل مع مجموعة من الباحثين في شركة Definiens AG عام 2000 م في مدينة ميونخ في ألمانيا. يقوم باستخراج الفئات من الصور من خلال تسلسل هرمي محدد واعتماداً على عناصر الصورة من خصائص اللون، الشكل، النسيج، والحجم للعناصر بالإضافة إلى الخصائص الطيفية وحالة العنصر وعلاقته مع العناصر المجاورة من أجل الحصول على نتائج دقيقة تحاكي التحليل البشري [23].

4 التطبيق العملي

4.1 البيانات المستخدمة في البحث

تم تشكيل صورة ملونة لمدينة حمص (الشكل 4) ضمن برنامج ArcGIS باستخدام الأداة (Composite Bands) بدقة مكانية 15 م من تسع نطاقات من نطاقات القمر الصناعي Landsat 8 (OLI): النطاق الأول ($0.43-0.45 \mu\text{m}$)، المجال الأزرق ($0.45 - 0.51 \mu\text{m}$)، المجال الأخضر ($0.53 - 0.59 \mu\text{m}$)، المجال الأحمر ($0.64 - 0.67 \mu\text{m}$)، مجال الأشعة تحت الحمراء القريبة ($0.85 - 0.88 \mu\text{m}$) والنطاقين السادس ($1.57 - 1.65 \mu\text{m}$) والسابع ($2.11 - 2.29 \mu\text{m}$) للأشعة تحت الحمراء المتوسطة، النطاق البانكروماتي ($0.5 - 0.68 \mu\text{m}$) والنطاق التاسع ($1.36-1.38 \mu\text{m}$).

وتم اقتطاع منطقة الدراسة وفق مدينة حمص اعتماداً على الأداة (Extract by Mask)،
لتصبح الصورة النهائية بأبعاد 21585 x 29925 م وتوسع نطاقات طيفية.
كما تم استخدام صورة ملونة لمدينة طرطوس (الشكل 4) أيضاً مكونة من النطاقات التسع
نفسها لنفس القمر لتطبيق التصنيف بالطرق التقليدية بدايةً ومن ثم تطبيق النموذج المبني
بالشبكات العصبونية عليها لتقييم قدرة النموذج على استخراج المباني من باقي فئات
التصنيف الموجودة في الصورة عن طريق تطبيق معايير الدقة المختلفة.



الشكل 4: منطقة الدراسة والبيانات (صور مركبة ملونة من نوع لاندسات 8 لمدينة حمص وطرطوس معروضة بالتركيبة اللونية التالية: RGB = 5 4 3)

4.2 بناء الشبكة العصبونية الاصطناعية

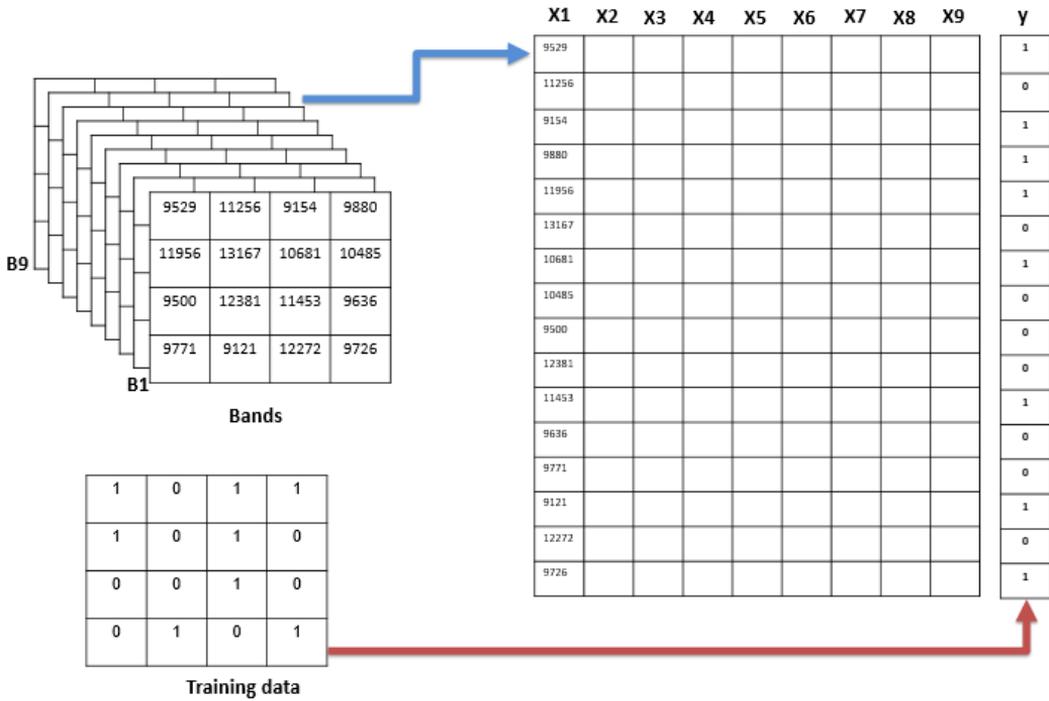
بدأنا ببناء نموذج الشبكة العصبونية الاصطناعية ضمن برنامج Spyder وكتابة النص البرمجي عن طريق مجموعة من المراحل والخطوات (الشكل 5)، في المرحلة الأولى يتم استدعاء كافة المكتبات اللازمة للعمل، ومن ثم تحميل البيانات وقراءة صور لاندسات لمنطقة الدراسة (الصورة الملونة لمدينة حمص المكونة من تسعة نطاقات) عن طريق الوحدة النمطية raster التابعة لـ pyrsgis، حيث تم تشكيل مصفوفة NumPy من صورة الـ GeoTIFF مكونة من الموقع الجغرافي (الإحداثيات) والقيم الرقم الرقمية للبيكسلات (DN).

