

Evaluating the Accuracy of Classification and Statistical Comparisons in the Qualitative Determination of Land Use in Al-Ahsa Oasis with Geographic Information Systems Technology

Nashmiah Saud Awad Al Hujuri * 

Department of Geography, College of Arts, King Faisal University, Al-Ahsa, Kingdom of Saudi Arabia

Received: 27/6/2024
Revised: 2/9/2024
Accepted: 29/9/2024
Published online: 1/9/2025

* Corresponding author:
nalhujuri@kfu.edu.sa

Citation: Al Hujuri, N. S. A. (2025). Evaluating the Accuracy of Classification and Statistical Comparisons in the Qualitative Determination of land use in Al-Ahsa Oasis with Geographic Information Systems Technology. *Dirasat: Human and Social Sciences*, 53(2), 8052.
<https://doi.org/10.35516/Hum.2025.8052>

Abstract

Objectives: The study aimed to examine performing cell-based classification (PBC), and objective-based classification (OBC) of space visuals within digital environments of geographic technologies, as well as a statistical comparison between the machine learning algorithms used, and to evaluate their accuracy in classifying categories/qualifying the use of Land (LU) for the purpose of producing qualitative maps with high accuracy that can be relied upon in applied studies and development planning projects.

Methods: The study relied on a quantitative analytical approach in collecting and analyzing its data, using Geographic Information Systems (GIS) technology. And applying machine learning algorithms. This is done on a random sample in the category-based classification and the application of evaluating the validity of the classification.

Results: Applying objective-based classification (OBC) is very effective in urban and similar environments, with the overall accuracy reaching 92.72%, and the Kappa coefficient value reaching 89.86%. The results of the statistical comparison between machine learning algorithms (partial accuracy assessment) for mapping cover/land use also showed that the water category was 100%, followed by the agricultural land category at 98.2%, then the vacant land category at 95.6%, while urbanization recorded a rate of 90.8%.

Conclusions: The guidance in choosing the appropriate algorithm to improve classification accuracy is due to some controls that must be taken into account, the most important of which is determining the category to be classified, and the study may represent a model applicable to similar urban environments.

Keywords: Land cover; urban changes; development planning; machine learning; GIS; Al-Ahsa Oasis

تقييم دقة التصنيف والمقارنات الإحصائية في التحديد النوعي لاستخدام الأرض في واحة الأحساء بتقنية نظم المعلومات الجغرافية

نشمية سعود عوض الحجوري*

قسم الجغرافيا، كلية الآداب، جامعة الملك فيصل، الأحساء، المملكة العربية السعودية

ملخص

الأهداف: هدفت الدراسة إلى فحص منهجية أداء التصنيف القائم على الخلية، إلى جانب التصنيف القائم على الهدف للمربعات الفضائية داخل البيانات الرقمية للتقنيات الجغرافية، وكذلك المقارنة الإحصائية بين خوارزميات التعلم الآلي المستخدمة، وتقييم دقتها في تصنيف الفئات/التحديد النوعي لاستخدام الأرض بغرض إنتاج خرائط نوعية ذات دقة عالية يمكن الاعتماد عليها في الدراسات التطبيقية ومشروعات التخطيط التنموي.

المنهجية: اعتمدت الدراسة على المنهج التحليلي الكمي في جمع وتحليل بياناتها، وذلك بالاعتماد على الصورة الفضائية للقرم الصناعي Sentinel-2B متعددة الأطياف بتقنية نظم المعلومات الجغرافية (GIS). وتطبيق خوارزميات التعلم الآلي من خلال أساليب التصنيف المراقب، والتصنيف غير المراقب. وذلك على عينة عشوائية في التصنيف القائم على الفئة وتطبيق تقييم صحة التصنيف.

النتائج: إن تطبيق التصنيف القائم على الهدف (OBC) على المربعات الفضائية متعددة الأطياف فعال للغاية في البيانات الحضرية والبيئات المماثلة، حيث بلغت الصحة الشاملة 92.72%، وبلغت قيمة معامل كاي 89.86%. كما بينت نتائج المقارنة الإحصائية بين خوارزميات التعلم الآلي (تقييم الدقة الجزئية) لرسم خرائط الغطاء/الاستخدام الأرضي أن فئة المياه 100%، تليها فئة الأراضي الزراعية 98.2%، ثم فئة الأراضي الفضاء 95.6%، بينما سجلت العمران نسبة 90.8%. كما أظهرت نتائج الدراسة أن التصنيف غير المراقب باستخدام خوارزمية الايزو كلاستر ISO Cluster هي نتائج غير مرضية من خلال القيم الإحصائية التي جاءت بها دقة الصحة الشاملة ومعامل كاي.

الخلاصة: إن التوجيه باختيار الخوارزمية المناسبة لتحسين دقة التصنيف يعود إلى بعض الضوابط التي يجب مراعاتها أهمها تحديد الفئة المراد تصنيفها، وإن الدراسة قد تمثل نموذجاً قابلاً للتطبيق على البيانات الحضرية المشابهة. الكلمات الدالة: الغطاء الأرضي، التغيرات الحضرية، التخطيط التنموي، التعلم الآلي، التصنيف، استخدام الأرض، واحة الأحساء، نظم المعلومات الجغرافية.



© 2026 DSR Publishers/ The University of Jordan.

This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY-NC) license
<https://creativecommons.org/licenses/by-nc/4.0/>

1. المقدمة:

ساهمت المراثيات الفضائية في دعم الدراسات الجغرافية الحديثة كأحد أهم مصادر البيانات، وفاقته الدراسة الميدانية في اختصار الوقت والكلفة، مما خلق وفرة هائلة في الكثير من البيانات الرقمية من خلال الأجيال الجديدة من الأقمار الصناعية وتنوع خصائصها المكانية (الدقة والطيفية) (النطاق)، كما شكل توافق هذه البيانات مع تطبيقات الاستشعار عن بعد ونظم المعلومات الجغرافية دوراً مهماً في تحليل المراثيات والتعامل مع أساليب وخوارزميات التعلم الآلي (Machine learning (ML)، بما يحسن التصنيف الرقمي ويساهم في إنتاج المزيد من الخرائط للمناطق الحضرية وما يطرأ عليها بشكل مستمر من تغيرات. وتعد نتائج التصنيف هي الأساس للعديد من التطبيقات البيئية والاجتماعية والاقتصادية، التي أتاحت المجال لحل كثير من مشكلات التخطيط الحضري ونمو المدن.

هناك حاجة مستمرة إلى دراسة التغيرات الحضرية في استخدام الأرض (Land Uses/Land Caver (LU/LC وتحديث امتدادها المساحي وبياناتها الخرائطية، باعتبار أن المناطق الحضرية هي مراكز للتنمية الاقتصادية والاجتماعية (المجلي، والغامدي، 2017م)، كما يعد نقل واستخلاص البيانات الحضرية من الواقع وتحويلها إلى بيانات رقمية أحد التحديات التي تواجه الجغرافيين وصناع القرار، ولقد لجأت الدراسات الحديثة لمواجهة ذلك نظير ما توفره التقنيات الحديثة من سرعة للقيام بذلك مقابل ما تطلبه تقنيات المسح التقليدي (الميداني) من جهود كبيرة تكلف الكثير من الوقت، لذلك يتم تحسين المراثيات من خلال تطبيق تقنيات أساليب المعالجة المناسبة، للسماح بتفسير أفضل وفقاً لخصائصها والأهداف المراد تحقيقها، وبالتالي رسم خرائط دقيقة تحاكي الواقع (الغامدي، 2007م).

تبرز أهمية الدراسة في تعدد أساليب المعالجة الرقمية لتصنيف مراثيات القمر الصناعي سينتيال 2 (Sentinel-2B)، والمقارنة بين الخوارزميات وصولاً إلى أسلوب التصنيف الأمثل تبعاً للتحديد النوعي لفئات التصنيف المستخدمة؛ والخروج بمنهج خرائطي نوعي دقيق لمنطقة الدراسة، حيث يلعب نوع الخوارزمية المستخدمة لتصنيف المراثيات الفضائية دوراً كبيراً في التأثير على الدقة. وفي العقود الأخيرة، حظي التعلم الآلي (ML) باهتمام كبير نظراً لقوته في تحسين التصنيف، ومن هذا المنطلق: تسعى الدراسة إلى توفير تمرين قابل للتطبيق لتقييم أداء خوارزميات التعلم الآلي في المناطق الجافة وشبه الجافة والبيئات المماثلة.

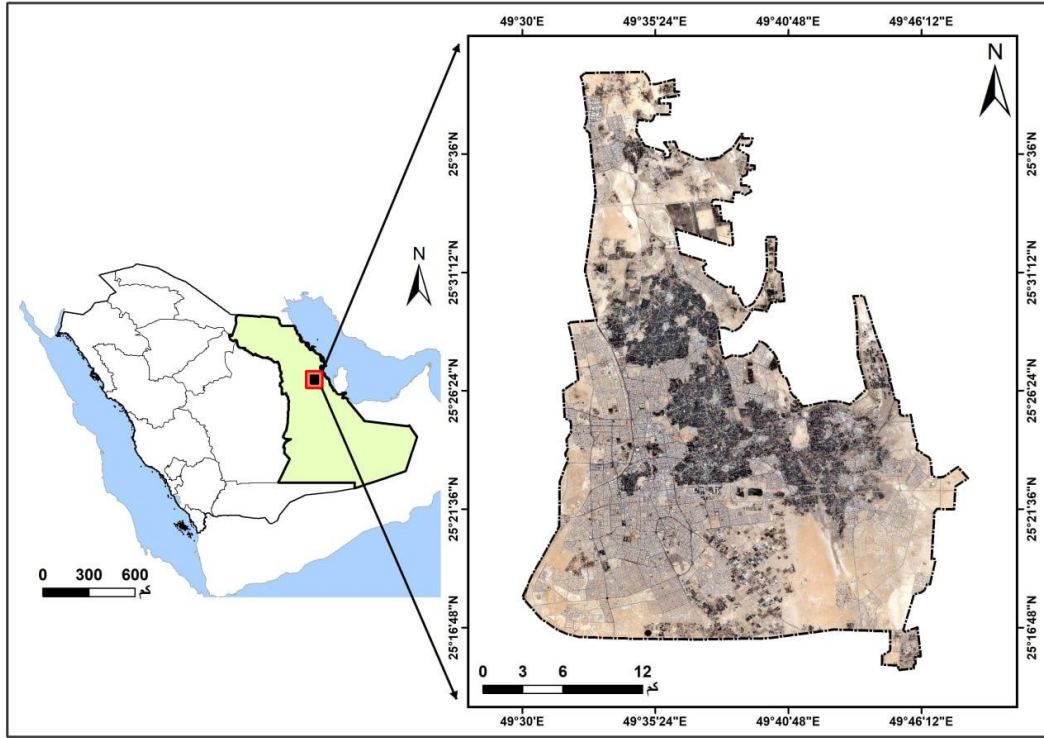
2. المشكلة البحثية:

