المركز الجغرافي الملكي الأردني

دور الذكاء الإصطناعي في المعلومات الجيومكانية

اعداد النقيب المهندس يوسف البنا

دراسة تطبيقية على مدينة العقبة

الكشف الآلي عن المعالم العمرانية باستخدام التعلم العميق والمرئيات الفضائية عالية الدقة

من الصورة الفضائية إلى المعرفة المكانية



المقدمة

- تشهد المدن نمواً عمرانياً متسارعاً يفرض تحديثاً مستمراً لقواعد البيانات الجيومكانية، وتوفر الصور الفضائية عالية الدقة تفاصيل كافية لتمييز المعالم العمرانية لكن حجم البيانات يتجاوز قدرة التفسير البصري بينما تبقى الرقمنة اليدوية للصور الفضائية بطيئة ومكلفة.

- يؤدي الذكاء الاصطناعي اليوم دور مهم في نظم المعلومات الجغرافية من حيث إنتاج البيانات المكانية من الصور الفضائية، وتحليل الأنماط ، ودعم القرار المكاني.

الفكرة الرئيسية

من الصورة الفضائية إلى المعرفة المكانية

- تبحث الدراسة في توظيف التعلم العميق ضمن بيئة نظم المعلومات الجغرافية لاستخراج معالم عمرانية محددة من المرئيات الفضائية وتحويلها إلى طبقات مكانية يمكن مراجعتها وتحليلها.

- تطوير إطار عمل قائم على الذكاء الاصطناعي الجغرافي لاستخراج المباني والتحقق الآلي من جودة بياناتها المكانية وتحسين دقتها الهندسية باستخدام الصور الجوية عالية الدقة.

- دعم إنتاج بيانات مكانية تفصيلية بصورة شبه آلية بإستخدام أدوات الذكاء الإصطناعي.

أهداف الدراسة وأهميتها

- بناء سير عمل متكامل يبدأ من الصورة الفضائية وينتهي بطبقات معالم جغرافية.
- إعداد بيانات تدريب لفئة المباني باستخدام مضلعات مرجعية.
- تدريب نموذج (Mask R-CNN) ضمن أدوات التعلم العميق في (ArcGIS Pro).
- إبراز القيمة العملية للذكاء الإصطناعي الجغرافي في تحديث قواعد البيانات الجغرافية لمدينة العقبة.