استخدم التصنيف بالتعلم العميق المراقب، ولذلك اعتمدنا على صورة ثنائية من قيمتين 0 و 1 للدلالة على فئة وجود فئة المباني من عدم وجودها حيث ستكون مهمتها كعينات للتدريب (training data)، تم تحميل هذه الصورة أيضاً وقراءتها، وكان عدد السطور والأعمدة والدقة المكانية (أبعاد البيكسل) هو نفسه تماماً.



الشكل 5: مراحل بناء الشبكة العصبونية الاصطناعية

يتوجب معالجة البيانات وتحويل المصفوفات إلى مصفوفات ثنائية الأبعاد، وهو الشكل الذي تعمل به غالبية خوارزميات تعلم الآلة، حيث يمثل كل صف بكسل والأعمدة هي القيم الرقمية DN لكل نطاق من النطاقات في البكسل. تقوم الوحدة النمطية convert التابعه لـ pyrsgis من خلال changeDimension بهذه المهمة كما هو موضح في (الشكل 6).



الشكل 6: تحويل الصور

تم تحويل الصورة المكونة من 1439 سطر و 1995 عمود إلى 2870805 سجل. عادة ما يتم اختيار أكثر من 50% من البيانات لبناء النموذج، قمنا بتقسيم البيانات 65% من أجل التدريب 35% من أجل الاختبار والتحقق من الصحة وهي نسب قياسية مستخدمة عند بناء نماذج الشبكات العصبونية الاصطناعية، ويلعب عدد سجلات البيانات دوراً مهماً بنسب التقسيم، فإذا كان عددها كبيراً فأى نسبة تقسيم تعمل بشكل جيد ولكن عندما تكون مجموعة البيانات محدودة، فإن نسبة التقسيم قد تلعب دوراً حاسماً.

تعمل معظم خوارزميات التعلم الآلي بما في ذلك الشبكات العصبونية ANNs على بيانات طبيعية، حيث قمنا في هذه المرحلة بتحويل البيانات وتقييسها من 0 إلى 1. يمكن تحقيق التطبيع أو ما يسمى بالتقييس بطرح قيمة الحد الأدنى من قيمة البيكسل والقسمة على الفرق بين الحد الأدنى والأعلى. بما أن الدقة الراديومترية لصور Landsat 8 المعالجة هي 16 بت، فإن القيم الدنيا والعليا هي 0 و 65535 ($2^{16}=65535$)، وبالتالي تتم عملية التقييس بالقسمة على 65535.

بعد الانتهاء من تحضير البيانات وتطبيعها بدأنا ببناء النموذج باستخدام keras واستخدمنا النموذج المتسلسل sequential لإضافة الطبقات واحدة تلو الأخرى، حيث توجد طبقة إدخال واحدة مع عدد من العقد (العصبونات) يساوي عدد النطاقات (تسع في حالتنا).

يعد تحديد عدد الخلايا العصبونية في الطبقات المخفية جزءاً مهماً جداً من تحديد بنية الشبكة العصبونية الشاملة. على الرغم من أن هذه الطبقات لا تتفاعل بشكل مباشر مع البيئة الخارجية، إلا أن لها تأثيراً كبيراً على المنتج النهائي. لذلك يجب مراعاة كل من عدد الطبقات المخفية وعدد الخلايا العصبونية في كل من هذه الطبقات المخفية بعناية، فاستخدام عدد قليل من الخلايا العصبونية في الطبقات المخفية سيؤدي إلى شيء يسمى نقص في التدريب (Underfitting). كما أن وجود عدد كبير من الخلايا العصبونية في الطبقات المخفية سيؤدي إلى التدرّب المفرط (Overfitting) [24].

يقترح [23] مجموعة من القواعد لاختيار عدد مقبول من العصبونات في الطبقة المخفية:

1- يجب أن يكون عدد الخلايا العصبونية في الطبقة المخفية محصوراً بين حجم

طبقة الإدخال وحجم طبقة الإخراج.

2- يجب أن يكون عدد الخلايا العصبونية المخفية ثلثي (2/3) حجم طبقة

الإدخال بالإضافة إلى حجم طبقة الإخراج.

3- يجب أن يكون عدد الخلايا العصبونية المخفية أقل من ضعف حجم طبقة

الإدخال.

يمكن الاعتماد على واحدة من هذه القواعد الثلاث كنقطة انطلاق وفي النهاية فإن اختيار

بنية الشبكة العصبونية سيعتمد على مبدأ التجربة والخطأ (trial and error).

في المرحلة اللاحقة يجب اختيار تابع التفعيل أو التنشيط (activation function) وهو عبارة عن تابع رياضي ضمن العصبون بين طبقتين من أي شبكة عصبونية. يُعرف أيضاً باسم تابع النقل (transfer function) يتم استخدامه لتحديد ناتج عن طريق مدخل أو مجموعة من المدخلات، وله دور أساسي في التعلم العميق للشبكة العصبونية.

تتيح المكتبة Keras استخدام أنواع مختلفة من توابع التفعيل مثل: relu, sigmoid, softmax, softplus, softsign, tanh, selu, elu, exponential function.

لاختيار توابع التنشيط في الشبكات العميقة تأثير كبير على ديناميكيات التدريب وأداء المهام.

