

تصنيف المباني من مشاهد الاستشعار عن بعد ذات قدرة التمييز المكاني العالية بطريقة الأهداف المحددة باستخدام برنامج Imagine Objective "حالة دراسية منطقة سكنية بمدينة دمشق"

د. محمد علاء شعلان*
د. أسماء الفوال**

المخلص

يعدُّ استخراج الأهداف من الصور الفضائية من أهم تطبيقات الاستشعار عن بعد. وفي أغلب الأحيان تُستخرَجُ المعلومات المكانية من مشاهد الاستشعار عن بعد بطرائق الرقمنة اليدوية المجهدة والمكلفة. ومع الجهود العلمية المبذولة لتطوير منهجيات لتصنيف مشاهد الاستشعار عن بعد (بما في ذلك الصور الجوية والمرئيات الفضائية)، لا تزال معظم هذه المنهجيات بعيدة عن التطبيق العملي. تقسم معظم منهجيات تصنيف مشاهد الاستشعار عن بعد إلى قسمين رئيسيين: الأولى تعتمد على تصنيف عناصر الصورة Pixel-based والثانية تعتمد على تصنيف الأهداف Object-based. عَرَضَ هذا البحث المنهجية المشتركة المتوافرة ضمن برنامج Imagine Objective الذي يتيح مجموعة أدوات عامة قابلة للتكيف حسب رغبة المستخدمين والأهداف المحددة المنشود استخراجها من الصور.

الكلمات المفتاحية: الاستشعار عن بعد /RS/ Remote Sensing، تصنيف الصور، Image classification، Imagine Objective.

* الهيئة العامة للاستشعار عن بعد.

** جامعة دمشق، كلية الآداب والعلوم الإنسانية، قسم الجغرافية.

Object-based Classification of Buildings from High Spatial Resolution Remotely Sensed Imagery Using Imagine Objective "case study of residential area in Damascus"

Dr. Muhammad Alaa Sha'lan*

Dr. Asmaa Al Fawal**

Abstract

Objects extraction from satellite images is one of the most important applications of remote sensing. The extraction of spatial information from remote sensing scenes is often carried out by laborious and costly manual digitization techniques. Despite scientific efforts to develop methodologies for classifying remote sensing scenes, most of these methodologies are still far from practical use. Most of the methodologies used for remotely sensed data classification are divided into two main domains: the first is pixel-based and the second is object-based classification. This research presents the common methodology available in the Imagine Objective program, which provides group of general tools that can be adapted to the users' needs and the specific objects that are to be extracted from the images.

Key words: remote sensing, image classification, Imagine Objective.

* General Authority for Remote Sensing.

** Damascus University, Faculty of Arts and Humanities, Department of Geography.

مقدمة:

إن أهم الجوانب التطبيقية للاستشعار عن بعد القدرة على تحديد الأهداف المختلفة، وتعرفها من مشاهد الاستشعار عن بعد. ومع التقدم الكبير في تقنيات الاستشعار عن بعد والبرمجيات فلا تزال طرائق التفسير البصري تستخدم في معظم الأحيان؛ مما يؤدي إلى هدر الوقت والجهد بشكل كبير. تسعى معظم البحوث في مجال تصنيف صور الاستشعار عن بعد لإيجاد طرائق ومنهجيات آلية لمحاكاة قدرة الإنسان في تفسير الصور بصرياً والحصول على معلومات مفيدة منها بأقل جهد ووقت ممكنين.

يمكن عدّ أن قدرتي التمييز المكانية Spatial Resolution والطيفية Resolution Spectral من أهم العناصر الرئيسة في عمليات التفسير والتحليل لمشاهد الاستشعار عن بعد. فكلما زادت قدرة التمييز المكانية، زادت قدرة الإنسان على إجراء عملية التفسير البصري ولكن انخفضت قدرة الحاسب على إجراء تصنيف مقبول. وعلى العكس تماماً كلما زادت قدرة التمييز الطيفية في المشهد (عدد المجالات الطيفية) تحسنت فرص الحاسب على تنفيذ التصنيف الآلي بشكل أفضل. تعدّ قدرة التمييز المكانية أكثر أهمية من قدرة التمييز الطيفية لتحديد المباني من المشاهد الفضائية (Gober, Myint, Grossman-Clarke, Brazel، و Weng، 2011). إلا أنّ زيادة قدرة التمييز المكانية وانخفاض التمايز الطيفي سيؤدي إلى خفض إمكانية الحاسب على التصنيف الآلي من خلال إظهار تفاصيل أكثر من اللازم.

مع تحسن قدرة التمييز المكاني لمستشعرات الأقمار الصناعية التجارية مثل (Quick Bird و IKONOS) ازدادت إمكانية تمييز المعالم الأرضية أكثر فأكثر. إلا أنّ انخفاض عدد المجالات الطيفية بهذه المستشعرات يؤدي إلى انخفاض التباين في انعكاسية الأهداف وظهور أخطاء كبيرة نتيجة التصنيف حاسوبياً. لهذا السبب تسعى منهجيات التصنيف الحاسوبي إلى محاكاة قدرة العين البشرية على تفسير الصور من خلال نمذجة عناصر التفسير الإضافية كالمساحة والشكل والنسيج والنمط.

يعدّ برنامج Imagine Objective المتاح تجارياً أحد الحلول البرمجية لاستخراج السمات الأرضية من مشاهد الاستشعار عن بعد وإجراء عمليات التصنيف المعتمدة على الهدف (Object-based classification). إذ يمكن بالتحليل الموجه هدفاً الحصول على نتائج أفضل من بيانات مشاهد الاستشعار عن بعد. إن كثرة المراحل والأدوات المتاحة للاستخدام في البرنامج والإعدادات اللازمة لها تجعل عملية استكشاف إمكانات

البرنامج جميعها مهمة شاقة قد تحول دون استخدامه بشكل فعال ومجدي. ولكن مقارنة بالبرمجيات والأدوات الأخرى يعدُّ برنامج *Imagine Objective* أقل تعقيداً وأسهل للاستخدام وبإمكانات محدودة (Chepkochei, 2011).