منطقة الدراسة: مدينة العقبة

موقع ساحلي يتسم بتباين النسيج العمراني والمساحات المفتوحة

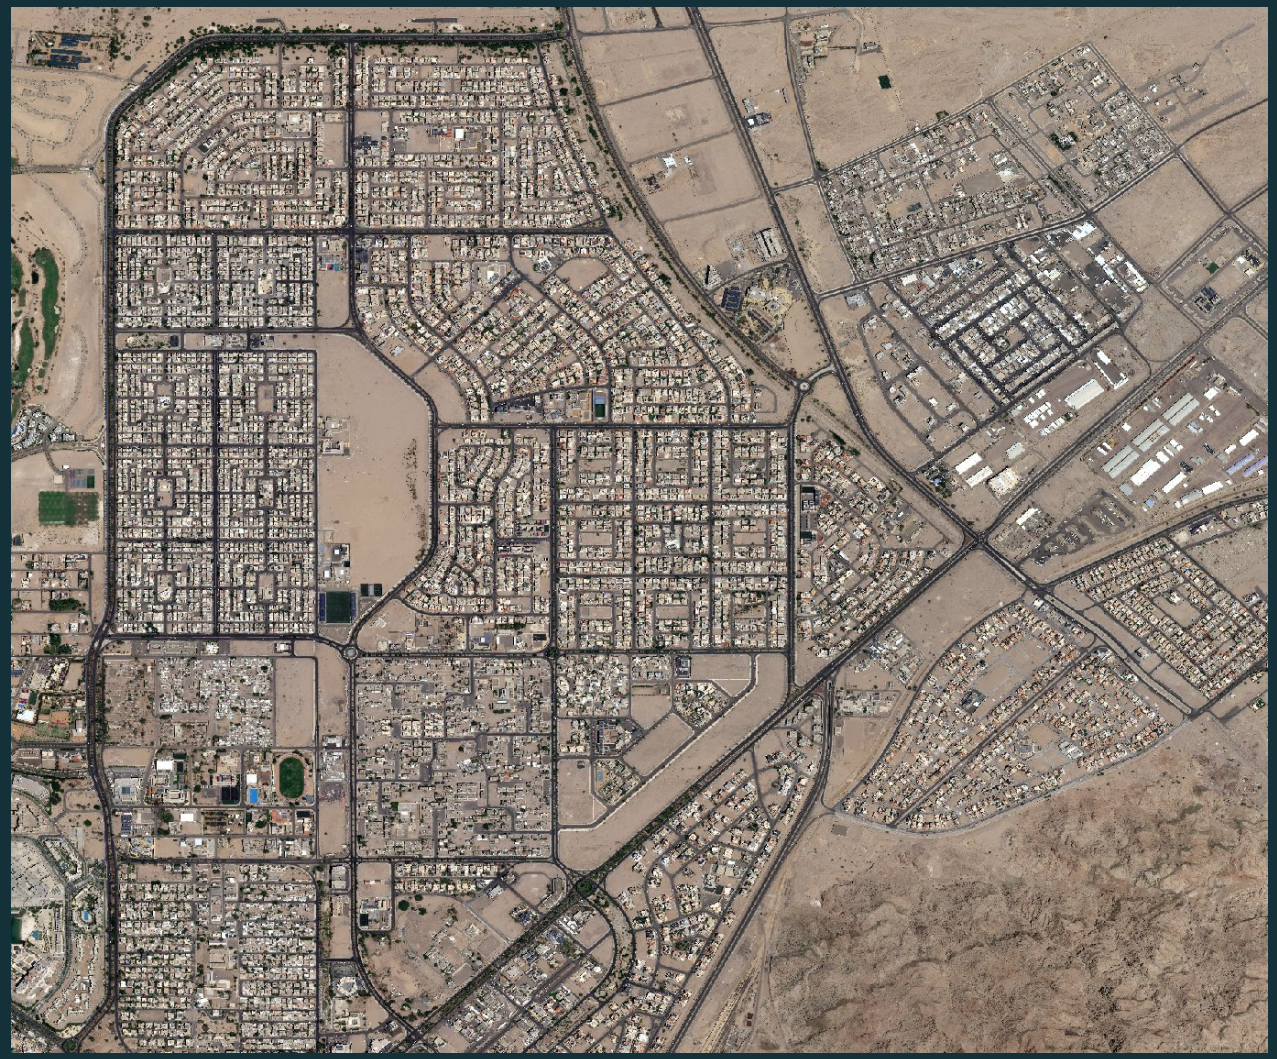

الموقع

مدينة العقبة، جنوب المملكة الأردنية الهاشمية.

الخصائص

أنماط عمرانية متنوعة، منتظمة، متلاصقة ومتفرقة، طرق واسعة، وأراضي جرداء.

أهمية الاختيار

بيئة مناسبة لاختبار قدرة النموذج على التمييز بين الأجسام.

الفئة المستهدفة

المباني

البيانات والأدوات المستخدمة



- صور فضائية بدقة عالية تصل الى 30 سم.
- ARCGIS PRO
- DEEP LEARNING
- Mask R-CNN

منهجية العمل

تجهيز البيانات.

- قص الصورة للمنطقة المراد العمل عليها وفحص الدقة ونظام الإحداثيات.