سنقوم فيما يلي بتوضيح أهم توابع التفعيل التي قمنا بتطبيقها والتي أعطت أفضل النتائج. حالياً، أكثر توابع التنشيط نجاحاً والأكثر استخداماً هي الوحدة الخطية المصححة (rectified linear activation function) ReLU [25].

حيث يقوم تابع التفعيل ReLU وبكفاءة عالية بتحويل مدخلات العصبون لناتج يحمل القيمة صفر بحال المدخل سالب أو نفس قيمة المدخل في حال كان موجب (المعادلة (11).



$$\begin{cases} 0 & \text{if } x \leq 0 \\ x & \text{if } x > 0 \end{cases} \\ = \max \{0, x\} = x 1_{x>0} \quad (11)$$

التابع softmax يحول شعاع القيم الحقيقية K إلى شعاع من القيم الحقيقية K التي مجموعها 1. يمكن أن تكون قيم الإدخال موجبة أو سالبة أو صفرية، ويقوم التابع softmax بتحويلها إلى قيم محصورة بين 0 و 1، بحيث يمكن تفسيرهما على أنها قيمة

الاحتمال. إذا كان أحد المدخلات صغيراً أو سالباً، فإن softmax يحوله إلى احتمال صغير، وإذا كان أحد المدخلات كبيراً، فإنه يحوله إلى احتمال كبير، لكنه سيظل دائماً بين 0 و 1 (المعادلة 12).

$$\frac{e^{x_i}}{\sum_{j=1}^J e^{x_j}}$$

for $i = 1, \dots, J$ (12)

مجال القيم لتابع التفعيل tanh يمتد من (-1 إلى 1). وهو أيضاً تابع سيني أو سيغموئيدي (على شكل s). ويسمى أيضاً تابع الظل (المعادلة 13).

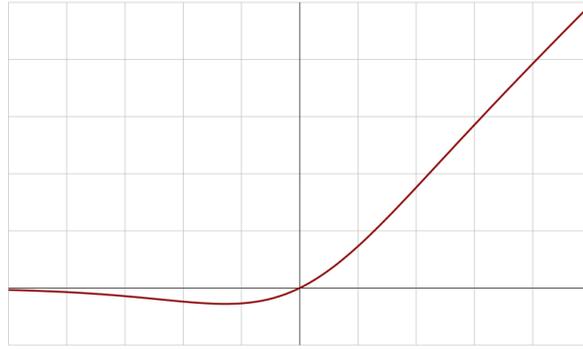


$$f(x) = \tanh x = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (13)$$

يقوم تابع التفعيل Softsign بإعادة تقييس القيم بين -1 و 1 من خلال تطبيق عتبة تماماً مثل وظيفة التابع السيني أو السيغموئيدي (المعادلة 14).

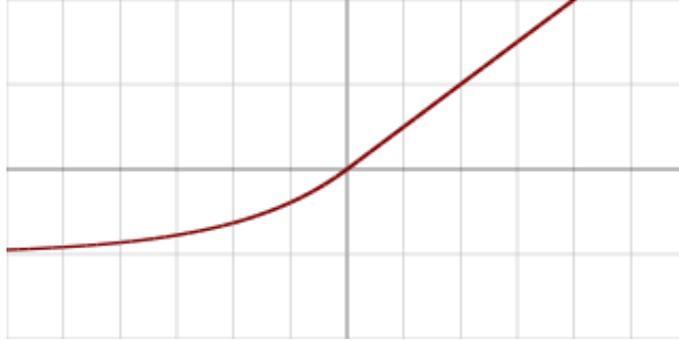
$$\frac{x}{1 + |x|} \quad (14)$$

تابع التفعيل SiLU (Sigmoid Linear Unit) هو تابع تقريب سيغموئيدي خطي تم تقديمه للمرة الأولى عام 2016 [26] (المعادلة 15).



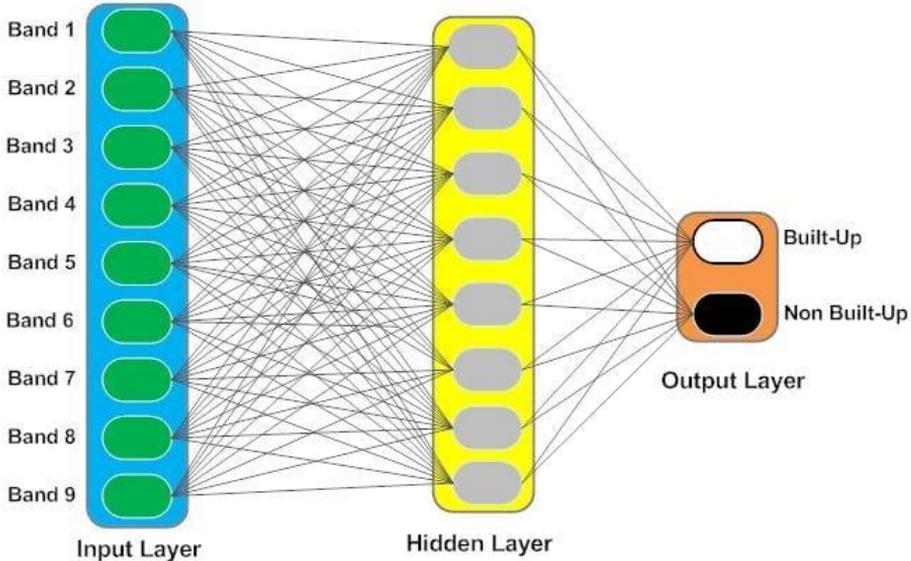
$$f(x) = \frac{x}{1 + e^{-x}} \quad (15)$$

يحاول تابع التفعيل ELU (Exponential linear units) الخطي الأسّي جعل التنشيط المتوسط أقرب إلى الصفر، مما يسرع التعلم. لقد أثبتت بعض الأبحاث أن ELUs يمكنها الحصول على دقة تصنيف أعلى من ReLUs [27] (المعادلة 16).



$$f(x) = \begin{cases} x & \text{if } x > 0, \\ a(e^x - 1) & \text{otherwise,} \end{cases} \quad (16)$$

تحتوي الطبقة النهائية على عقدتين أو عصبونين للدلالة على وجود مباني من عدمه (الشكل 7) مع تابع تفعيل "softmax"، وهذا النوع مناسب عندما يكون الخرج على شكل فئة.