أصبح تقييم دقة الخرائط الموضوعية الناجمة عن استخدام البيانات الرقمية موضوع بحث مهم، ويمثل تحدياً في ظل العديد من العوامل المؤثرة، مثل المكونات البيئية في منطقة الدراسة، والبيانات المختارة، وأساليب المعالجة والتصنيف، غالباً ما يكون من الصعب تحديد أفضل مصنف بسبب عدم وجود إرشادات لاختيار خوارزميات التصنيف المناسبة، وبالتالي يتم إجراء دراسات مقارنة لمصنفات مختلفة بشكل متكرر، كما إن الظهور المستمر لخوارزميات وتقنيات التصنيف الجديدة في السنوات الأخيرة يستلزم الحاجة إلى توفر مزيد من المراجعة والتطبيق في الواقع، وتقييم النتائج على نطاق محدود لتحسين دقة المنتج وإمكانية رسم الخرائط في مناطق أخرى.

تتلخص مشكلة الدراسة في التساؤلات التالية: أولاً: هل هناك فروق ذات دلالة إحصائية بين أساليب المعالجة و خوارزميات التعلم الآلي في تحسين دقة التصنيف؟ ثانياً: كيف يمكن الحصول على تحديد نوعي دقيق لفئات استخدامات الأرض في المناطق الحضرية باستخدام المراثيات الفضائية لواجهة الأحساء الواقعة في شرق المملكة العربية السعودية؟.

3. منطقة الدراسة:

تقع واحة الأحساء في الشمال الشرقي من محافظة الأحساء، وتمتد فلكياً بين دائرتي عرض شمالاً ($25^{\circ} 15' 0''$ و $25^{\circ} 44' 0''$)، وخطي طول ($21^{\circ} 0'$ و $49^{\circ} 52' 0''$) شرقاً، وتشغل مساحة تقدر بـ 1860 كم² تقريباً الشكل (1). وتعدُّ من أقدم مناطق الاستقرار البشري والحضري في المنطقة الشرقية، كما أن النمو السكاني المتزايد وما يتبعه من توسع وتمدد عمراني، ساعد على تلاحم بعض المدن؛ مثل: مدينتي الهفوف والمبرز، وهما ما يعرف بـ "حاضرة الأحساء" في الوقت الحاضر (المبارك، والحاجي، 2019م). اعتمدت الدراسة في حدودها المكانية على حد منطقة حماية التنمية لواجهة الأحساء، وهي المساحة المساندة للتنمية العمرانية والموضحة في خرائط وثائق النطاق العمراني للتنمية حتى 1450 هـ (وزارة الشؤون البلدية والقروية والإسكان، 2015م)، وتعتمد الضوابط المبنية لهذا الحد على التجمعات البشرية وتركزها؛ لذا يمتد نطاق حد حماية التنمية متماسكاً مع الحدود الطبيعية للواجهة لكونها تشكل 85% من التجمعات السكانية من كامل المحافظة، ويزيد إلى أبعد منها وفقاً لضوابط محددة (وزارة الشؤون البلدية والقروية والإسكان، 2015م).



الشكل (1): موقع منطقة الدراسة بالمنطقة الشرقية من المملكة العربية السعودية

المصدر: الباحثة اعتماداً على بيانات وزارة الشؤون البلدية والقروية والإسكان (2021م).

4. أهداف البحث:

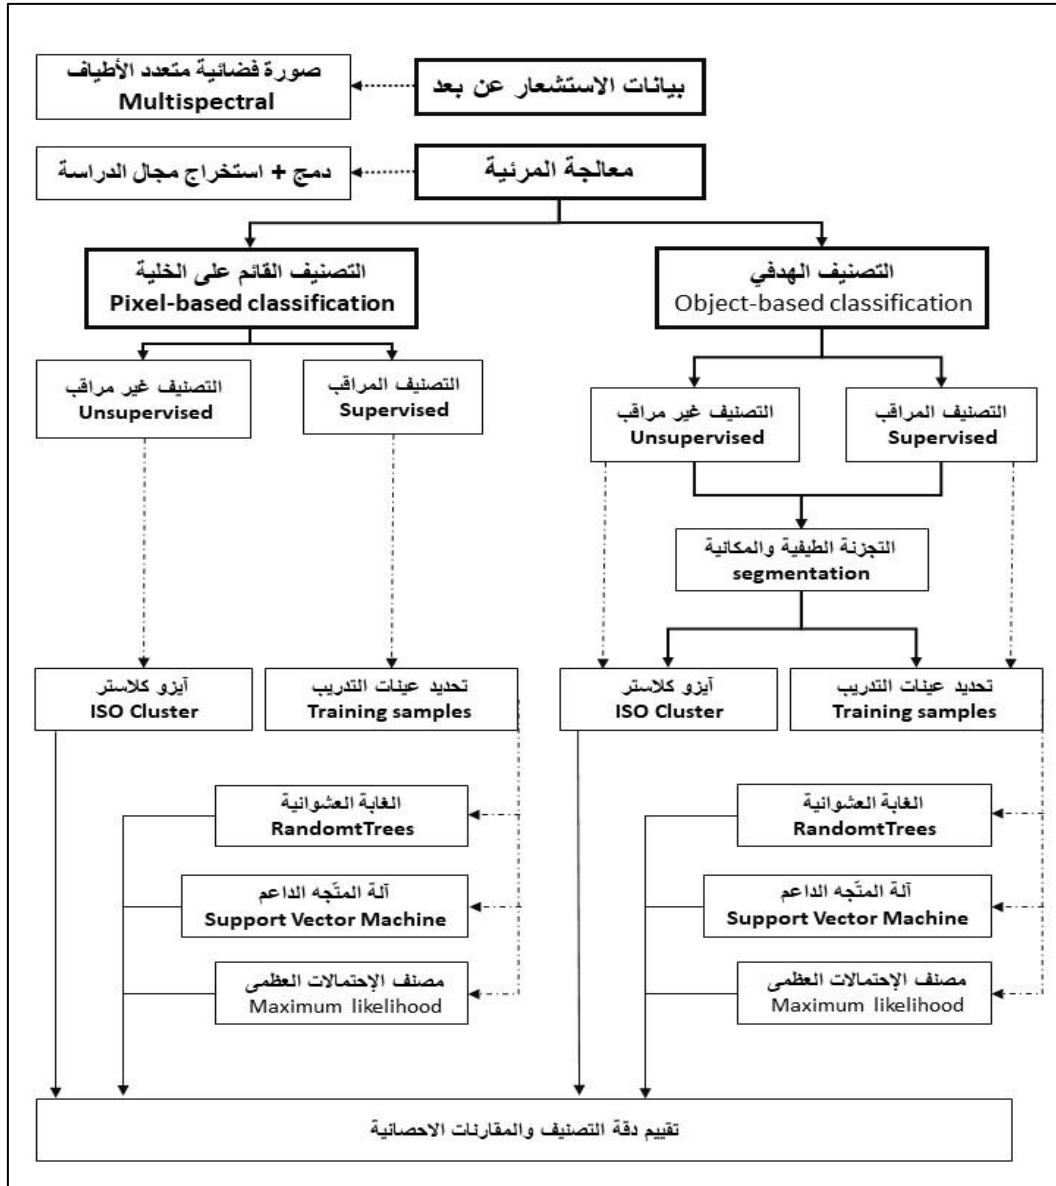
تهدف الدراسة إلى تحقيق التالي:

- فحص منهجية أداء التصنيف القائم على الخلية Pixel-based classification (PBC) ، إلى جانب التصنيف القائم على الهدف Object-based classification (OBC) للمرتبات الفضائية داخل البيئات الرقمية للتقنيات الجغرافية.
- المقارنة الإحصائية بين خوارزميات التعلم الآلي المستخدمة، وتقييم دقتها في تصنيف الفئات/التحديد النوعي لاستخدام الأرض/الغطاء الأرضي (LU/LC).
- إنتاج خرائط نوعية لمنطقة الدراسة ذات دقة عالية تدعم صناع القرار في مشروعات التخطيط التنموي.

5. منهجية البحثية ومصادرها وأدواتها:

1-5 منهج الدراسة:

اعتمدت الدراسة على المنهج التحليلي الكمي، وذلك بتطبيق الطرق التجريبية على متغيرات الدراسة ووصفها وصفاً كمياً بعد إجراء الحسابات والقياسات ضمن مراحل متعددة من المعالجات والتحليلات الخاصة بما يحقق إمكانية المقارنة بينهما للوصول إلى أفضل نتائج ممكنة، باستخدام برمجيات نظم المعلومات الجغرافية (GIS)، تركز هذه الدراسة بشكل رئيسي على توظيف التقنيات الجغرافية في التعامل مع بياناتها من خلال استخدام مرتبات فضائية عالية الوضوح المكاني والطيفي، كما أنها توفر تميزاً قابلاً للتطبيق على المزيد من البيئات الحضرية الجافة وشبه الجافة، كما استعانت الدراسة على العمل الميداني للمراجعة والاستدلال في كلا المراحل الأولى والنهائية (Tilahun and Teferie, 2015)، وتضمنت الدراسة مجموعه من الإجراءات المنهجية لتحقيق أهدافها كما يوضح شكل (2).



الشكل (2): مخطط تدفق المنهجية المتبعة في الدراسة.