الدقة	30 CM
نظام الإحداثيات	WGS 84
النطاقات الطيفية	3

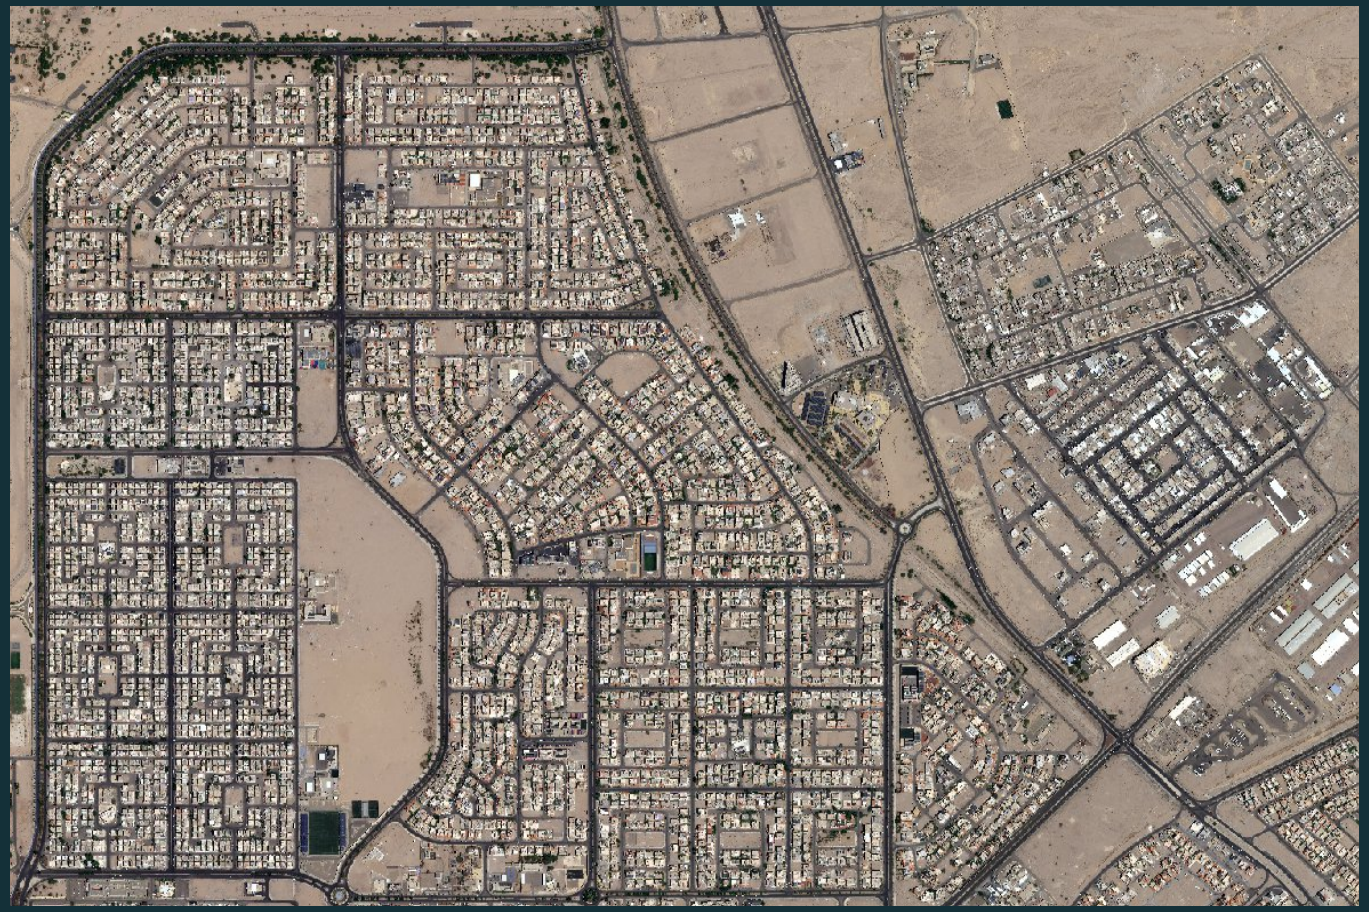

منهجية العمل

تعريف الفئات وبناء العينات المرجعية.

- الفئات المستهدفة المباني.