الشكل 7: تمثيل الشبكة مع طبقة مخفية واحدة

التعلم العميق هو عملية تكرارية للغاية، وعلينا أن نحاول العديد من التجارب لتغيير البارامترات في كل مرة لمعرفة أي مجموعة من البارامترات تتوافق مع بعض وتعمل بالشكل الأفضل، فمن المهم أن يتدرب نموذج التعلم العميق في أقصر وقت ممكن. يتم عادة استخدام خوارزميات تحسين (optimizers) أثناء تدريب الشبكة العصبية لتغيير سمات الشبكة العصبونية مثل الأوزان ومعدل التعلم.

تحتوي مكتبة Keras على مجموعة من خوارزميات التحسين (SGD, RMSprop, Adam, Adadelata, Adagrad, Adamax, Nadam, Ftrl) [18].

قمنا في نموذجنا بالاعتماد على خوارزمية (Adaptive Moment Estimation) Adam وهي عبارة عن خوارزمية تحسين معدل التعلم التكيفي مصممة خصيصاً لتدريب الشبكات العصبية العميقة، نُشرت لأول مرة في عام 2014 [28].

اخترنا "sparse_categorical_crossentropy" كتابع للخسارة ويسمى أيضاً تابع التكلفة (loss) وهو تابع وظيفته تقييم مدى جودة نماذج الخوارزمية لمجموعة البيانات الخاصة بنا. فإذا انحرفت التنبؤات كثيراً عن النتائج الفعلية، فسيخرج تابع الخسارة رقماً أعلى، أما إذا كانت قريبة فسيخرج رقماً أقل. بمساعدة خوارزميات التحسين، يتعلم تابع التكلفة تقليل الخطأ في التنبؤ.

قمنا بإجراء عدة تجارب بطبقة واحدة مخفية واحدة وبطبقتين وفي كل مرة تحتوي على عدد مختلف من العصبونات أو العقد، وعدد متنوع من توابع التفعيل التي تتيحها مكتبة .Keras

تم فحص هذه النماذج ومقارنتها من حيث التنبؤ، الكفاءة ودقة النموذج، وقد كانت تتقارب النتائج في بعض الأحيان من أجل توابع تفعيل مختلفة. تكونت الشبكة النهائية التي أعطت أفضل أداء وتم اعتمادها للتنبؤ من ثمانية عصبونات مع تابع تفعيل relu في الطبقة الخفية، ويبين الجدول (2) بعض التجارب التي تنفيذاً وأفضل دقة تم الحصول عليها مع الزمن الازم لتدريب الشبكة والتنبؤ.

الجدول (2): نماذج مختلفة من الشبكات العصبونية مع توابع تفعيل وعدد عصبونات مختلفة

تابع التفعيل	عدد العصبونات	دقة الاسترجاع (Recall)	دقة الصحة (Precision)	زمن التنفيذ بالدقائق والثواني
relu	8	0.905	0.935	7 د 3 ثا
softsign	7	0.908	0.931	7 د 21 ثا
selu	6	0.912	0.931	7 د 50 ثا
elu	10	0.903	0.937	7 د 35 ثا
Softmax	9	0.908	0.912	7 د 5 ثا
tanh	8	0.918	0.928	7 د 4 ثا

آخر مرحلة كانت عملية تنبؤ النموذج لمنطقة جديدة، حيث قمنا بإدخال صورة مدينة طرطوس المكونة من النطاقات التسع ومن 656 سطر و 769 عمود، وتم تحويلهم إلى 504464 سجل. حيث سيتعلم النموذج من خلال عملية التدريب تحديد فيما إذا كان البيكسل يحتوي على مناطق عمرانية أم لا بناءً على القيم الرقمية DN لجميع النطاقات، وبالتالي يتوجب أن تكون الصورة المراد التنبؤ بها متعددة الأطياف وبنفس عدد النطاقات وبنفس الترتيب.

تم الاعتماد بالنتيئة على النموذج المكون من ثلاث طبقات: طبقة إدخال مع تسعة عصبونات وطبقة خفية مع ثمانية عصبونات مع تابع تفعيل relu وطبقة الخرج بعصبونين، وكانت دقة النموذج المبني كالتالي: Precision= 0.935, Recall= 0.905، وكانت مصفوفة الخطأ:

Confusion matrix:

$$\begin{bmatrix} 1070101 & 4645 \\ 7002 & 66574 \end{bmatrix}$$

وتم التنبؤ بالمناطق العمرانية في الصورة من خلال نموذج الشبكة العصبونية الاصطناعية الذي تم اعتماده.