2-5 مصادر جمع البيانات:

اعتمدت الدراسة على صورة فضائية للقمر الصناعي Sentinel-2B متعددة الأطياف، بدقة مكانية 10 متر، بتاريخ 2023/07/16م، وعلى النطاق الطيفي المرئي ونطاق الأشعة القريبة من الحمراء Band 1,2,3,8 (BGR,NIR) (وكالة الفضاء الأوروبية، 2023م)، كما تم عمل التصحيح الهندسي لها. استخدمت الدراسة تطبيقات الاستشعار عن بعد من خلال برنامج نظم المعلومات الجغرافية ArcGIS Pro 2.8 في التعامل مع البيانات الرقمية وتحليل الصور الفضائية، اعتمدت على خوارزميات التعلم الآلي التالية:

1. الغابة العشوائية (Random Trees (RT).

2. خوارزمية الاحتمالات العظمى (Maximum Likelihood (MLC).

3. خوارزمية الآلة المتجهة الداعم (Support Vector Machine (SVM، في المصنف القائم على الهدف (Object-based classification (OBC) والمصنف القائم على الخلية (Pixel-based classification (PBC).

وقد طبقت الخوارزميات السابقة من خلال أسلوب التصنيف المراقب Supervised classification، بينما جاء تطبيق خوارزمية الايزو كلاستر ISO Cluster من خلال أسلوب التصنيف غير المراقب Unsupervised classification.

3-5 أدوات وأساليب الدراسة:

تم تحديد واقتطاع منطقة الدراسة من المرئية الفضائية بما يضمن جودة ظهور جميع الخصائص المكانية، والتي ستعتمد عليها الدراسة في العمليات الحسابية للتصنيف، وقد تضمنت الفئات المختارة (الأراضي العمرانية، والأراضي الزراعية، والأراضي الفضاء وفئة المياه) والتي تتفق مع نظام أندرسون لتصنيف الغطاء الأرضي ضمن المستوى الأول (Anderson, et al., 1976)، وهو ما تسعى الدراسة للتقييم الدقة النوعي بين تصنيف الفئات ومدى صحة الأسلوب المتبع والخروج بأفضل النتائج.

يتطلب التعامل مع المراثيات الفضائية معالجات مسبقة تزيد من الرؤية الطيفية للمعالم الأرضية المعنية في الدراسة، ويعد تحليل المركبات الأساسية (Principal Components Analysis (PCA و دمج الصور؛ من أكثر الطرق الشائع استخدامها في المعالجات الرقمية لتحسين المراثيات الفضائية طيفياً ومكانياً (الجعدي، 1430م) وقد طبقت الدراسة على المرئية المستخدمة تقنية تحليل المركبات الأساسية (PCA) والذي يتم العمل عليها من خلال التلاعب في قيم وحدات الخلية للمرئية الأصلية، و غالباً تعد عملية مساعدة في التفسير البصري، كما تعتبر خطوة تمهيدية في اختيار عينات التدريب في التصنيف المراقب Supervised classification، بينما عملية الدمج كانت باستخدام الأداة Composite Bands للخروج بمرئية متعددة الأطياف بدقة مكانية 10م، ويعد ذلك من الخطوات المهمة لتجهيز المرئية الفضائية للتفسير والتحليل (Baroud, 2019).

تم تجميع البيانات من خلال عينة عشوائية طبقية في التصنيف القائم على الفئة وتطبيق تقييم صحة التصنيف (أراضي عمرانية- أراضي زراعية- أراضي فضاء- مياه)، وقد تم الاعتماد في تحديد حجم العينة على معادلة هيربرت أركن (عبد، 2013م):

$$N = \frac{p(1-p)}{\frac{SE}{t} + [p(1-p)/n]}$$

حيث إن:

N : حجم المجتمع

t : الدرجة المعيارية المقابلة لمستوى الدلالة 0.95 وتساوي 1.96

SE : نسبة الخطأ وتساوي 0.05

P : نسبة توفر الخاصية والمحايدة وتساوي 0.50

حيث بلغ حجم عينة التصنيف القائم على الخلية 172 مفردة، وكذلك حجم عينة تقييم صحة التصنيف 1580 مفردة، إذ يحتاج تطبيق تقييم صحة التصنيف إلى تعيين عينات مرجعية ومقارنتها مع الفئات المصنفة، وهناك عدد من الممارسات المستخدمة في اختيار العينات، وقد أشار الميثي والجعدي (2021م) في دراستهما إلى طريقة العينات المنتظمة المكانية، وطريقة العينات العشوائية البسيطة، وطريقة اختيار العينات اعتماداً على المعرفة السابقة من قبل المستخدم، وهو ما اتبعته الدراسة باستخدام المرئية نفسها لمنطقة الدراسة باعتبارها صورة مرجعية، كما أن من خلال الوضوح المكاني العالي الذي تمتاز به يمكن قياس وتقييم صحة التصنيف بشكل جيد.

6. الدراسات السابقة:

تنوعت الدراسات من حيث الأهداف والتطبيق والمنهجية حول استخلاص فئات استخدامات الأرض/الغطاء الأرضي من خلال المراثيات الفضائية، وتحسين الدقة من خلال تصنيف البيانات، قدمت دراسة (Adam et al, 2016) مقارنة بين التصنيف القائم على الخلية والقائم على الهدف، وقد كان أداء النهج القائم على الخلية أفضل قليلاً من النهج القائم على الهدف في تصنيف الغطاء الأرضي لاستخدام الأراضي في الأراضي شبه القاحلة في السودان، وعلى عكس ذلك جاءت دراسة (المجلي والغامدي، 2017م) حيث استخدمت التصنيف الهديفي Objective Classification لاستخلاص الأراضي الفضاء مدينة الرياض، من خلال صور الأقمار الصناعية عالية الوضوح، واتبع الباحثان منهجية تضمنت معالجة البيانات وتمييزها سبع مراحل، وقد نتج من ذلك خرائط موضوعية توضح توزيع الأراضي الفضاء في منطقة الدراسة. كما بلغت صحة التصنيف 84%، وقد استفادت هذه الدراسة من أهم توصياتها والتي توصي بأهمية تطبيق هذا النوع من التصنيف للظواهر الجغرافية البشرية مقارنة بالأنواع الأخرى من التصنيف التي هي أكثر ملاءمة لظواهر البيئة الطبيعية، كما جاءت دراسة (الميثي والجعدي، 2021م) بتقييم أسلوب التصنيف الهديفي لاستخراج المباني من المراثيات الفضائية على جزيرة تاروت، وأُجري التصنيف متعدد المستويات باستخدام خوارزمية شجرة القرار المستندة إلى القواعد Rule Based Decision Tree (RBDT)، وخوارزمية الجار الأقرب Nearest Neighbor في التصنيف الهديفي، وقُورنت نتائج التصنيف مع خوارزميات الاحتمالات العظمى Maximum Likelihood Classifier والمسافة الدنيا للمتوسطات Minimum Distance to Means والأنابيب المتوازية Parallelepiped في المبني على الخلية Pixel، وتظهر نتيجة تقييم التصنيف الهديفي Object-Based Classification أن الصحة الشاملة Overall Accuracy ومعامل كبا Kappa Coefficient بلغت النسبة الأعلى باستخدام خوارزمية الجار الأقرب، بينما بالتصنيف القائم على الخلية جاءت خوارزمية الاحتمالات العظمى أعلى

بكثير من الخوارزميات الأخرى المطبقة في التصنيف ذاته، وأوصت الدراسة بتطبيقه لسهولة تنفيذه، بينما جاءت هذه الدراسة مختلفة عنهما في أنها عملت على توحيد الخوارزميات المطبقة ذاتها في كل أساليب المصنفات، بهدف خلق اتساق متكامل في النتائج والوصول إلى الدقة المثلى بعيداً عن التحيز. كما أن هناك دراسات (Li, et al., 2017; Chen et al., 2018) بحثت أهمية الدمج في تقنيات وأدوات التصنيف، وحاولت الجمع بين التصنيفات القائمة على الخلية و القائمة على الأهداف في استخراج معلومات الغطاء الأرضي من صور الاستشعار عن بعد، موضحة بذلك أن لكل منهم مزاياه وقيوده المتأصلة، واقترحت طريقة تصنيف من خلال الدمج بين الطريقتين؛ حيث يتم تقدير تسميات ونسب فئة البيكسل منخفض الدقة بداخل الأهداف المختلطة عالية الدقة اعتماداً على العلاقات المكانية للخلايا داخل مناطق التقاطع، ومن ثم يمكن تحسين التصنيف وتحديد تفاصيل الغطاءات الأرض بتكامل الطريقتين معاً. أما الدراسات التي استفادت منها هذه الدراسة في اختيار الخوارزميات للمقارنة بينهم، نظراً لعدم وجود إجماع واضح في الأدبيات حول أفضل خوارزمية للتعلم الآلي، فقد جاءت دراسة كل من (Dabija, et al., 2021; Naz, at Abdi, 2020; Maxwell, et al., 2018) مشيرة أنه إذا لم يكن من الممكن اختبار ومعايرة مجموعة متنوعة من المصنفات، يمكن الاعتماد بالمقارنة والتطبيق على أداء الخوارزميات الغابة العشوائية (RF) وآلة المتجهة الدعم (SVM)، إذا تبدو بشكل عام طرق تصنيف موثوقة، كما تعد من أكثر خوارزميات التعلم الآلي استخداماً وفعالية، لإنتاج خرائط الغطاء الأرضي، كما أن سهولة تنفيذ الخوارزميات المستخدمة تجعل إعادة إنتاج النتائج ممكنًا وقابلًا للمقارنة.