يستخدم برنامج *Imagine Objective* نماذج السمات (Feature Models) كإطار عمل موحد للأهداف الناتجة عن تجزئة المشاهد (Image segmentation) وخوارزميات معالجة عناصر الصورة (Pixel-based) التي تحول لصيغة تمثيل شعاعية (Vector) لتعالج لاحقاً بالمتغيرات الهندسية والنسجية. (Lack & Bleisch, 2010)

تزداد التفاصيل الظاهرة في المناطق العمرانية بازدياد قدرة التمييز المكانية، ومن ثمَّ تزداد إمكانية تحديد الأبنية وتصنيفها بصرياً (Benediktsson, Pesaresi, & Amason, 2003). أمّا حاسوبياً فإن ذلك قد يؤدي إلى ظهور تفاصيل أكثر من اللازم؛ ممَّا يؤدي إلى انخفاض دقة الخريطة الناتجة، وعرقلة عملية التحديد الآلي للحدود الخارجية للأبنية. من هنا فإن التصنيف وفقاً للهدف وعمليات تجزئة الصورة تؤدي دوراً مهماً في استخراج الأبنية من الصور الفضائية. وبهذا فإن عملية استخراج الأبنية مرتبطة ارتباطاً مباشراً بنجاح عملية تجزئة الصورة أو تقسيمها والعتبات المختارة لذلك. وتزداد صعوبة تجزئة الصورة بازدياد درجة تعقيد المشهد العمراني، وقد اقترح العديد من طرائق التجزئة (Cui, Yan, & Reinartz, 2012) و (Khoshelham, Li, & King, 2005) لاستخراج شكل مخطط سطوح الأبنية بشكل آلي وفعال.

أهمية البحث وأهدافه:

تعدُّ طرائق التصنيف وفقاً لأهداف محددة (Object-based classification) إحدى الطرائق الممكنة لعمليات التصنيف الآلي، إلا أنَّ تطبيقها على الصعيد العملي لا يزال محدوداً نظراً لتعدد الخطوات الممكنة لها وتنوعها؛ ممَّا يضيف نوعاً من التعقيد عليها. نظراً لتعدد الخطوات الممكن إتباعها لتصنيف المشاهد الفضائية بطريقة الأهداف المحددة وتنوعها. ونظراً لتنوع السمات الممكن استخراجها (أبنية - طرقات) فقد حدّدت الأهداف الرئيسية في هذا البحث بما يأتي:

- استكشاف الخطوات الرئيسية والفرعية المتوافرة ضمن برنامج *Imagine Objective* ودراستها وتحليلها التي يمكن استخدامها لتحديد الأبنية من المشاهد الفضائية وفقاً لترتيب مبسط وممنهج.
- تحديد أهم الخطوات ذات التأثير المباشر في دقة الخرائط المنجزة.

مشكلة البحث:

تمتاز المناطق العمرانية بالكثير من التفاصيل الممكن تمييزها من المشاهد الفضائية عالية قدرة التمييز المكانية. وغالبًا ما تخفق طرائق تصنيف عناصر الصورة (Pixel-based classification) في الحصول على خارطة رقمية دقيقة ضمن المناطق العمرانية. ومما يزيد الأمر سوءًا هو صعوبة الحصول على هذه المشاهد الفضائية بقدرات تمييز طيفية عالية. لذلك في أغلب الأحيان يتم اللجوء إلى عمليات الترقيم اليدوي المجهدة والمكلفة ماليًا وزمانيًا. من هنا لا بدّ من البحث عن الوسائل الأخرى البديلة لتصنيف المشاهد الفضائية تصنيفًا آليًا ودقيقًا.

أدوات البحث ومواده:

في هذا البحث استُخدم برنامج Imagine Objective المتاح ضمن أدوات برنامج ERDAS Imagine 2014. كما استُخدمت صورة فضائية Quickbird بقدرة تمييز مكاني عالية (0.61 متر) في المجال الطيفي البانوكروماتي ($0,445 - 0,900 \mu\text{m}$)، وقدرة تمييز مكاني (2.44 متر) في أربعة مجالات طيفية ($0,450 - 0,520 \mu\text{m}$ / $0,520 - 0,600 \mu\text{m}$ / $0,630 - 0,690 \mu\text{m}$ / $0,760 - 0,900 \mu\text{m}$). ملتقطه خلال عام 2006. ونظرًا لعدم إمكانية الحصول على المشهد الأصلي استُخدم المشهد المتوافر المدمج بثلاثة مجالات طيفية في المجال المرئي فقط الذي تم الحصول عليه لإحدى المناطق السكنية في مدينة دمشق؛ وذلك بهدف تطبيق الأدوات الممكنة ضمن البرنامج المستخدم.

منهجية البحث:

اعتمد المنهج الوصفي التحليلي والطرائق الاستشعارية من خلال دراسة الخطوات اللازمة لإنجاز عملية تصنيف الأهداف المحددة من المشاهد الفضائية، وتحليل هذه الخطوات لتحديد أكثرها تأثيرًا في دقة النتائج؛ وذلك بالمقارنة البصرية بالمشهد المستخدم دون إجراء تحليل كمي لدقة النتائج، إذ إنّ غاية البحث عرض خطوات المنهجية المقترحة بشكل مبسط للحصول على دقة نوعية مقبولة.