4.3 التصنيف القائم على البيكسل

يكون التصنيف القائم على البيكسل إما غير مراقب فيتم تقسيم الصورة إلى عدد من الفئات Classes على أساس الإحصائيات الداخلية للصورة أو مراقباً بحيث يتم توجيه البرنامج من قبل المستخدم على أساس مجموعة من البيانات المعبرة عن فئات التصنيف المختلفة يطلق عليها عينات التدريب (Training data) يتم إدخالها للبرنامج مسبقاً ويمكنه من خلالها التعرف على الفئات المختلفة داخل الصورة.

هناك العديد من المناهج التي يتم اتباعها عند التصنيف المراقب منها الطرق الإحصائية وهي الأكثر استخداماً، الطرق غير الإحصائية والطرق الهندسية التي تعمل على الفصل بين الفئات التصنيفية بسطوح هندسية.

يعتبر التصنيف بطريقة الاحتمالية العظمى (Maximum Likelihood Classification) من أكثر التصنيفات شيوعاً واستخداماً، وهو عبارة عن تصنيف إحصائي تعتمد خوارزميته على منحنيات التوزيع التكرارية (Histogram) للنطاقات ذات التوزيع الطبيعي وعلى قاعدة قرار الاحتمال الأعظمى المستندة على مبدأ الاحتمالات أو ما يسمى بتصنيف بايز Bayes Classification [29].

تمت عملية التصنيف بطريقة الاحتمالية العظمى لصورة مدينة طرطوس ضمن برنامج ArcGIS، حيث تم تصنيف المنطقة إلى مناطق مبنية ومناطق غير مبنية وذلك اعتماداً على مجموعة من عينات التدريب وتم التأكد من العينات وتقييمها قبل البدء بعملية التصنيف.

بعد ذلك، تم فصل المناطق العمرانية عن غيرها عن طريق الأداة (Raster Calculator) عن طريق عبارة شرطية تنفذ عملية منطقية ينتج عنها صورة ثنائية: تمثل القيم 1 المناطق العمرانية والقيم 0 باقي الفئات.

4.4 التصنيف القائم على الكائن

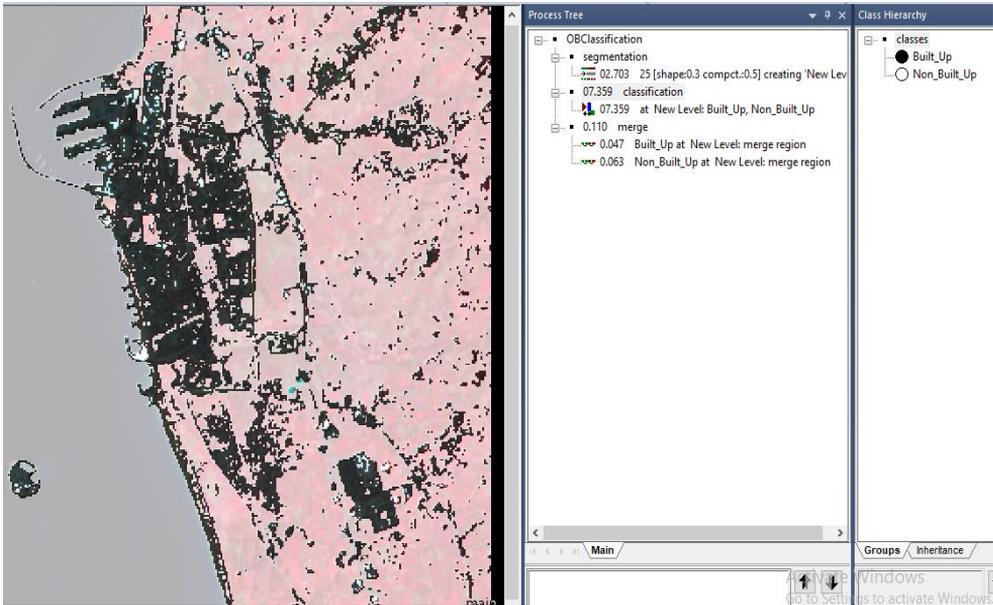
تم تطبيق التصنيف اعتماداً على الكائن على صورة مدينة طرطوس ضمن برنامج eCognition Developer. يعتمد مبدأ العمل على إنشاء تسلسل محدد لتنفيذ التصنيف من خلال (process tree) وهو عبارة عن برنامج نصي يتحكم في العمليات (الخوارزميات) التي يتم تشغيلها وترتيب تنفيذها.

يعتبر التقسيم أو التجزئة (Segmentation) الخطوة الأولى في عملية التصنيف اعتماداً على الكائن، وهو يقوم بإنشاء كائنات أو عناصر الصورة التي سيتم تنفيذ عملية التصنيف بناءً عليها. يتمثل الجزء المهم في عملية التجزئة في تحديد الكائنات التي تمثل السمات التي نرغب في تصنيفها والتي تكون مميزة حسب خصائص محددة مثلاً القيم الطيفية والشكل والنسيج. تم استخدام التقسيم مختلف الدقة (Multiresolution segmentation) مع تحديد معامل المقياس (Scale Parameter) بـ 25 للحصول على عناصر متوسطة الحجم، حيث يتحكم هذا المعامل في مقدار التباين الطيفي داخل الكائنات وبالتالي حجمها الناتج وكلما كانت قيمته أكبر كلما كان حجم العناصر أكبر والعكس صحيح، وقد اعتمد الكثير من الباحثين وفي العديد من الدراسات التطبيقية على نهج التجربة والخطأ لاختيار معامل المقياس المناسب لعملية التصنيف واستخراج كائنات الصورة [30] [31].