7. المناقشة وتحليل النتائج:

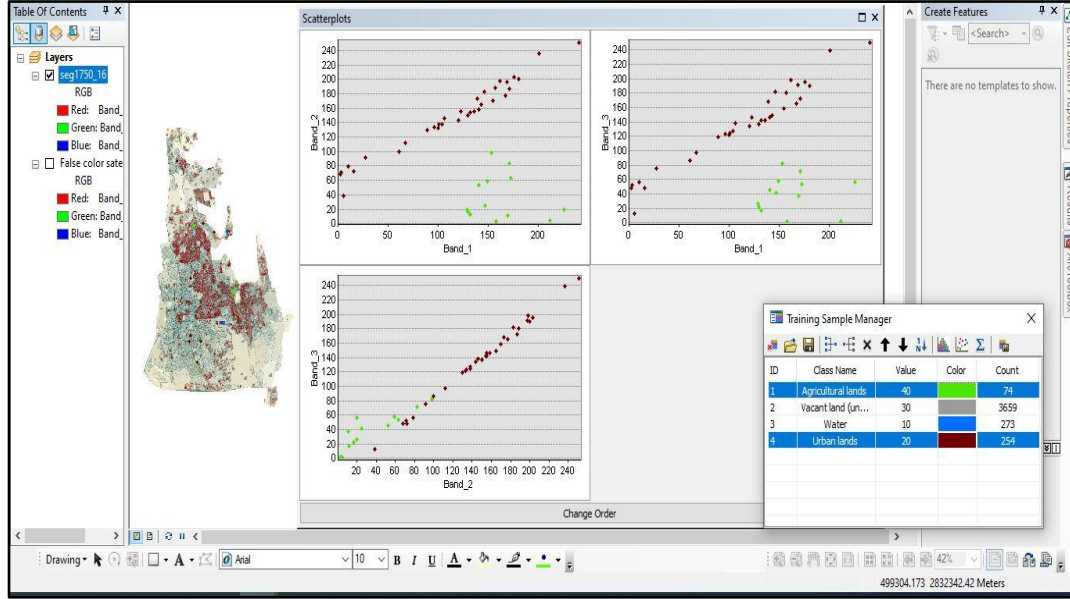
1-7 التصنيف Classification:

تقوم عملية التصنيف على معالجة البيانات الرقمية للنطاقات المتعددة ذات النطاق الطيفي المتصل Continuous من خلال تحويلها إلى بيانات منفصلة النطاق Discrete Data، حيث كل خلية Pixel مستقلة تمثل قيمة رقمية واحدة في أحد النطاقات الطيفية التي تتكون منها المرئية، ثم يتم جمع الخلايا معاً حسب قيمها الرقمية ويتم تصنيفها إلى وحدات Classes معينة، ويمكن بذلك إعداد منتج خرائطي موضوعي Thematic Map حسب أهداف الدراسة (Lu & Weng, 2007).

وعليه استخدمت الدراسة التصنيف المراقب وغير المراقب للمساعدة في تقييم أنواع المصنفات القائمة على الخلية أو الهدف، إلا أنه على وجه التحديد غالباً التصنيف غير المراقب يسبق عملية التصنيف المراقب، حيث يتم بشكل آلي اختيار الفئات المراد تصنيفها دون تدخل من المستخدم، وقد أشار البنا (2005م) في دراسته أنه تكمن أهمية هذا التطبيق على جذب انتباه المستخدم لكفاءة البيانات الأولية وما يمكن أن يحققه من نتائج دقيقة، وقد استخدمت الدراسة خوارزمية ISO Cluster المتوفرة في برنامج ArcGIS Pro 2.8، وجاءت نتيجة التصنيف على 6 فئات، تم خفضها إلى 4 فئات بناء على انعكاسها الطيفي وذلك بدمج بعض الحزم الطيفية مثل دمج في فئة الطرق والظلال والمباني في صنف واحد، بينما جاءت فئات الأراضي الفضاء والزراعة والمياه أصنافاً مستقلة، وقد اتبعت الدراسة هذا التقسيم في تطبيق كافة خوارزميات المصنفات القائمة على الخلية أو الهدف، متفقة بذلك مع ما أوصت به دراسة الغامدي (2007م) حول ضرورة الفصل أو الحاجة إلى الدمج بين البصمات الطيفية المتقاربة خاصة في التطبيقات العمرانية والتخطيطية.

1-1-7 التصنيف القائم على الخلية (Pixel-based classification (PBC:

يعد تطبيق التصنيف المراقب مرحلة تلي التصنيف غير المراقب ويختلف عنه بأنه يتم بتدخل من المستخدم في اختيار الفئات المراد تصنيفها، وفي هذه الدراسة تم الاعتماد على أربع فئات تمثل (أراضي عمرانية- أراضي زراعية- أراضي فضاء- مياه)، وتم تعيين واختيار عينات تدريب لكل فئة، حيث حُددت عينة مكونة 172 مفردة تدريب بواقع 43 مفردة لكل فئة، موزعة على كامل منطقة الدراسة بشكل عشوائي، يلي ذلك مرحلة إدارة عينات التدريب من خلال تقييم دقة الفصل الطيفي شكل رقم (3).



الشكل رقم (3): تقييم دقة الفصل الطيفي لعينات التدريب.*

المصدر: الباحثة باستخدام برنامج ArcGIS Pro 2.8، ومريثة Sentinel-2B.

* يمثل الشكل مرحلة يلي ذلك مرحلة إدارة عينات التدريب من خلال تقييم دقة الفصل الطيفي لضمان عدم التداخل بينها حتى لا يؤثر على متوسط قيمة الانعكاس لعينات التدريب (Baroud, 2019).

كما تم تقليل تحيز التصنيفات باستخدام تكرار التدريب العشوائي والاختبار وبكسلات التحقق (Dabija, et al., 2021)، كما طبقت الدراسة التصنيف المراقب القائم على الخلية بعد إدخال الصورة الأصلية، وملف توقيع العينات وإصدار صورة جديدة، وملف تعريف لكل مصنف وذلك باستخدام خوارزميات التصنيف المتوفرة في برنامج ArcGIS Pro 2.8 كما يوضح الشكل رقم (4) وهي:

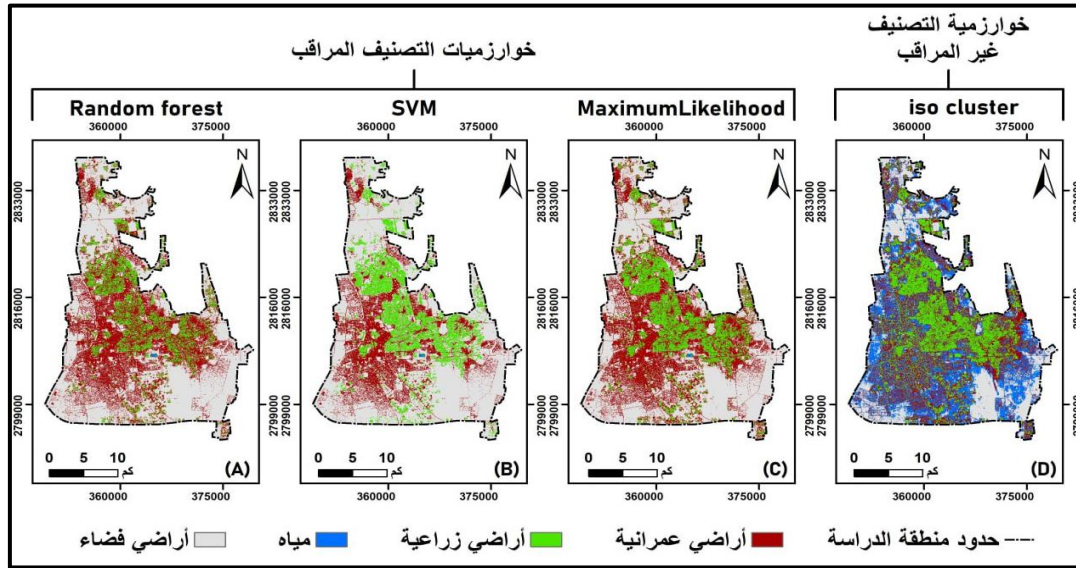
– خوارزمية مصنف الغابة العشوائية **Random Trees Classifier (RT)**: عبارة عن مصنف للتعلم الآلي خاضع للإشراف (المراقبة)، وهو يعتمد على إنشاء مجموعة عينات مختلفة وعشوائية من بيانات التدريب، واستخدامها لتصنيف عام، ويفترض التوزيع الطبيعي للعينات في كل فئة. وتعمل هذه الخوارزمية على تخفيف التجيز الزائد للبيانات، حيث إنه مقابل كل بكسل يتم تصنيفه، يتم اتخاذ عدد من القرارات حسب أهميتها عند رسمها بيانياً للبيانات، وبعد تصنيف البيانات بأكملها تشكل مجموعة قرارات فرعية بناء على وحدات بكسل التدريب، ومن ثم اتخاذ القرار النهائي (Esri, 2023).

– خوارزمية مصنف الاحتمالات العظمى **Maximum Likelihood Classifier (MLC)**:

يعتمد هذا المصنف على احتمال أن عينات التدريب في كل الفئات تتبع التوزيع الطبيعي، وعليه يتم احتساب احتمالات جميع الفئات لكل عينة، ثم يتم تعيين الفئة الأعلى احتمالاً لتلك العينة (Esri, 2023).

– خوارزمية مصنف الآلة المتجهة الداعم **Support Vector Machine (SVM)**:

يحاول هذا المصنف العثور على متجهات الدعم والسطح الفائق للفصل لكل زوج من الفئات، بغرض تعظيم الهامش والفاصل بين الفئات، وتعد طريقة حديثة وقوية خاضعة للإشراف (مراقب) وتحتاج عينات أقل من مصنف الاحتمالات العظمى ولا تفترض التوزيع الطبيعي كما هو الحال في مصنف الاحتمالات العظمى (MLC).

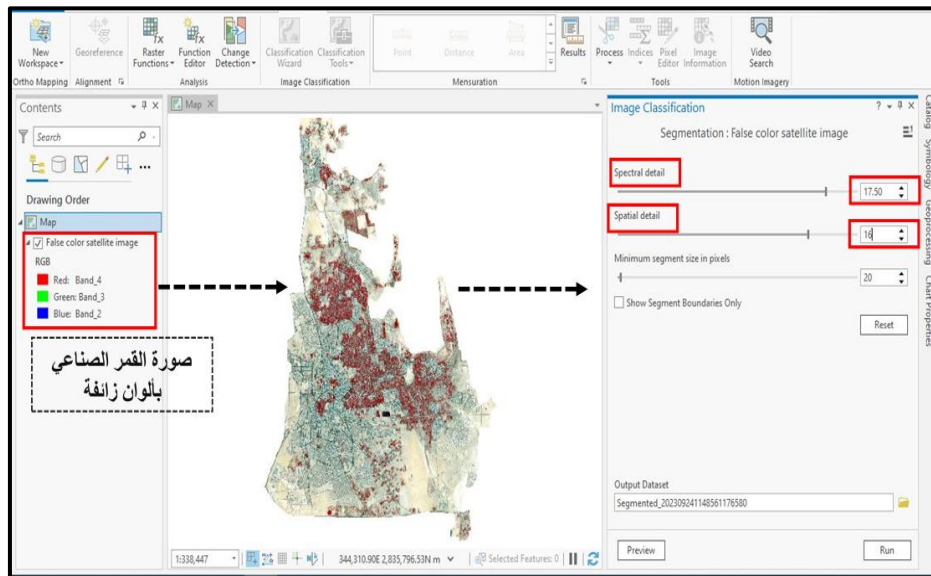


الشكل (4): التصنيف القائم على الخلية (PBC)

[A] خوارزمية الغابة العشوائية، [B] خوارزمية آلة المتجه الداعم، [C] خوارزمية الاحتمالات العظمى، [D] خوارزمية الايزو كلاستر. المصدر: الباحثة، باستخدام برنامج ArcGIS Pro 2.8، ومريثة Sentinel-2B.