المنهجية المقترحة لاستخراج الأبنية باستخدام أدوات Imagine Objective

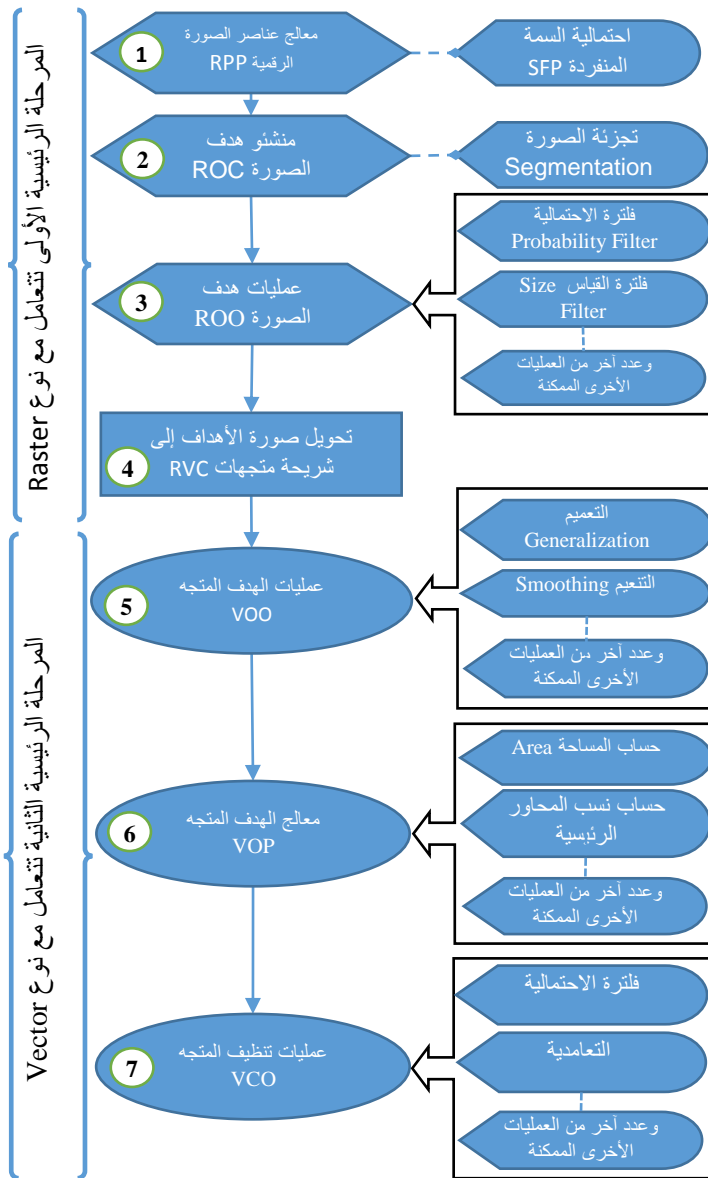
تتضمن منهجية استخراج الأبنية مرحلتين رئيسيتين لبناء نموذج السمة. الأولى تتعامل مع الصورة كمصفوفة خلية رقمية (Raster¹)، والثانية لمعالجة شريحة الأهداف المستخرجة كشريحة شعاعية خطية (Vector).

تقسم المرحلة الرئيسية الأولى إلى أربع مراحل فرعية: في البداية تُحدّد القيمة الاحتمالية لانتماء كل عنصر صورة من المشهد إلى الهدف المطلوب (الأبنية)، ثم تُقسّم أو تُجزّأ المشهد الخليوي، بعدها تُجرى مجموعة من العمليات على الأهداف الخليوية الناتجة عن عملية التجزئة، ثم تتم عملية تحويل الأهداف الخليوية إلى شريحة شعاعية خطية (مضلعات مغلقة أو خطوط متعددة). بهذه المراحل الأربع تنتهي المرحلة الرئيسية الأولى لمعالجة الصورة المصفوفية.

وتقسم المرحلة الرئيسية الثانية إلى ثلاث مراحل فرعية: تجري المعالجة الأولية لشكل الأهداف الخطية، تُجرى بعض العمليات الحسابية وتُحزّن ضمن جدول المواصفات لشريحة الأهداف الخطية، ثم في المرحلة الأخيرة تُجرى عملية تنظيف ومعالجة شريحة الأهداف الناتجة للحصول على المنتج النهائي.

يوضّح الشكل (1) المخطط الانسيابي للخطوات المتبعة كلاً لها لإنجاز عملية التصنيف لأهداف محددة. يشير القسم الأيسر من المخطط الانسيابي إلى تسلسل المراحل الفرعية السبع المتاحة والمرتبطة ضمن برنامج Imagine Objective التي قسّمت وفقاً لنوع البيانات التي تتعامل معها إلى قسمين رئيسيين (Raster ثم Vector). أمّا القسم الأيمن من المخطط الانسيابي فيوضّح الأدوات الفرعية المتاحة ضمن كل مرحلة من المراحل السبع التي يمكن اختيارها ضمن ترتيب يحدد من قبل المستخدم وفقاً لمتطلبات العمل. ولكل أداة من هذه الأدوات مجموعة من المتغيرات (Parameters) يقوم المستخدم بضبطها ومعايرتها. تنفذ كل أداة وظيفة معينة لمعالجة الشريحة المدخلة الناتجة عن الأداة التي تسبقها. وبهذا فإن اختيار الأدوات ضمن كل مرحلة وتغيير ترتيبها يتيح مرونة كبيرة في تصميم نموذج السمة المراد تحديدها من الصورة.

¹ مصطلح Raster يعرب كمصفوفة خلية أو مصفوفة مساحية.



الشكل (1): مخطط انسيابي لنموذج السمة Feature Model

تتضمن كل مرحلة فرعية مجموعة من الأدوات التي يمكن إضافتها إلى سلسلة النموذج المصمم لاستخراج الهدف المحدد. لبعض المراحل الفرعية يمكن اختيار أداة واحدة فقط وبعضها الآخر يمكن للمستخدم اختيار أكثر من أداة وفقاً لترتيب يحدده المستخدم. ولكل من هذه الأدوات مجموعة متغيرات يمكن تعديلها لتحسين أداء النموذج المصمم لاستخراج الهدف المطلوب.

في الفقرات الآتية سنسرد أهم الأدوات المتاحة ضمن كل مرحلة من المراحل الفرعية السبع التي تخدم بشكل خاص عملية استخراج شريحة الأبنية من مشاهد الاستشعار عن بعد. ومن أجل تبسيط آليات العمل وفقاً لمراحل المعالجة المذكورة واختبار مدى فعالية برنامج *Imagine Objective* في استخراج الأهداف المطلوبة وتصنيفها، اختيرت منطقة ضمن مدينة دمشق كمثال تطبيقي سيُعرض من خلاله نتائج تطبيق الأدوات المتاحة ضمن كل مرحلة من المراحل المذكورة.