تم اختيار قيمة معامل الشكل (Shape) مساوية لـ 0.3 ويمثل هذا المعامل توزيع بين شكل الكائنات ولونها الطيفي، حيث إذا كانت قيمته 0، يتم أخذ اللون بالاعتبار فقط بينما إذا كانت قيمته أكبر من 0 يتم أخذ شكل الكائنات بعين الاعتبار مع اللون وكلما زادت القيمة زادت أهمية أخذ الشكل بالاعتبار، وتم تعيين قيمة معامل الاكتناز (Compactness) بـ 0.5 وهو عبارة عن معامل توزيع لتمثيل انضغاط الأشياء المتكونة أثناء التجزئة.

تم فيما بعد وكمرحلة أساسية ثانية تنفيذ التصنيف بطريقة الجار الأقرب (Nearest neighbour classification) على الصورة المجزأة وبالاعتماد على متوسط القيم

الرقمية للبيكسلات لكافة النطاقات، ويوضح (الشكل 8) آلية العمل ضمن برنامج eCognition من خلال ثلاث نوافذ، الأولى توضح فئات التصنيف المطلوبة والمتمثلة بفئة المناطق المبنية وفئة المناطق غير المبنية، وتبين النافذة الثانية شجرة المعالجة وترتيب العمليات والخوارزميات المختلفة ابتداءً من عملية التقسيم، ومن ثم التصنيف وانتهاءً بعملية دمج الكائنات الناتجة، وتظهر النافذة الثالثة النتيجة النهائية لعملية التصنيف .

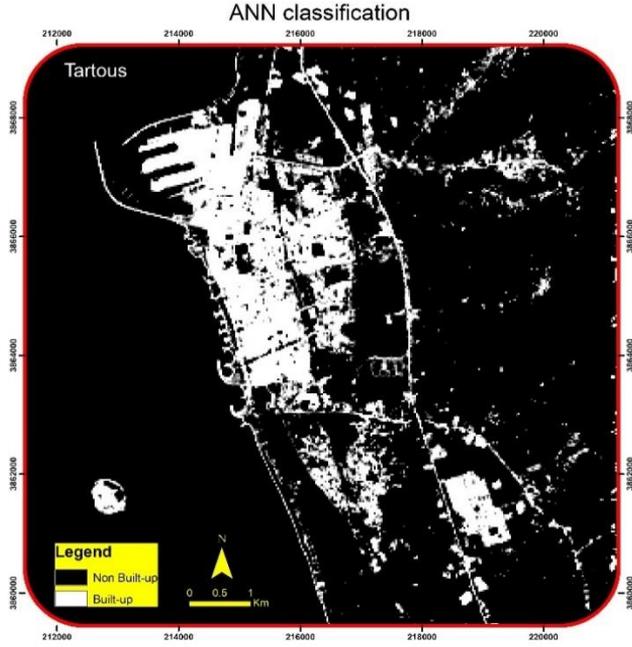


الشكل 8: التصنيف القائم على الكائن في برنامج eCognition

4.5 مقارنة طرق التصنيف الثلاثة

قمنا بتصدير النتائج النهائية من برنامج eCognition وبرنامج Spyder إلى برنامج ArcGIS لعرضها وتقييم دقة النتائج.

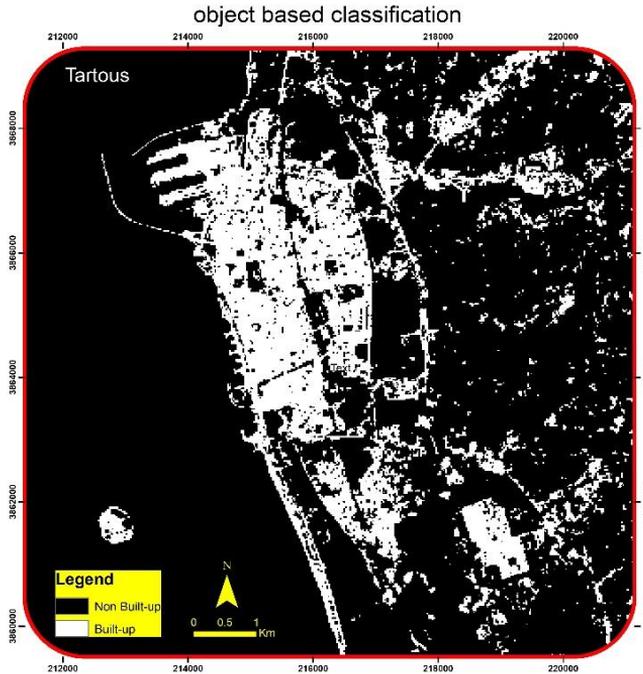
ويوضح الشكل 9 نتيجة التصنيف بالشبكات العصبونية الاصطناعية، الشكل 10 نتيجة التصنيف اعتماداً على البيكسل ومن خلال خوارزمية الاحتمالية العظمى، والشكل 11 النتيجة اعتماداً على التصنيف القائم على الكائن.



الشكل 9: نتيجة التصنيف بالشبكات العصبونية الاصطناعية



الشكل 10: ، التصنيف اعتماداً على البيكسل ومن خلال خوارزمية الاحتمالية العظمى.



الشكل 11: نتيجة التصنيف اعتماداً على التصنيف القائم على الكائن

لمقارنة نتائج الطرق الثلاثة قمنا بتقييم دقة النتائج عن طريق حساب الدقة الكلية، دقة المستخدم، دقة المنتج ومعامل كابتا، حيث قمنا بداية بتعيين عدد العينات اللازم لتقييم الدقة اعتماداً على معادلة Cochran [15]، ويوضح الجدول 3 آلية حساب عدد العينات اللازم لتقييم الدقة استناداً الى وزن كل منطقة حسب مساحتها ودقة المستخدم المتوقعة، مع خطأ معياري مختار للدقة الكلية مساوي لـ 0.01، حيث كان عدد النقاط اللازم لتقييم الدقة 196 عينة.