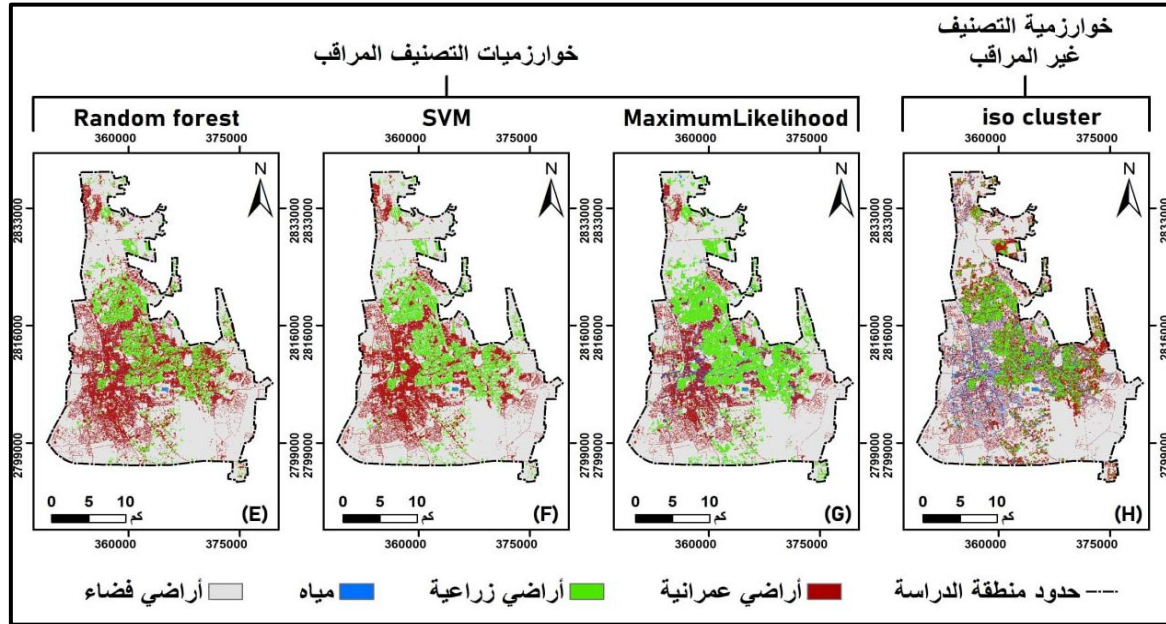
2-1-7 التصنيف القائم على الهدف (Object-based classification (OBC):

تتم عملية تقسيم أو تجزئة للمريثة الفضائية قبل تطبيق عملية التصنيف المراقب القائم على الهدف، وهي عملية تتم بشكل تكراري إلى أن يمكن الحصول على القيمة المثلى للتجزئة المناسبة، وتعد أهم مدخلات عملية التجزئة هي التفاصيل الطيفية Spectral detail والتفاصيل المكانية Spatial detail، حيث إنه ينبغي تحديد الكيفية التي يجب أن تكون الخلايا متجاورة ومتشابهة في المريثة الفضائية حتى يمكن تجميعها في هدف أو كائن واحد (Baroud, 2019)، وتتطلب هذه العملية تغييرا بين القيم الأعلى والقيم الأدنى Higher/Smaller values للتفاصيل الطيفية/ والمكانية حتى الوصول للقيمة المثلى، وجودة الأهداف التي تنتج عن هذا التصنيف تعتمد على اختيار القيم المناسبة والمقياس الأمثل للأهداف المحددة على منطقة الدراسة. وقد استخدمت الدراسة الأداة Segment Mean Shift، وعليه أختيرت القيمة المثلى للتفاصيل الطيفية (17.50) للتفاصيل الطيفية، بينما اختيرت (16) كقيمة مثلى للتفاصيل المكانية كما يوضح الشكل (5).



الشكل (5): مقاييس التجزئة المكانية والطيفية المثلى لمنطقة الدراسة باستخدام أداة Segment Mean Shift

ثم طبقت الدراسة التصنيف القائم على الهدف OBC باستخدام ذات الخوارزميات المطبقة على التصنيف المراقب القائم على الخلية PBC وهي: الغابة العشوائية RT، وخوارزمية الاحتمالات العظمى MLC، وخوارزمية الآلة المتجهة الداعم SVM كما يظهر في الشكل (6).



الشكل (6): التصنيف القائم على الهدف (OBC)

[E] خوارزمية الغابة العشوائية، [F] خوارزمية آلة المتجه الداعم، [G] خوارزمية الاحتمالات العظمى، [H] خوارزمية الايزو كلاستر.

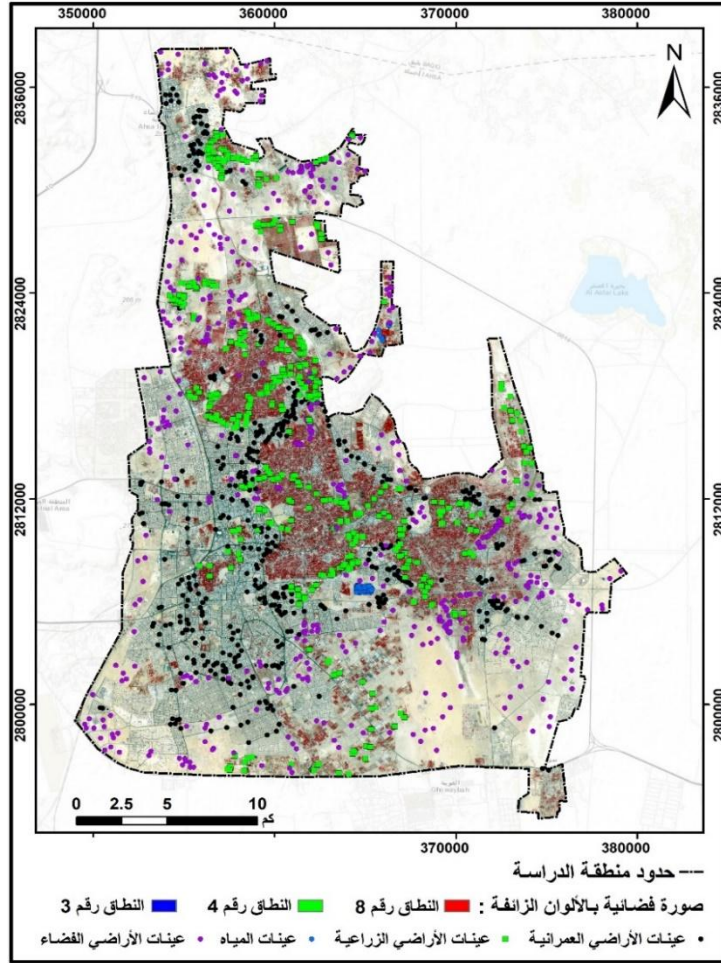
المصدر: الباحثة، باستخدام برنامج ArcGIS Pro 2.8، ومريئة Sentinel-2B.

3-1-7 التحليل البصري لنتائج التصنيف:

تبين من الفحص البصري لنتائج التصنيف أن تصنيفات الغطاء/الاستخدام الأرضي (LU/LC) بالاعتماد على التوقعات الطيفية (بشكل منفصل) يعد إجراء شاقاً وقابلاً للخطأ نتيجة وجود تداخل كبير بين التوقعات الطيفية، ويرجع ذلك إلى أن التركيبات اللونية بين المباني والطرق والمياه مختلفة، لذا نلاحظ أنها تعطي معلومات غير متناسقة من خلال المعلومات الطيفية وقد يؤثر ذلك في صحة التصنيف، كما أن الغطاءات الأرضية في المناطق الحضرية متشابهة طيفياً فالطرق الاسفلتية والظلال لها توقيع طيفي مشابه جداً لأسقف المباني، وينتج عن ذلك التباين الطيفي العالي داخل الفئة الواحدة أو التشابه الطيفي بين فئات الصور المصنفة للمناطق الحضرية عالية الوضوح ذات صحة منخفضة اعتماداً على الخصائص الطيفية فقط. كما أثبتت الدراسة تطبيق التصنيف القائم على الخلية، انخفاض دقة التصنيف في المناطق الحضرية نتيجة الخلط بين درجات الانعكاس الطيفي بين الطرق المعبد والمنازل، وانعكاس المياه لما بينها من خصائص طيفية ماثلة.

2-7 تقييم الصحة والمقارنات الإحصائية:

اختبرت عينات الاختبار من خلال خلايا فردية موزعة على كامل منطقة الدراسة بصورة عشوائية في محاولة لتحقيق الشمولية، حيث اختبرت عينة حجمها 1580 مفردة موزعة بين كافة الفئات، جاء عدد 500 مفردة للأراضي العمرانية و500 مفردة للأراضي الزراعية و500 مفردة للأراضي الفضاء و80 مفردة للمياه كما يبين الشكل (7).



الشكل (7): توزيع نقاط اختبار صحة التصنيف على منطقة الدراسة.