منطقة الدراسة:

يتوافر لمنطقة الدراسة في أحد أحياء مدينة دمشق (المزة الغربية) صورة فضائية مدمجة الشكل (2) من التابع الصناعي *Quickbird* ضمن ثلاث أغطية طيفية ضمن المجال المرئي فقط؛ نظراً لعدم التمكن من الحصول على المشهد الأصلي. تتصف منطقة الدراسة بوجود عدد من السمات الظاهرة كالطرق والأبنية المتنوعة ضمن منطقة تنظيمية لها ضوابط وشروط بنائية للحفاظ على جمالية المنطقة من الناحية المعمارية. فعلى سبيل المثال لنفترض أن أحد الشروط البنائية في المنطقة أن يكون سقف الطابق الأخير قرميدياً. فمن أجل التحقق من مدى الالتزام بتنفيذ هذا الشرط الافتراضي يمكن تحديد الأبنية المسقوفة بالقرميد كحالة تطبيقية يمكن من خلالها استعراض الخطوات والأدوات المتاحة لإجراء عملية التصنيف المطلوبة.



الشكل (2): منطقة الدراسة (المزة الغربية في مدينة دمشق).

مراحل التنفيذ ضمن برنامج Imagine Objective

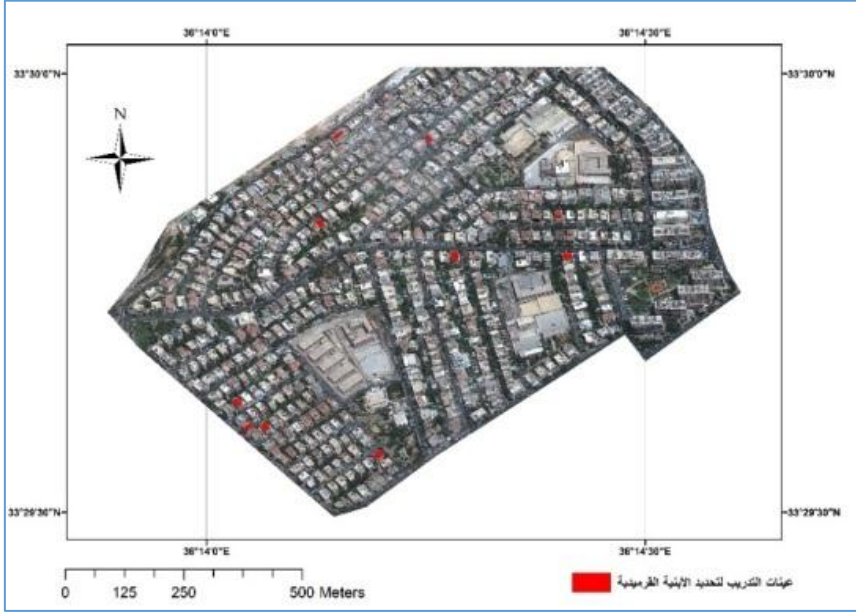
بعد تشغيل برنامج Imagine Objective وتسمية المشروع وتسمية نموذج السمة (Feature Model) لاستخراج الأبنية القرميدية، حُدِّت الصورة الفضائية المستخدمة في هذا البحث ضمن قائمة خصائص المتغيرات (Variable Properties). يقوم البرنامج بإظهار شجرة المراحل بشكل مرتب لنموذج السمة، بحيث يمكن العمل على كل مرحلة من المراحل السبع على التسلسل واختيار الأدوات المتاحة ضمنها كما يأتي:

1- معالج عناصر الصورة الرقمية (RPP) Raster Pixel Processor:


في هذه المرحلة تُستخدَم احتمالية السمة المنفردة Single Feature Probability (SFP) كمؤشر لعنصر الصورة (Pixel Cue) إذ تُصنَّف عناصر الصورة بشكل منفرد من خلال عينات التدريب المختارة. يقوم المستخدم باختيار عينات الأبنية المراد استخراجها بحيث لا تتضمن أيًا من عناصر الخلفية. في هذا المثال التطبيقي اختيرت عينة من الأبنية المغطاة بالقرميد كما هو موضح بالشكل (3) لاستخدامها في تدريب عملية التصنيف، حيث تُختار بعض السطوح القرميدية بشكل موزع ضمن منطقة الدراسة ويُحدَّد هذه العينات على شكل مضلعات تغطي السطح. يتيح البرنامج إمكانية اختيار

عينات من الخلفية، ولكن نظراً للتنوع الكبير في الخلفيات إكْتَفِيَّ بأخذ عينات الهدف المطلوب فقط لتوفير الجهد والوقت فضلاً عن أن البرنامج يتيح إمكانية تحديد بيكسلات الخلفية بشكل آلي كما هو موضح لاحقاً.

يقوم مصنف عناصر الصورة بقياس مدى التشابه بين عناصر الصورة وعينات التدريب المختارة. وتنتج عن هذه العملية شريحة احتمالية العناصر Pixel Probability Layer (PPL) بقيم بين الصفر والواحد لكل عنصر، وفقاً لاحتمال انتمائه للهدف المطلوب (الأبنية). الشكل (4) يبيّن شريحة الاحتمالية الناتجة عن RPP.




الشكل (3): العينة المختارة من الأبنية المكسوة بالقرميد



الشكل (4): شريحة الاحتمالية الناتجة عن تصنيف عناصر الصورة

إن المشهد المتوافر لمنطقة الدراسة ضمن المجال المرئي لا يحوي أفضية طيفية متعددة إضافية يمكن استخدامها في تمييز انعكاسية الهدف المطلوب (الأبنية القرميدية). ولكن من الواضح أن الأبنية القرميدية تمتاز بانعكاسية عالية في المجال الأحمر، لذا يمكن تحديد عتبة للاحتتمالية للحصول على نتيجة أكثر ملاءمة للهدف المراد تصنيفه. يتيح البرنامج إمكانية تحديد عتبة للاحتتمالية؛ وذلك ضمن لوحة خصائص SFP التي يمكن من خلالها أيضاً السماح للبرنامج بتحديد عينات الخلفية ألياً. حدّدت قيمة عتبة الاحتمالية (0.9) لأن الأبنية القرميدية تملك تبايناً واضحاً ومميزاً. الشكل (5) يبيّن الشريحة الناتجة عن تطبيق عتبة للاحتتمالية. بالمقارنة بالنتيجة السابقة الشكل (4) نلاحظ أنه تم إظهار البيكسلات الممثلة للأبنية القرميدية بشكل أفضل، لذا ستُعتمدُ هذه النتيجة للمرحلة اللاحقة.