الجدول 3: حساب عدد العينات لتقييم الدقة

	Not Built-up	Built-up	Total
Area in pixel	440114	64350	504464
Wi (mapped proportion)	0.8724	0.1276	
Ui (expected user's accuracy)	0.98	0.98	
Si (standard deviation)	0.14	0.14	
Wi*Si	0.1221	0.0179	0.14
		SE overall accuracy	0.01
		Total numbers of samples	196

تم تقييم الدقة وبناء مصفوفة الخطأ للطرق الثلاثة المستخدمة ضمن برنامج ArcGIS وقد تم الاعتماد على 196 نقطة من البيانات الحقلية، يتم تقييم الدقة ضمن برنامج ArcGIS على مرحلتين: نقوم بالمرحلة الأولى بإعداد جدول يحتوي عينات التدريب الحقيقية وما يقابلها من الطبقة المصنفة عن طريق الأداة (Create Accuracy Assessment) (Points

لإعداد الجدول اللازم وبالإستعانة بالأداة (Extract Values to Points) لاستخراج القيم الموافقة من الطبقات المصنفة بالطرق الثلاثة، ونقوم بالمرحلة الثانية بحساب مصفوفة الخطأ ومعايير تقييم الدقة عن طريق الأداة (Compute Confusion Matrix) ويظهر الجدول 4 النتائج وقيم الدقة المختلفة للطرق الثلاث.

بمقارنة قيم الدقة المختلفة في الجدول يظهر تفوق طريقة الشبكات العصبونية الاصطناعية بدقة كلية أكبر من 93% ، دقة مستخدم 89%، دقة منتج 98% ومعامل كبا 0.87، تليها طريقة التصنيف اعتماداً على الكائن بدقة كلية مساوية لـ 91% ، دقة مستخدم 87% ، دقة منتج 96% ومعامل كبا 0.83، بينما كانت نتائج تقييم الدقة بطريقة التصنيف القائم على البيكسل بخوارزمية الاحتمالية العظمى مساوية لـ 86% ، دقة مستخدم 81% ، دقة منتج 89% ومعامل كبا 0.71.

الجدول 4: تقييم الدقة بالطرق الثلاث

الطريقة	الدقة الكلية	دقة المستخدم	دقة المنتج	معامل كبا
الشبكات العصبونية	0.93	0.89	0.98	0.87
التصنيف القائم على الكائن	0.91	0.87	0.96	0.83
طريقة الاحتمالية العظمى	0.86	0.81	0.89	0.71

5 الاستنتاجات والتوصيات

أثبتت المنهجية المقدمة للتعلم العميق بالشبكات العصبونية الاصطناعية أفضليتها على باقي الطرق التقليدية في عملية التصنيف واستخراج فئة محددة تمثلت بالمناطق العمرانية في هذا البحث، الأفضلية كانت بدقة المنتج النهائي وبالجهد والوقت الذي وفرته عند التنبؤ لمنطقة جديدة، فكما نعلم كافة طرق التصنيف المراقب تحتاج لعينات تدريب كمرحلة أولى

وهي خطوة تحتاج الوقت والجهد في جمع العينات وفي تشكيل ملف البصمة الطيفية، ويعتمد الوقت والجهد في هذه المرحلة على خبرة الباحث وعلى منطقة الدراسة وطبيعتها وأيضاً اتساعها، في حالة التعلم العميق بالشبكات العصبونية الاصطناعية تكون هذه الخطوة ضمنية عند بناء النموذج ولا داعي لتكرارها عند التنبؤ لمنطقة جديدة وبالتالي يكون وقت التنفيذ هو الوقت الكافي لتدريب الشبكة والتنبؤ فقط، وفي حالتنا كان الوقت لا يتجاوز 8 دقائق لتدريب شبكة مكونة من 2870805 سجل والتنبؤ لمنطقة جديدة تحوي 504464 سجل، علماً أن مواصفات الحاسب تلعب دوراً مهماً في زمن المعالجة، وقد تمت الدراسة باستخدام حاسب محمول يتميز بالمواصفات التالية (Dell, 64 bit, Windows 10, Ram: 8 GB, CPU: Intel CoreTM I7, GPU: NVIDIA GeForce GT).

وتجدر الإشارة بأن الدقة المكانية تلعب دوراً مهماً في التعلم العميق ولكن زيادتها ستزيد بشكل كبير من عدد السجلات وبالتالي من زمن تدريب الشبكة ووقت المعالجة. يمكن تطبيق النموذج على أي بيانات مشابهة بالدقة الطيفية ومكونة من نفس عدد النطاقات للصورة الأصلية التي تم بناء النموذج على أساسها، ويجب التنويه الى أنه كان من الممكن اختصار عدد النطاقات الطيفية، حيث قمنا بحساب مصفوفة الارتباط (correlation matrix) ودراسة الترابط بين هذه النطاقات، وكان الترابط كبير بين النطاق الأول والثاني حوالي 98%، فكان من الممكن الاستغناء عن أحد النطاقين ولكن بما أن الدقة المكانية للبيانات المستخدمة متوسطة فضلنا استخدام كامل النطاقات، باستثناء النطاقين الحاربيين الذين يملكان قيم عالية من الانعكاس لكل الظواهر تقريباً، وبذلك تم الاعتماد على الدقة الطيفية بشكل كامل لتحسين دقة الكشف. استخراج المناطق العمرانية من صور متوسطة الدقة المكانية كصور لاندسات لا يعطي دقة كافية للتعامل على مستوى الأبنية والعقارات، لذلك نوصي بتطوير المنهجية المقدمة وتطبيقها على بيانات عالية الدقة المكانية ودراسة تأثير أهمية الدقة المكانية والدقة الطيفية على استخراج حدود المباني.