تعد عملية تقييم دقة نتائج التصنيف الرقمي هي الخطوة الأولى والمهمة التي يتحقق من خلالها مدى التطابق بين وحدات كافة الفئات بما يضمن التجميع الصحيح، على أن تتبع كل وحدة الصنف أو الفئة التي ينتهي إليها (النجم والموسوي، 2020م)، ويتم وصف هذه العملية وصفاً إحصائياً من خلال الأساليب التالية:

1-2-7 أسلوب تقييم الصحة الكلية:

وهو أسلوب قائم على تطبيق الصحة الشاملة Overall Accuracy التي تقوم على حساب الاتفاق الفعلي بين المرئية المصنفة مع نقاط وفئات البيانات المرجعية المعتمدة في الدراسة، وذلك من خلال حساب مصفوفة الخطأ، ثم تطبيق معامل كابل Kappa Coefficient الذي يرفق عادة مع الدقة الشاملة، ويأخذ بالاعتبار وفقاً لقانون الاحتمالية ويشير إلى دقة التصنيف من خلال إدخال جميع عناصر المصفوفة (عبده، 2013م) ويعبر عنه رياضياً كالتالي:

حيث إن:

po : هو الاتفاق المرصود نسبياً بين المقيمين (وهو مطابق لقيمة الدقة).

pe : هو الاحتمال الافتراضي لاتفاق الصدفة.

2-2-7 أسلوب التقييم الجزئي:

هو أسلوب يهدف إلى التعرف على مدى تقدير دقة تصنيف البيانات بالنسبة لكل فئة أو صنف بشكل منفرد، ويقاس من خلال حساب وصحة المستخدم User's Accuracy، وصحة المنتج Producer's Accuracy، ومن الناحية العلمية وفقاً لما أشار إليه عبده في كتابه (2013م) بأنه تعتبر دقة المنتج هي الأكثر أهمية، وعليه ستبني هذه الدراسة نتائجها حول الدقة المثلى المحققة في هذا الجانب، حيث تشير صحة المنتج إلى دقة تصنيف فئة بعينها وتحسب إحصائياً من خلال عدد الخلايا الصحيحة من فئة أو صنف معين مقسوم على العدد الكلي من تلك الفئة في 100، بمعنى إذا كان النظام


يقوم بتصنيف كائن معين كجزء من فئة معينة، فصحة المنتج هي احتمالية أن يكون هذا التصنيف صحيحاً بالفعل لجميع الهدفات في تلك الفئة. وبذلك يمكن أن تعكس صحة المنتج قدرة النظام على إنتاج نتائج متسقة ودقيقة على المستوى العام، مما يعكس جودة النموذج أو الخوارزمية المستخدمة (Maxwell, et al., 2018)، بينما دقة المستخدم تشير إلى دقة اختيار البيانات المرجعية المستخدمة في تقييم الدقة وهو يعد مؤشراً إحصائياً لمقدار خطأ التصنيف عن البيانات المرجعية (الأخطاء الضمنية)، بالمجمل يجب أن يتم تقييم صحة المستخدم وصحة المنتج معاً للحصول على فهم كامل لجودة التصنيف وأداء النظام، ويجب تحديد الأكثر أهمية وفقاً لاحتياجات ومتطلبات التطبيق المحدد (الحسن، 2007).

تم إنشاء مصفوفة الخطأ Error Matrix لتقييم صحة التصنيف، حيث تم ضبط حجم الخلية Pixel بالتساوي مع حجم خلية صورة التصنيف، وذلك بعد تحويل عينات الاختبار إلى صورة خلوية Raster، كما طبقت الدراسة باستخدام الأمر Combine المقارنة بين عينات الاختبار من خلال برنامج ArcGIS Pro، وباستخدام الأمر Pivot تم قلب محور الجدول لمقارنة التصنيف كما يتضح من خلال الجدول (1). وعليه تم تحويل الجدول الناتج إلى برنامج الأكل Excel وذلك لقياس التقييم الكلي من خلال: الصحة الشاملة Overall Accuracy، ومعامل كابا Kappa Coefficient، ثم حساب التقييم الجزئي من خلال: صحة المستخدم User's Accuracy، وصحة المنتج Producer's Accuracy.

الجدول (1): المقارنة الإحصائية بين دقة خوارزميات التصنيف المستخدمة في التحديد النوعي لاستخدامات الأرض.

المصنفات				خوارزميات التصنيف	الاسلوب
التصنيف القائم على الهدف Object-Based Classification		التصنيف القائم على الخلية Pixel-Based Classification			
معامل كابا (%) Kappa Coefficient	الصحة الشاملة (%) Overall Accuracy	معامل كابا (%) Kappa Coefficient	الصحة الشاملة (%) Overall Accuracy		
80.19	86.08	81.57	87.15	Random Trees الغابة العشوائية	التصنيف المراقب Supervised Classification
89.86	92.72	88.55	92.22	Support Vector Machine الآلة المتجهة الداعم	
83.4	88.16	82.29	87.66	Maximum Likelihood الاحتمالات العظمى	
49.623	63.67	29.16	47.47	Iso Cluster الايزو كلاستر	التصنيف غير المراقب Unsupervised Classification

تشير النتائج من خلال الجدول السابق أن كل من خوارزميات التصنيف المراقب في كل المصنفات القائمة على الهدف أو الخلية حققت نتائج مناسبة وجيدة من حيث الصحة الشاملة Overall Accuracy تتراوح قيمتها ما بين 86.08% و 92.72%، إلا أن خوارزميات التصنيف المراقب القائمة على الهدف قدمت نتائج أكثر دقة وصحة إذا ما قورنت بخوارزميات التصنيف المراقب القائمة على الخلية، ويمكن الاعتماد عليها في اتخاذ القرار، إذا ما استثنينا خوارزمية الغابة العشوائية التي بلغت 87.15% بقيمة أعلى في التصنيف القائم على الخلية عنها في التصنيف القائم على الهدف بفارق بسيط. يظهر من خلال الشكل (8) الفوارق البسيطة بين الصحة الشاملة وبين معامل كابا التي تحققت من خلال تطبيق المصنفات القائمة على الهدف والخلية، حيث جاءت خوارزميات التصنيف الهدف (OBC) في المرتبة الأولى باستخدام خوارزمية الاحتمالات العظمى (MLC) حيث بلغت قيمة الصحة الشاملة 92.72%، وبلغت قيمة معامل كابا 89.86%، بينما انخفضت صحة التصنيف المراقب الهدف باستخدام خوارزمية الآلة المتجهة الداعم (SVM) لتصل إلى 88.16% وبلغت قيمة معامل كابا 83.4%.



الشكل (8): التقييم الكلي بين خوارزميات المصنفات المستخدمة لقياس دقة التحديد النوعي لاستخدامات الأرض، اعتماداً على بيانات الجدول (1).

كما جاءت في المرتبة الثانية خوارزميات التصنيف المراقب القائم على الخلية (PBC) من حيث صحة التصنيف باستخدام خوارزمية الآلة المتجهة الداعم (SVM)، تليها خوارزمية الاحتمالات العظمى (MLC) حيث بلغت على التوالي قيمة الصحة الشاملة 92.22% و 87.66%، وبلغت قيمة معامل كبا 88.55% و 82.29% لكل منهما على التوالي، بينما ارتفعت صحة التصنيف الشاملة باستخدام خوارزمية الغابة العشوائية (RT) لتصل إلى 87.15% وبلغت قيمة معامل كبا 81.57% على نحو أعلى مما جاء عند تطبيقه في المصنف الآخر (PBC).

أما نتائج التقييم الجزئي (دقة المستخدم والمنتج) في المصنفات المستخدمة في الدراسة كانت متباينة بين فئات وتصنيفات الغطاء/ الاستخدام الأرضي (LU/LC)، وذلك تبعاً لخوارزميات التعلم الآلي المستخدمة، كما جاء من خلال الجدول رقم (2)، تراوحت نتائج صحة المستخدم باستخدام خوارزميات التعلم الآلي في التصنيف المراقب القائم على الخلية (PBC) بشكل عام بين 100% و 75.46% بين فئات وأصناف الغطاء الأرضي، حيث سجلت أعلى القيم باستخدام خوارزمية الغابة العشوائية (SVM) لتصل إلى ما نسبته 100%، ثم تليها قيمة خوارزمية الاحتمالات العظمى (MLC) التي بلغت نسبتها 94.63%، أما صحة المنتج Accuracy Producer's بين فئات أصناف الغطاء الأرضي تراوحت القيم من 100% حتى 82.8%، حيث جاءت أعلى القيم في كل فئة كالتالي: بلغت نسبة فئة الأراضي الفضاء 90.61%، ونسبة فئة المياه 100%، ونسبة فئة الأراضي الزراعية 96.8%، وأخيراً نسبة فئة الأراضي العمرانية 86.4%.

كما يوضح الجدول (2) نتائج التقييم الجزئي من خلال حساب صحة المستخدم User's Accuracy في التصنيف القائم على الهدف باستخدام الخوارزميات، حيث تراوحت القيم 98.51%-83.33% بشكل عام، نال استخدام خوارزمية الاحتمالات العظمى أعلى قيمة تساوي 98.51%، يليها استخدام خوارزمية الآلة المتجه الداعم بقيمة 97.7%، وأخيراً سجل استخدام خوارزمية الغابة العشوائية أدنى قيمة بلغت 96.84%. أما نتائج حساب صحة المنتج Accuracy Producer's للفئات المصنفة في التحديد النوعي لاستخدامات الأرض، تراوحت القيم المسجلة لشكل عام ما بين 100%-80.4%، وقد جاءت أعلى قيمة في كل فئة على حدة كالتالي: سجلت فئة الأراضي الفضاء 95.6%، وفئة المياه 100%، وفئة الأراضي الزراعية 98.4%، وأخيراً فئة الأراضي العمرانية 91.74%.

الجدول (2): التقييم الجزئي (صحة المستخدم وصحة المنتج) لخوارزميات التصنيف المستخدمة في قياس دقة التحديد النوعي لاستخدام الأرض.