الشكل (5): شريحة الاحتمالية بعد تطبيق قيمة عتبة (0.9)

2- منشئو هدف الصورة الرقمية (ROC) Raster Object Creators:

في هذه المرحلة تجري عملية تجزئة الصورة فضلاً عن كشف الحواف لتحديد الأجزاء متشابهة الخواص. تجري عملية تجزئة مظاهر الصورة بناء على تشابه قيم العناصر وتجاورها لتصبح الصورة أبسط وأكثر قابلية للتحليل. يمكن للمستخدم اختيار معاملات تجزئة الصورة: المسافة الاقليدية Euclidean distance، فرق القيم الأدنى minimum value difference، عامل التباين variation factor، العتبة Threshold والعدد الأدنى من العناصر الممثلة لهدف واحد. ينتج عن تقسيم الصورة شريحة مصفوية Raster Object Layer (ROL) تمثل قيم عناصرها أرقامًا تعريفية لأجزاء الصورة بحيث يمثل كل جزء مجموعة من العناصر المتجاورة والمتشابهة. تُستخدَم في هذه المرحلة أيضًا شريحة احتمالية العناصر PPL الناتجة عن المرحلة السابقة RPP لحساب متوسط الاحتمالية لكل جزء (هدف منفصل) ضمن المشهد.

في المثال التطبيقي اختيرت أداة التجزئة Segmentation لتجزئة المشهد باستخدام الطبقات كلها (Layers) واختيار القيم الافتراضية لفرق القيم الأدنى وعامل التباين التي يمكن حسابها من خلال الوظيفة (Compute Settings) المتاحة ضمن لوحة (Segmentation Properties)؛ أمّا الإعدادات المتقدمة، التي يمكن الولوج إليها من خلال (Advanced Settings) فقد اختارت تطبيق كشف الحافات بعتبة 15 وأقصر طول 50 بيكسل، فضلاً عن اختيار المساحة الصغرى 400 بيكسل. الشكل (6) يبين الصورة الناتجة عن تطبيق عملية التجزئة ضمن مرحلة ROC باستخدام الإعدادات المذكورة التي اختيرت تجريبياً. كل جزء أو هدف ضمن الصورة المجزئة يملك قيمة احتمالية تعبر عن متوسط احتمالية البيكسلات المنفردة المشكلة لهذا الهدف. تُخزّن هذه القيم المتوسطة ضمن حقل (PixProb) في جدول خصائص الصورة المجزئة. يمكن عدّ مرحلة إنشاء الأهداف بطريقة تجزئة الصورة هي عملية حرجة وتتطلب عناية فائقة للوصول إلى نتائج مقبولة. من هنا يمكن عدّ المرحلتين الأولى RPP والثانية ROC هي أهم مراحل المعالجة في طريقة التصنيف وفقاً لأهداف محددة.




الشكل (6): تجزئة المشهد ضمن مرحلة إنشاء الأهداف ROC

3- عمليات هدف الصورة الرقمية (ROO) Raster Object Operators:

هنا تُطبَّق مجموعة من عمليات المعالجة على شريحة الأهداف المصفوفية ROL الناتجة عن المرحلة السابقة ROC. إذ يوفر البرنامج عدداً من الأدوات يمكن الاختيار منها وترتيبها ضمن هذه المرحلة حسب الحاجة وتشمل:

1. فلتر الاحتمالية: لإزالة الأجزاء (الأهداف المنفصلة) جميعها التي متوسط احتمالية عناصرها أقل من الاحتمالية الصغرى المحددة.
2. فلتر القياس: تُزال الأجزاء جميعها الأصغر أو الأكبر من حجم محدد.
3. التوسيع: تُوسَّع الأجزاء الناتجة عن إعادة التكتل لتغطية عناصر الصورة المجاورة لها.
4. التآكل: تُقلَّص الأهداف الناتجة لإزالة عناصر الصورة المحيطة بكل هدف
5. فلتر قياس الكتل: لإزالة الكتل الأصغر من قيم معينة التي نتجت عن عملية دمج الكتل المتجاورة.

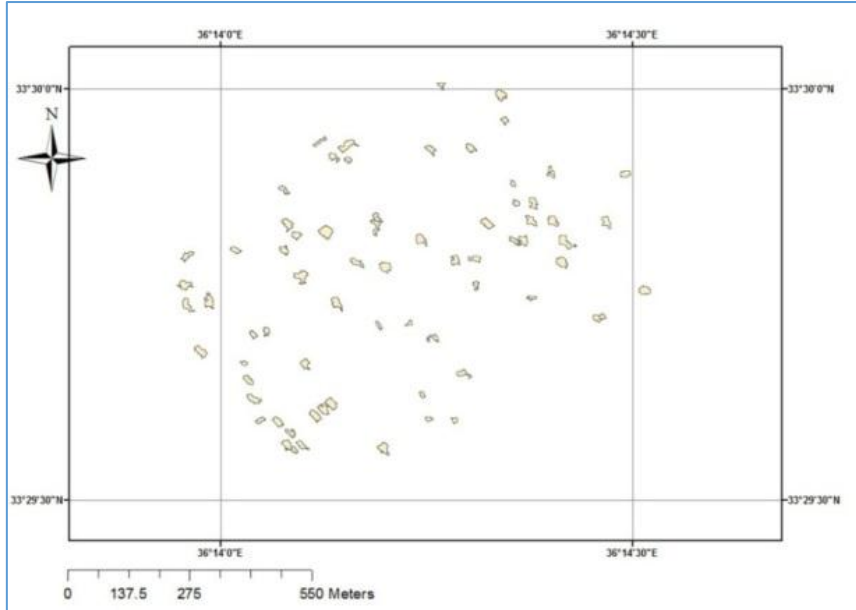
ينتج عن مجموعة العمليات المذكورة شريحة أهداف من نوع Raster تحتوي على بيكسلات مجمعة تمثل مساقط الأبنية التي استُخْرِجَت مع قيم متوسط الاحتمالية لها. للمثال التطبيقي اختيرت ثلاث أدوات فقط من الأدوات المتاحة هما: فلتر الاحتمالية، والتآكل، وفلتر القياس. وطُبِّقَت القيمة الدنيا لفلتر الاحتمالية (0.5). واستُخدمت نواة مربعة بحجم 3 بيكسلات لأداة التآكل، ثم أُجْرِيَت فلتر الأهداف التي يقل قياسها عن 400 بيكسل. الشكل (7) يبيِّن نتيجة تطبيق هذه الأدوات.