- [1] Mahmon, Nur Anis, and Norsuzila Ya'acob. "A review on classification of satellite image using Artificial Neural Network (ANN)." 2014 IEEE 5th Control and System Graduate Research Colloquium. IEEE, 2014.
- [2] Atkinson, Peter M., and Adrian RL Tatnall. "Introduction neural networks in remote sensing." *International Journal of remote sensing* 18.4 (1997): 699-709.
- [3] Kussul, Nataliia, et al. "Deep learning classification of land cover and crop types using remote sensing data." *IEEE Geoscience and Remote Sensing Letters* 14.5 (2017): 778-782.
- [4] Bruzzone, Lorenzo, and Diego Fernández Prieto. "Unsupervised retraining of a maximum likelihood classifier for the analysis of multitemporal remote sensing images." *IEEE Transactions on Geoscience and Remote Sensing* 39.2 (2001): 456-460.
- [5] Gupta, Neha, and H. S. Bhadauria. "Object based information extraction from high resolution satellite imagery using eCognition." *International Journal of Computer Science Issues (IJCSI)* 11.3 (2014): 139.
- [6] Analytic Svidhya, 2020. [Online]. Available: <https://www.analyticsvidhya.com/blog/2020/02/cnn-vs-rnn-vs-mlp-analyzing-3-types-of-neural-networks-in-deep-learning/>. [Accessed: 15-january-2020].
- [7] Braspenning, Petrus J., Frank Thuijsman, and Antonius Jozef Martha Maria Weijters. *Artificial neural networks: an introduction to ANN theory and practice*. Vol. 931. Springer Science & Business Media, 1995.
- [8] Darwishe, Hanan, et al. "Prediction and control of nitrate concentrations in groundwater by implementing a model based on GIS and artificial neural networks (ANN)." *Environmental Earth Sciences* 76.19 (2017): 649.
- [9] Kasabov, Nikola K. *Foundations of neural networks, fuzzy systems, and knowledge engineering*. Marcel Alencar, 1996.
- [10] Russell, Stuart J., and Peter Norvig. "Artificial Intelligence-A Modern Approach, Third International Edition." (2010): I-XVIII.

- [11] Hinton, Geoffrey E., Terrence Joseph Sejnowski, and Tomaso A. Poggio, eds. Unsupervised learning: foundations of neural computation. MIT press, 1999.
- [12] Kaelbling, Leslie Pack, Michael L. Littman, and Andrew W. Moore. "Reinforcement learning: A survey." Journal of artificial intelligence research 4 (1996): 237-285.
- [13] Powers, David MW. "Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation." arXiv preprint arXiv:2010.16061 (2020).
- [14] Foody, Giles M. "Status of land cover classification accuracy assessment." Remote sensing of environment 80.1 (2002): 185-201.
- [15] Cochran, W. G., 1977. Sampling techniques. John Wiley & Sons.
- [16] ESRI, "Environmental Systems Research Institute," 2020. [Online]. Available: <https://www.esri.com>. [Accessed: 05-january-2020].
- [17] Tensorflow, 2021. [Online]. Available: <https://www.tensorflow.org> [Accessed: 05-january-2021].
- [18] keras, 2021. [Online]. Available: <https://keras.io> [Accessed: 05-january-2021].
- [19] Scikit-learn, 2021. [Online]. Available: <https://scikit-learn.org> . [Accessed: 05-january-2021].
- [20] Pyrgis, 2021. [Online]. Available: <https://pypi.org/project/pyrgis>. [Accessed: 05-january-2021].
- [21] numpy, 2021. [Online]. Available: <https://numpy.org> [Accessed: 05-january-2021].
- [22] spyder, 2021. [Online]. Available: <https://www.spyder-ide.org> [Accessed: 05-january-2021].
- [23] Geospatial trimble, 2021. [Online]. Available: <https://geospatial.trimble.com/products-and-solutions/ecognition> [Accessed: 05-january-2021].
- [24] Heaton, Jeff. Introduction to neural networks with Java. Heaton Research, Inc., 2008.
- [25] Ramachandran, Prajit, Barret Zoph, and Quoc V. Le. "Searching for activation functions." arXiv preprint arXiv:1710.05941 (2017).

- [26] Hendrycks, Dan, and Kevin Gimpel. "Gaussian error linear units (gelus)." arXiv preprint arXiv:1606.08415 (2016).
- [27] Clevert, Djork-Arné, Thomas Unterthiner, and Sepp Hochreiter. "Fast and accurate deep network learning by exponential linear units (elus)." arXiv preprint arXiv:1511.07289 (2015).
- [28] Kingma, Diederik P., and Jimmy Ba. "Adam: A method for stochastic optimization." arXiv preprint arXiv:1412.6980 (2014).
- [29] Richards, John A., and J. A. Richards. Remote sensing digital image analysis. Vol. 3. Berlin: Springer, 1999.
- [30] Ma, Lei, et al. "A review of supervised object-based land-cover image classification." ISPRS Journal of Photogrammetry and Remote Sensing 130 (2017): 277-293.
- [31] El-naggar, Aly M. "Determination of optimum segmentation parameter values for extracting building from remote sensing images." Alexandria engineering journal 57.4 (2018): 3089-3097.