فئات التصنيف القائم على الخلية (PBC)								الخوارزمية	
الأراضي العمرانية		الأراضي الزراعية		المياه		الأراضي الفضاء			
صحة المنتج (%)	صحة المستخدم (%)	صحة المنتج (%)	صحة المستخدم (%)	صحة المنتج (%)	صحة المستخدم (%)	صحة المنتج (%)	صحة المستخدم (%)	التصنيف المراقب	التصنيف المراقب
82.2	78.74	94.4	93.79	100	100	82.8	86.62		
85.8	88.6	96.8	95.6	97.5	100	90.8	87.81		
86.4	78.09	95.6	94.63	86.25	75.46	90.61	88.12		
63.6	52.54	80.6	67.49	0	0	38.4	64	Iso Cluster	

فئات التصنيف القائم على الكائن -الهدف- (OBC)								الخوارزمية	
الأراضي العمرانية		الأراضي الزراعية		المياه		الأراضي الفضاء			
صحة المنتج (%)	صحة المستخدم (%)	صحة المنتج (%)	صحة المستخدم (%)	صحة المنتج (%)	صحة المستخدم (%)	صحة المنتج (%)	صحة المستخدم (%)	التصنيف المراقب	
80.4	84.49	96.6	96.84	95	86.09	81.6	83.33		
91.74	92.68	98.4	97.7	93.75	83.33	91.4	88.23		
90.8	85.14	98.2	98.51	100	97.71	95.6	90.75		
71.8	67.33	82.8	72.4	100	35.71	78.6	54.97		

يقارن الجدول السابق رقم (3) صحة المنتج بين الخوارزميات والمصنفات المستخدمة بالدراسة، حيث بات الوقوف على تقييم مستوى دقة التصنيف هو نهج مهم لتصحيح وتحسين مخرجات العمل الخرائطي إلى جانب المعالجات لما هو قائم و تطوير المستقبل، وهو يتفق مع ما تركز الدراسة على استخلاصه من خلال نتائجها، كما أنه يتطابق مع ما أشار إليه عبده (2013م) في دراسته حول الأهمية العلمية، ومع ما أوصى به ماكسول (Maxwell, 2018) بأنّه ينبغي النظر عند مقارنه مصنفات متعددة إلى أبعد من مجرد الدقة الشاملة؛ بل ينبغي مراعاة دقة المستخدم والمنتج فيما يتعلق بالفئات المصنفة بشكل منفرد (كل على حده).

يتضح من خلال استعراض نتائج المقارنة التي يوضحها الجدول السابق أن تطبيق التصنيف القائم على الهدف باستخدام خوارزميات التعلم الآلي: الغابة العشوائية، وخوارزمية الاحتمالات العظمى، وخوارزمية الآلة المتجهة الداعم، والمستخدم في الدراسة. أنها حققت قيماً إحصائية مرتفعة نسبياً على مجمل فئات الاستخدام، إذا ما قُورنت بما سجلته الخوارزميات ذاتها في التصنيف القائم على الخلية والذي سجل نسب متفاوتة بين الفئات المصنفة. سجل استخدام خوارزمية الاحتمالات العظمى في التصنيف المراقب القائم على الهدف تفوقاً على كافة الخوارزميات المستخدمة في الدراسة، حيث نالت دقة المنتج القيمة الأعلى في كل الفئات المصنفة على التوالي: سجلت فئة المياه 100%، تليها فئة الأراضي الزراعية 98.2%، ثم فئة الأراضي الفضاء 95.6%، بينما سجلت العمران ما نسبته 90.8%، تليها بالمرتبة الثانية دقة المنتج باستخدام خوارزمية الآلة المتجهة الداعم كالتالي: فئة الأراضي الزراعية 98.4%، تليها من الفئات على التوالي المياه ثم العمران ثم الفضاء 91.4%-91.74%-93.75%، أخيراً جاءت ترتيب قيم صحة الفئات في خوارزمية الغابة العشوائية تنازلياً، فئة الأراضي الزراعية 96.6%، ثم المياه 95%، ثم الأرض الفضاء 81.6%، وأخيراً فئة العمران بنسبة 80.4%.

أما نتائج الدقة الكلية والجزئية في التصنيف غير المراقب باستخدام خوارزمية الايزو كلاستر ISO Cluster جاءت بشكل عام من خلال تطبيقها في التصنيف القائم على الهدف أعلى منها بالتصنيف القائم على الخلية وذلك بكافة الفئات المستخدمة (العمران، الزراعية، المياه، الفضاء).

الجدول (3): مقارنة صحة المنتج لتصنيف الفئات النوعية باستخدام الخوارزميات في كل المصنفات.

مقارنة دقة التقييم الجزئي للفئات المصنفة (دقة المنتج)			
المصنفات		فئات استعمالات الأرض	الخوارزميات المستخدمة
القائم على الهدف	القائم على الخلية		
	+	الأراضي الفضاء	الغابة العشوائية Random Trees (RTC)
	+	المياه	
+		الأراضي الزراعية	
	+	الأراضي العمرانية	
+		الأراضي الفضاء	الآلة المتجه الداعم Support Vector Machine (SVM)
	+	المياه	
+		الأراضي الزراعية	
+		الأراضي العمرانية	
+		الأراضي الفضاء	الاحتمالات العظمى Maximum Likelihood (MLC)
+		المياه	
+		الأراضي الزراعية	
+		الأراضي العمرانية	

المصدر: الباحثة اعتماد على نتائج بيانات الجدول (2).

(+): القيمة الإحصائية للفئة المنفردة قد حققت نتيجة أعلى من المصنف الآخر

8. الخاتمة:

ركزت الدراسة على التحقق من إمكانية تقييم دقة تصنيف استخدام/الغطاء الأرضي (LU/LC) اعتماداً على بيانات المرئيات الفضائية بالتطبيق على مرئية سنيتال2 (Sentinel-2)، وقد تبين من العرض السابق أن نتائج تطبيق التصنيف القائم على الهدف (OBC) على المرئيات الفضائية متعددة الأطياف فعال للغاية في البيئات الحضرية والبيئات المماثلة، حيث بلغت الصحة الشاملة 92.72%، وبلغت قيمة معامل كبا 89.86%، وبذلك يتفوق على التصنيف القائم على الخلية (PBC) في تحسين دقة التصنيف، إلا أنه ينبغي الإشارة أن نتائج تقييم الدقة الشاملة والدقة الجزئية بينهما تتفاوت بنسب متقاربة جداً، ويعود ذلك لمحددات مقياس قيم التجزئة المثلث التي تسبق عملية التصنيف (OBC)، اختُبرت 17.50 للتفاصيل الطيفية، و 16 للتفاصيل المكانية.

كما تضمنت نتائج المقارنة الإحصائية بين خوارزميات التعلم الآلي المستخدمة في الدراسة، تقييم الدقة المثلث في تصنيف الفئات/التحديد النوعي لاستخدام الأرض/الغطاء الأرضي (/)، وذلك من خلال تطبيق: خوارزمية الغابة العشوائية (RT)، وخوارزمية الاحتمالات العظمى (MLC)، وخوارزمية الآلة المتجهة الداعم (/)، وقد توصلت الدراسة إلى أن أداء خوارزمية الاحتمالات العظمى (MLC) قد أثبت أنها هي الخوارزمية المتفوقة، والتي توفر أعلى دقة إجمالية بقيمة 92.72%، ومعامل كبا 89.86%، كما كشفت من خلالها نتائج تقييم الدقة الجزئية (دقة المنتج ودقة المستخدم) بالنسبة لرسم خرائط الغطاء/الاستخدام الأرضي، أنها سجلت القيمة الأعلى في كل الفئات المصنفة على التوالي؛ حيث سجلت فئة المياه 100%، تليها فئة الأراضي الزراعية 98.2%، ثم فئة الأراضي الفضاء 95.6%، بينما سجلت العمران ما نسبته 90.8%.

كما أظهرت نتائج الدراسة أن التصنيف غير المراقب باستخدام خوارزمية الايزو كلاستر ISO Cluster هي نتائج غير مرضية من خلال القيم الإحصائية التي جاءت بها دقة الصحة الشاملة ومعامل كبا ويعود ذلك إلى تشابه الكثير من البصمات الطيفية في بعض الغطاءات الأرضية مما يجعله يعطي مدلولاً مخالفاً عن الواقع.

وعليه فقد قدمت الدراسة نموذج مقارنة تطبيقياً للتصنيف القائم على الهدف والتصنيف القائم على الخلية باستخدام الأسلوب المراقب وغير المراقب من خلال خوارزميات التعلم الآلي؛ خوارزمية الغابة العشوائية (RT)، وخوارزمية الاحتمالات العظمى (MLC)، وخوارزمية الآلة المتجهة الداعم

(SVM)، ولخصت حجم قيم الفوارق الإحصائية الممكنة بين المصنفات شريطة أن تكون البيانات الحضرية قريبة لخصائص منطقة الدراسة، وقد حُفقت أهداف الدراسة من خلال إطار منهجي متكامل تلخصت أهم نتائجه في التطبيق في إنتاج خريطة موضوعية للغطاء الأرضي/الاستخدام الأرضي (LU/LC)، كما أوصت بأفضلية التطبيق من بين الأساليب المتبعة في البيانات الحضرية المشابهة.

وبناء على ذلك توصي الدراسة بأن التوجيه باختيار الخوارزمية المناسبة لتحسين دقة التصنيف يعود إلى بعض الضوابط التي يجب مراعاتها: أهمها هو تحديد الفئة أو (الصنف) المراد تصنيفه فنجد على سبيل المثال: أن دقة صحة المنتج لفئة المناطق المياه وفئة الأراضي الفضاء حققت قيمة أعلى في خوارزمية الاحتمالات العظمى (MLC) عن باقي الخوارزميات، بينما جاءت أعلى قيمة لصحة المنتج لفئة المناطق العمرانية والزراعية باستخدام خوارزمية الآلة المتجه الداعم (SVM)، كما توصي بأن هذه الدراسة قد تمثل نموذجاً قابلاً للتطبيق على البيانات الحضرية المشابهة لمنطقة الدراسة والذي قد يخلق صحة مقارنة في النتائج.