الشكل (7): الصورة الناتجة عن تطبيق الأدوات ضمن مرحلة ROO

4- تحويل الصورة إلى متجهات (RVC) Raster to Vector Conversion:

هنا تُحوَّلُ الصورة الناتجة عن المرحلة السابقة لشريحة مضلعات خطية Vector. أي نحصل على شريحة أهداف خطية (VOL) Vector Object Layer من خلال رسم المضلعات المحيطة بكل هدف مستخرج، ويوجد خيار آخر بدلاً من رسم مضلع مغلق تُرسم مجموعة الخطوط دون إغلاق. الشكل (8) يبيّن نتيجة تحويل الصورة الناتجة من المرحلة السابقة ROO إلى شريحة مضلعات




الشكل (8): شريحة المضلعات الناتجة عن مرحلة RVC

5- عمليات الهدف المتجه (VOO) Vector Object Operators:

تجرى في هذه المرحلة بعض العمليات الشكلية على الشريحة الخطية VOL الناتجة عن عملية التحويل السابقة؛ وذلك لتعديل شكل المضلعات من خلال عملية التعميم Generalize والتنعيم Smooth لإزالة بعض رؤوس المضلعات غير الضرورية. كما يمكن فلترة الجزر الداخلية للمضلعات خلال هذه المرحلة بغض النظر عن مدى اتساعها باستخدام الأداة Island Filter. وتنتج عن هذه العمليات شريحة خطية VOL جديدة.

الشكل (9): يظهر نتيجة تطبيق عملية التعميم والتنعيم لتشذيب المضلعات الناتجة عن مرحلة RVC السابقة.



الشكل (9): نتيجة تطبيق عمليتي التعميم والتنعيم ضمن مرحلة VOO

6- معالج الهدف المتجه (VOP) Vector Object Processor:

توفر هذه المرحلة مجموعة من العمليات الحسابية على الشريحة الخطية VOL الناتجة عن مرحلة VOO السابقة. يمكن حساب عدد من المؤشرات المتاحة ضمن قائمة (Available Object Cues) إذ يقوم البرنامج بتخزين القيم المحسوبة ضمن جدول مواصفات الشريحة الخطية. وتجدر الإشارة هنا إلى أن هذه المرحلة لا تعمل على تعديل شكل المضلعات في الشريحة، وإنما تقوم بإضافة حقول إلى جدول مواصفات الشريحة بناء على المؤشرات المختارة، فضلاً عن حقل جديد (Probability) يمثل احتمالية انتماء كل مضلع ضمن الشريحة إلى الهدف المحدد من خلال المقارنة بعينة التدريب. من هنا فإن شكل عينات التدريب يؤدي دوراً مهماً في هذه المرحلة. إذ يمكن تحديد نوع عينات التدريب المختارة كبيكسلات (Pixel)، أو هدف (Object)، أو كلا النوعين بيكسل وهدف (Both). فمثلاً عند اختيار نوع عينة التدريب المضافة كبيكسل يقوم البرنامج باستخدام هذه العينة فقط لحساب احتمالية البيكسلات المنفردة SFP الواردة في

المرحلة الأولى RPP. أمّا إذا كان نوع العينة هدفاً أو بيكسلاً وهدفاً معاً فيقوم البرنامج باستخدام عينات التدريب هذه لتحديد قيمة الحقل (Probability)، وعندها يجب أن يكون شكل العينات المختارة ممثلاً لشكل الهدف المنشود.

إن الهدف من تحديد قيم المؤشرات الممكن اختيارها هو تمكين المستخدم من تنظيف هذه الشريحة لاحقاً وفقاً لمعايير التصنيف المناسبة للأهداف الخطية المستخرجة (الأبنية). فيما يأتي عرضنا بعض العمليات الحسابية للمؤشرات الممكنة في هذه المرحلة:

- حساب مجموعة من مؤشرات الشكل الهندسي Geometry لكل مضلع: نذكر منها **مساحة المضلع** بعد طرح مساحات الجزر الداخلية. **محيط المضلع** مضافاً إليه محيط الجزر الداخلية. **نسبة مربع المحيط إلى المساحة** وبعد هذا المؤشر مفيداً لتمييز شكل المضلع، فالمضلعات الدائرية تكون بأقل قيمة، كذلك المضلعات البسيطة الأخرى كالمربع تملك قيمة صغيرة نسبياً، أمّا المضلعات المعقدة أو المتطوّلة أو التي تحوي جزراً كبيرة فتمتلك قيمة عالية لهذا المؤشر. **طول المحور الرئيسي والثانوي للمضلع**. **نسبة المحور الثانوي للرئيسي**. **مؤشر الاستطالة** يقيس مدى تشابه المضلع لشكل المستطيل.