"تم دعم هذا المشروع من قبل عمادة البحث العلمي، وكالة الجامعة للدراسات العليا والبحث العلمي، جامعة الملك فيصل، المملكة العربية السعودية، رقم المنحة KFU253545"

المصادر والمراجع

- الحسن، ع. م. (2007). *معالجة الصور الرقمية في الاستشعار عن بعد*. الرياض: مركز بحوث كلية الهندسة- جامعة الملك سعود.
- الحجوري، ن. س. والدغيري، م. إ. (2023). المحاكاة المكانية للتخطيط والتنمية الحضرية في واحة الأحساء باستخدام نموذج السلوك الذاتي الخلوي-ماركوف CA-Markov. *مجلة الجامعة الإسلامية للعلوم التربوية والاجتماعية*، 13، 329-358. من موقع المجلة: <https://journals.iu.edu.sa/ESS/Main/Article/9638>
- الغامدي، س. أ. (2007). تصنيف استخدامات الأراضي في مدينة مكة المكرمة عن طريق معالجة بيانات أقمار صناعية مدمجة. *المجلة الجغرافية/المصرية*، 11(47)، 33-55. من موقع المجلة: <https://search.mandumah.com/Record/1348818>
- المبارك، ح. ع. والحاجي، ز. ر. (2019). تحليل أثر ارتفاع درجات الحرارة على التوسعات العمرانية الأفقية: محافظة الأحساء دراسة تطبيقية باستخدام تقنية الاستشعار عن بُعد GIS. *المجلة العربية للدراسات الجغرافية*، 2(2)، 73-110. من موقع المجلة: <https://doi.org/10.21608/jasg.2019.43524>
- المنشي، ع. م. والجعدي، ف. ح. (2021). تقييم أسلوب التصنيف الهديفي (OBC) لاستخراج المباني من المراثيات الفضائية. *مجلة العمارة والتخطيط*، 33(1)، 1-27. من موقع المجلة: <https://doi.org/10.33948/JAP-KSU-33-1-1>
- المجلي، ف. س. والغامدي، ع. م. (2017). التصنيف الهديفي لاستخلاص الأراضي الفضاء من صور الأقمار الصناعية عالية الوضوح: دراسة تطبيقية على مدينة الرياض. *مجلة العمارة والتخطيط*، 29(2)، 211-240. من موقع المجلة: https://cap.ksu.edu.sa/sites/cap.ksu.edu.sa/files/attach/jap_ksu_jul2017_ar4.pdf
- النجم، ع. ح. والموسوي، إ. إ. (2020). التصنيف الرقمي لتغير استعمالات الأرض الزراعية في قضاء الكوفة باستعمال GIS-RS. العراق: جامعة القادسية، من الموقع: <https://repository.qu.edu.iq/wpcontent/uploads/sites/31/2020/12/Total%D8%B9%D9%82%D9%8A%D9%84-%D8%AD%D8%B3%D9%86-%D9%8A%D8%A7%D8%B3%D8%B1.pdf>
- عبده، و. م. (2013م). *مقدمة إلى الاستشعار عن بعد وتطبيقاته*، الطبعة الأولى. الدمام: مكتبة المتنبي.
- غازي البناء، ر. (2005). مقارنة نتائج طرائق التصنيف الرقمي ودقتها في تصنيف الغطاء الأرضي لجزء من مدينة الموصل. *المجلة العراقية الوطنية لعلوم الأرض*، 5(2)، 64-77. من موقع المجلة: <https://doi.org/10.33899/earth.2005.41153>
- وزارة الشؤون البلدية والقروية والإسكان. (2015). من الموقع: <https://www.momah.gov.sa/ar/branches>

References

- Abdi, A. M. (2020). Land cover and land use classification performance of machine learning algorithms in a boreal landscape using Sentinel-2 data. *GIScience & Remote Sensing*, 57(1), 1–20. <https://doi.org/10.1080/15481603.2019.1650447>
- Abduh, W. al-D. M. (2013). *Muqaddimah ilā al-Istish'ār 'an ba'da wa-taṭbīqātuḥu* (1st ed.) [In Arabic]. Maktabat al-Mutanabbī.
- Adam, H. E., Csaplovics, E., & Elhaja, M. E. (2016). A comparison of pixel-based and object-based approaches for land use land cover classification in semi-arid areas, Sudan. *8th IGRSM International Conference and Exhibition on Remote Sensing & GIS (IGRSM 2016), IOP Conference Series: Earth and Environmental Science*, 37, 012061. <https://doi.org/10.1088/1755-1315/37/1/012061>
- Adugna, T., Xu, W., & Fan, J. (2022). Comparison of Random Forest and Support Vector Machine classifiers for regional land

- cover mapping using coarse resolution FY-3C images. *Remote Sensing*, 14(3), 574. <https://doi.org/10.3390/rs14030574>
- al-Hajūri, N. S., & wāldghyry, M. I. (2023). *Al-Muḥākāh al-makānīyah lil-Takhḥīṭ wa-al-tanmiyah al-ḥaḍarīyah fī wāḥat al-Aḥsā' bi-istikhdām namūdḥaj al-sulūk al-dhātī alkhlw-Mārkwf CA-Markov* [In Arabic]. *Majallat al-Jāmi'ah al-Islāmīyah lil-'Ulūm al-Tarbawīyah wa-al-Ijtīmā'īyah*, 329, 13-358. <https://journals.iu.edu.sa/ESS/Main/Article/9638>
- al-Ḥasan, 'I. M. (2007). *Mu'ālajat al-ṣuwar al-raqmīyah fī al-Istish'ār 'an ba'da* [In Arabic]. Markaz Buḥūth Kullīyat al-Handasah, Jāmi'at al-Malik Sa'ūd.
- al-Ghāmidī, S. A. R. (2007). *Taṣnīf Istikhdāmāt al-arāḍī fī Madīnat Makkah al-Mukarramah 'an ṭarīq Mu'ālajat bayānāt Aqmār ṣinā'īyah mdmjh* [In Arabic]. *al-Majallah al-jughrāfiyah al-Miṣrīyah*, 11(47), 33-55. <https://search.mandumah.com/Record/1348818>
- al-Majlisī, F. S., & al-Ghāmidī, 'A. M. (2017). *Al-taṣnīf alḥdfy lāstkhālāsh al-arāḍī al-faḍā' min ṣuwar al-Aqmār al-Ṣinā'īyah 'Āliyah al-wuḍūḥ: Dirāsah taṭbīqīyah 'alā Madīnat al-Riyāḍ* [In Arabic]. *Majallat al-'Imārah wa-al-takhḥīṭ*, 29(2), 211-240. https://cap.ksu.edu.sa/sites/cap.ksu.edu.sa/files/attach/jap_ksu_jul2017_ar4.pdf
- Almthyby, A. M., & wālī'ydy, F. H. (2021). *Taqyīm uslūb al-taṣnīf alḥdfy (OBC) li-istikhrāj al-mabānī min almr'yāt al-faḍā'īyah* [In Arabic]. *Majallat al-'Imārah wa-al-takhḥīṭ*, 33(1), 1-27. <https://doi.org/10.33948/JAP-KSU-33-1-1>
- al-Mubārak, H. 'A., & wālḥājy, Z. R. (2019). *Taḥlīl athar artfā' darajāt al-ḥarārah 'alā al-tawassu'āt al-'umrānīyah al'fgyh: Muḥāfaẓat al-Aḥsā' dirāsah taṭbīqīyah bi-istikhdām taqnīyat al-Istish'ār 'an bu'd wGIS* [In Arabic]. *al-Majallah al-'Arabīyah lil-Dirāsāt al-jughrāfiyah*, 2(2), 73-110. <https://doi.org/10.21608/jasg.2019.43524>
- al-Najm, 'A. H., & wālmwswy, I. I. (2020). *Al-taṣnīf al-raqmī lṭghyr isti 'mālāt al-arḍ al-zirā'īyah fī Qaḍā' al-Kūfah bi-isti 'māl GIS-RS* [In Arabic]. *Jāmi'at al-Qādisīyah, al-'Irāq*. <https://repository.qu.edu.iq/wpcontent/uploads/sites/31/2020/12/>
- Baroud, F. K. (2019). *Remote sensing in ArcGIS* (1st ed.).
- Chen, Y., Zhou, Y., Ge, Y., An, R., & Chen, Y. (2018). Enhancing land cover mapping through integration of pixel-based and object-based classifications from remotely sensed imagery. *Remote Sensing*, 10(1), 10-33. <https://doi.org/10.3390/rs10010077>
- Copernicus Open Access Hub. (n.d.). Retrieved from <https://scihub.copernicus.eu/>
- Dabija, A., Kluczek, M., Zagajewski, B., Raczek, E., Kycko, M., Al-Sultani, A. H., Tardà, A., Pineda, L., & Corbera, J. (2021). Comparison of support vector machines and random forests for Corine land cover mapping. *Remote Sensing*, 13(4), 777. <https://doi.org/10.3390/rs13040777>
- De Paul, O. V. (2007). Remote sensing: New applications for urban areas. *Proceedings of the IEEE*, 12(95). <https://doi.org/10.1109/JPROC.2007.908065>
- Ghāzī al-Bannā, R. (2005). *Muqāranah natā'ij ṭarā'iq al-taṣnīf al-raqmī wḍqthā fī taṣnīf al-Ghiṭā' al-arḍī lḥz' min Madīnat al-Mawṣil* [In Arabic]. *al-Majallah al-'Irāqīyah al-Waṭanīyah li-'Ulūm al-arḍ*, 5(2), 64-77. <https://doi.org/10.33899/earth.2005.41153>
- Anderson, J. R., et al. (n.d.). A land use and land cover classification system for use with remote sensor data. *U.S. Geological Survey Paper*, 6-22.
- Lu, D., & Weng, Q. (2007). A survey of image classification methods and techniques for improving classification performance. *International Journal of Remote Sensing*, 28(5), 823-870. <https://doi.org/10.1080/01431160600746456>
- Li, M., Zang, S., Zhang, B., Li, S., & Wu, C. (2014). A review of remote sensing image classification techniques: The role of spatio-contextual information. *European Journal of Remote Sensing*, 47(1), 389-411. <https://doi.org/10.5721/EuJRS20144723>
- Maxwell, A. E., Warner, T. A., & Fang, F. (2018). Implementation of machine-learning classification in remote sensing: An applied review. *International Journal of Remote Sensing*, 39(9), 2784-2817. <https://doi.org/10.1080/01431161.2018.1433343>
- Naz, F., Nuthammachot, N., & Shabbir, R. (2024). Comparative analysis of support vector machine, random forest, K-nearest neighbors, and maximum likelihood algorithms for land use and land cover change detection: Mardan District, Pakistan. *SSRN*. <https://ssrn.com/abstract=4806019> or <http://dx.doi.org/10.2139/ssrn.4806019>
- Tilahun, A., & Teferie, B. (2015). Accuracy assessment of land use land cover classification using Google Earth. *American Journal of Environmental Protection*, 4(4), 193.