- **مؤشر الارتباط بالظل (Association: Shadow)**: إذ يقيس هذا المؤشر الارتباط المكاني للمضلع مع ظاهرة ما (كالظل). تُدخّل الظاهرة المرتبطة كملف خطي (Vector) يحوي المضلعات المستخرجة بأحد الموديلات المصممة خصيصاً لذلك والتي يمكن إنشاؤها ضمن هذا البرنامج باستخدام نموذج جديد (Feature Model) لاستخراج ظل الأبنية فقط. يمكن للمستخدم إدخال الزاوية المشكلة بين شريحة الأبنية المستخرجة وشريحة الظاهرة المرتبطة (الظل) بالدرجات. تمثل الزاوية صفر اتجاه الشرق، أي أن الظل المرتبط بالبناء يقع شرق هذا البناء. وتزداد الزاوية بعكس عقارب الساعة لتصل 90 درجة شمالاً، أي أن الظل المرتبط بالبناء يقع شمال هذا البناء. أمّا الزاوية 180 درجة فتعني أن الظل يقع غرب البناء وهكذا. كما يمكن حساب هذه الزاوية آلياً من خلال عملية تصنيف يقوم بها الحاسب بإعطاء قيم احتمالية أولية لشريحة المضلعات، ومن ثم فحص المضلعات المجاورة للمضلعات، ذات الاحتمالية الأعلى لإيجاد أي مضلع ظل موجود في الجوار القريب.

- **مؤشر تحليل التوزيع التجريبي (EDA) Empirical Distribution Analysis** الذي يقيس مدى تشابه التوزيع الإحصائي لمجموعة عناصر الصورة ضمن الهدف المستخرج مع عناصر عينات التدريب. ويختلف هذا المؤشر عن المؤشرات الإحصائية الأخرى (المتوسط والانحراف المعياري) بأنه يقيس التكرار النسبي للقيم الرقمية (الهيستوغرام) لكل هدف مستخرج.

للمثال التطبيقي اختيرت ثلاثة مؤشرات للشكل الهندسي، وهي: المساحة Area، ونسبة مربع المحيط إلى المساحة Perim Sqr/Area والمستطيلية Rectangularity. الشكل (10) يبين جزءاً من جدول مواصفات الشريحة الناتجة، إذ كما ذكرنا تبقى الشريحة الناتجة عن المرحلة السابقة VOO كما هي ولكن تُضاف حقول جديدة إلى جدول المواصفات وأهمها الحقل Probability الذي يلخص مدى تشابه كل مضلع مع عينة التدريب المختارة للهدف.

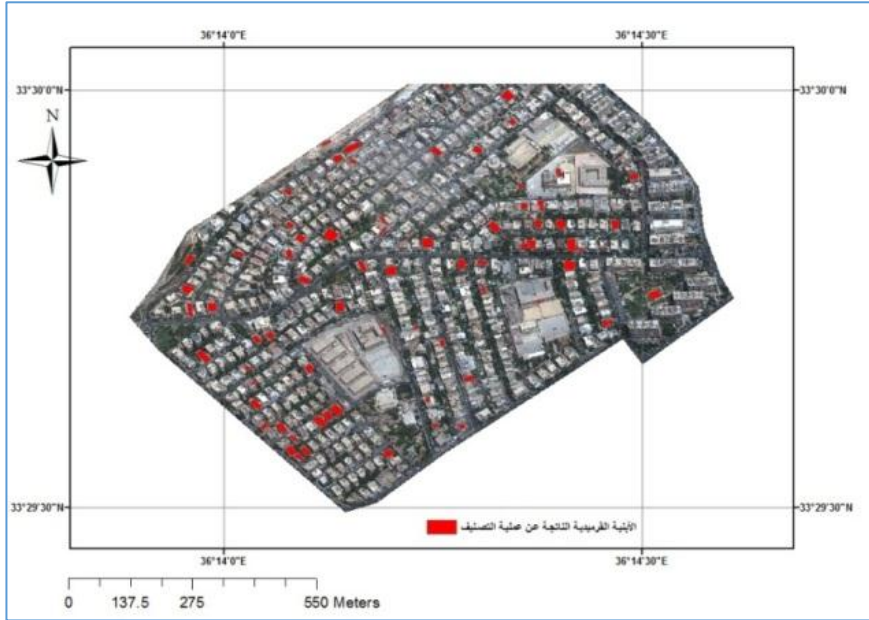
Record	PixProb	Area	PerimSqr/Area	Rectangularity	Probability
1	0.7049	94.6174	36.5795	0.0984	0.3515
2	0.6352	319.7562	21.7199	0.5095	0.3230
3	0.5968	130.0153	22.2046	0.5275	0.6309
4	0.8240	139.7225	38.9130	0.4543	0.4296
5	0.6465	420.3511	27.8680	0.4057	0.3203
6	0.7445	205.7616	23.0977	0.4787	0.5472
7	0.5924	209.6970	28.5540	0.4511	0.3488
8	0.7409	201.6132	29.2339	0.3830	0.4104
9	0.7460	109.0530	23.5947	0.4747	0.6288
10	0.5856	179.7433	35.0324	0.2295	0.2762
11	0.5550	204.7830	19.4119	0.6260	0.5531
12	0.6329	87.3297	21.9614	0.4886	0.5397
13	0.6258	165.2668	28.8197	0.4635	0.4574

الشكل (10): جزء من جدول المواصفات للشريحة الناتجة عن مرحلة VOP

7- عمليات تنظيف المتجه (VCO) Vector Cleanup Operators:

تتضمن المرحلة الأخيرة للنموذج المصمم مجموعة أدوات تساعد على تنظيف شريحة المضلعات الناتجة عن سلسلة المراحل السابقة. من ضمن هذه الأدوات: **فلتر الاحتمالية (Probability Filter)** الذي يعمل على حذف المضلعات ذات الاحتمالية الأقل من قيمة معينة. **فلتر الجزر (Island Filter)** الذي يقوم بحذف الجزر أو الثقوب ضمن المضلعات وفقاً لمساحة يحددها المستخدم. **التنعيم (Smooth)**، ويستخدم لتبسيط حدود المضلع وتخفيف درجة الزوايا الحادة. **التعامدية (Orthogonality)** تجري عملية التنعيم أولاً ثم التعميم لحدود المضلع، ثم تجري عملية حذف القطع التي لا تحقق العتبة المحددة، ثم عملية تدوير القطع المتبقية حول مركزها إلى أقرب زاوية تعامد لتجري مقاطعتها مع القطع الأخرى الممثلة لحدود المضلع.

للمثال التطبيقي اختيرت أداة التعامدية للحصول على مضلعات ذات زوايا شبه قائمة. الشكل (11) يظهر شريحة الأبنية القرميدية النهائية الناتجة وفقاً لطريقة التصنيف المقترحة في هذا البحث. إذ يمكن ملاحظة أن معظم الأبنية ذات السقوف القرميدية في منطقة الدراسة قد حُدِّثت تحديداً جيداً.



الشكل (11): شريحة الأبنية القرميدية الناتجة عن عملية التصنيف

مناقشة النتائج:

من خلال المقارنة البصرية للشريحة الناتجة عن عملية التصنيف المقترحة بالصورة المستخدمة يمكن القول: إنه تم الحصول على نتائج بدقة نوعية جيدة. لم يُجرَ تحليل كمي للدقة لأسباب تتعلق بنوعية المشهد المستخدم إذ لم يكن بالإمكان الحصول على المشهد الأصلي بقدرة التمييز المكاني الفعلية. لذا فإن الاكتفاء بتقدير الدقة نوعياً يفي بغرض البحث لاختبار كفاءة برنامج *Imagine Objective* في فصل الأهداف العمرانية وتصنيفها آلياً لزيادة دقة التصنيف.

مع أنه لم تُستخدَم الأدوات المتاحة كلها، إلا أن الدقة النوعية التي تم التوصل إليها تعدُّ جيدة نسبة إلى نوعية المشهد المتوافر. وللحصول على نتائج أكثر دقة لا بد من

تأمين مشاهد فضائية بجودة أفضل، وتطوير النموذج المقترح بإضافة أدوات أكثر. ويجدر الذكر هنا إلى ضرورة الاعتناء باختيار عينات تدريب أكثر شمولية للهدف المطلوب، وأن تضم العينات كلها الأنواع الممكنة من حيث الانعكاسية الطيفية والشكل الهندسي للهدف. فعلى سبيل المثال لا يمكن الإفادة من الأدوات المتاحة كلها ضمن المرحلة السادسة (VOP) ما لم يتم اختيار عينات تدريب تمثل الشكل الهندسي للهدف. إن ما يوفره برنامج Imagine Objective من أدوات وخوارزميات متعددة وبيئة عمل تفاعلية مع المستخدم يسهم إلى حد كبير في توفير الوقت والجهد لتصنيف المشاهد آلياً ضمن المدن، وتنفيذ الدراسات العمرانية المتنوعة.

المقترحات:

يعتمد نجاح عملية التصنيف وفقاً للأهداف المحددة باستخدام برنامج Imagine Objective على عاملين رئيسيين هما:

- درجة دقة شريحة احتمالية عناصر الصورة الناتجة عن المرحلة الأولى ضمن سلسلة نموذج السمة (SFP - RPP). وللحصول على تمايز في الاحتمالية للهدف المحدد يجب توافر تمايز في الانعكاسية الطيفية لهذا الهدف ضمن المشهد. من هنا فإن الحصول على صورة ذات أطراف متعددة قد تساعد في رفع دقة عملية التصنيف.
- للحصول على أفضل النتائج نقترح تقسيم المشهد المراد تصنيفه إلى مجموعة من الأهداف المتميزة طيفياً، وإنشاء نموذج سمة مخصص لكل هدف منفصل.
- إن نجاح عملية تجزئة المشهد في مرحلة إنشاء الأهداف الخلفية ROC له تأثير كبير في دقة النتائج، إذ يتيح برنامج Imagine Objective عددًا من الخوارزميات لإنجاز التجزئة، ويسمح بتغيير الإعدادات لها للحصول على تجزئة أفضل. ونظرًا إلى أن المجال البحثي لا يزال مستمرًا لتطوير خوارزميات أكثر فاعلية، فيمكن دراسة إمكانية دمج تلك الخوارزميات في البرنامج للإفادة منها في رفع الدقة الناتجة.
- إن الحصول على مشهد بجودة عالية وبقدرة تمييز مكانية عالية يسهم في رفع كفاءة عملية التجزئة. وعند تصميم أكثر من نموذج سمة بعدد الأهداف المطلوب استخراجها يمكن إجراء عملية التجزئة مرة واحدة فقط، وبذل أفضل جهد لاختيار الإعدادات لخوارزمية التجزئة المختارة، وتكرار استخدام نتيجة التجزئة ضمن كل نموذج سمة جديد لتوفير الجهد والوقت.

لذا يمكن توقع رفع دقة التصنيف الناتجة ببذل الجهد الأكبر على المرحلتين الأولىين ضمن سلسلة نموذج السمة Feature Model. إذ إن تأثير بقية المراحل في دقة النتائج ليس بالأمر الجوهري.

References:

1. Benediktsson, J. A; Pesaresi, M. & Amason, K: Classification and feature extraction for remote sensing images from urban areas based on morphologica transformations. IEEE Transactions on Geoscience and Remote Sensing, pp. Vol. 41, 2003, Pp: 1940-1949.
2. Chepkochei, L. C: Object-oriented image classification of individual trees using Erdas Imagine Objective: Case study of Wanjohi area, Lake Naivasha Basin, Kenya. proceedings, Kenya Geothermal Conference, November 21-22, 2011.
3. Cui, S; Yan, Q. & Reinartz, P: Complex building description and extraction based on Hough transformation and cycle detection. Remote Sensing Letters, pp. vol. 3, 2012, Pp: 151-159.
4. Khoshelham, K; Li, Z. & King, B: A split-and merge technique for automated reconstruction of roof planes. Photogrammetric engineering and remote sensing, vol.(71), 2005, Pp: 855-862.
5. Lack, N. & Bleisch, S: Object-based change detection for a cultural-historical survey of the Landscape - From cow trails to walking paths. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, vol. XXXVIII-4/C7, 2010.
6. Myint, S. W., Gober, P., Brazel, A., Grossman-Clarke, S., & Weng, Q: Per-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery. Remote Sensing of Environment, 2011, Pp: 1145-1161.