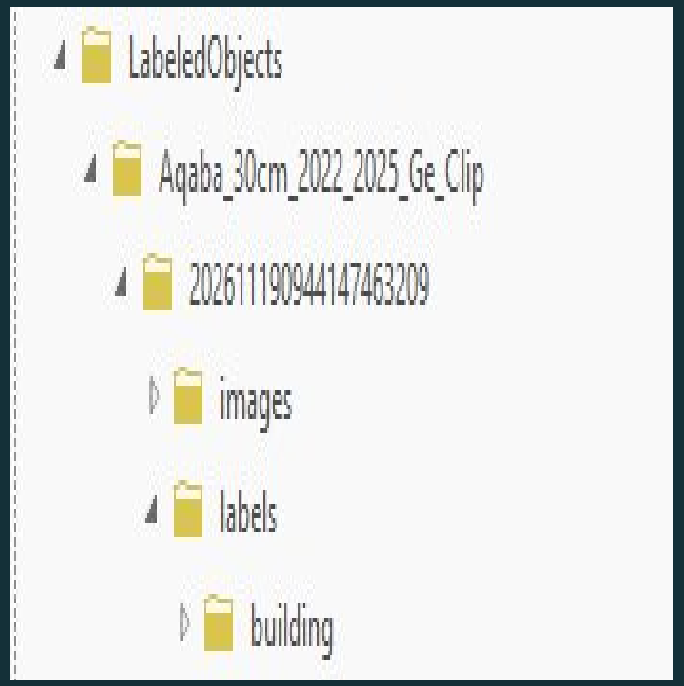



منهجية العمل

رسم المضلعات للفئات المستهدفة لتحديد ما يتعلمه النموذج.

- تنوع العينات يحد من إنحياز النموذج الى نمط معين.



حالات متفرقة



حالات متلاصقة



حالات متنوعة الشكل

منهجية العمل

المباني المتلاصقة

عينات توضح حدود المباني المتجاورة وصعوبة الفصل بين الكتل.

المباني المتفرقة والمتنوعة

عينات منفصلة تساعد على تمثيل اختلاف السياق والمسافات.

منهجية العمل

إعداد وتصدير بيانات التدريب.

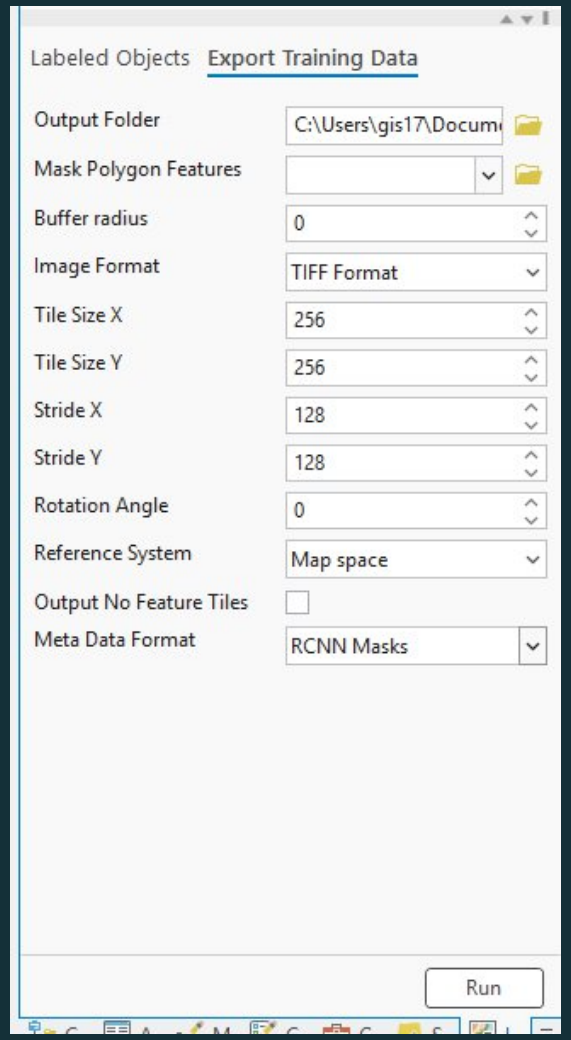

أعداد بيانات التدريب

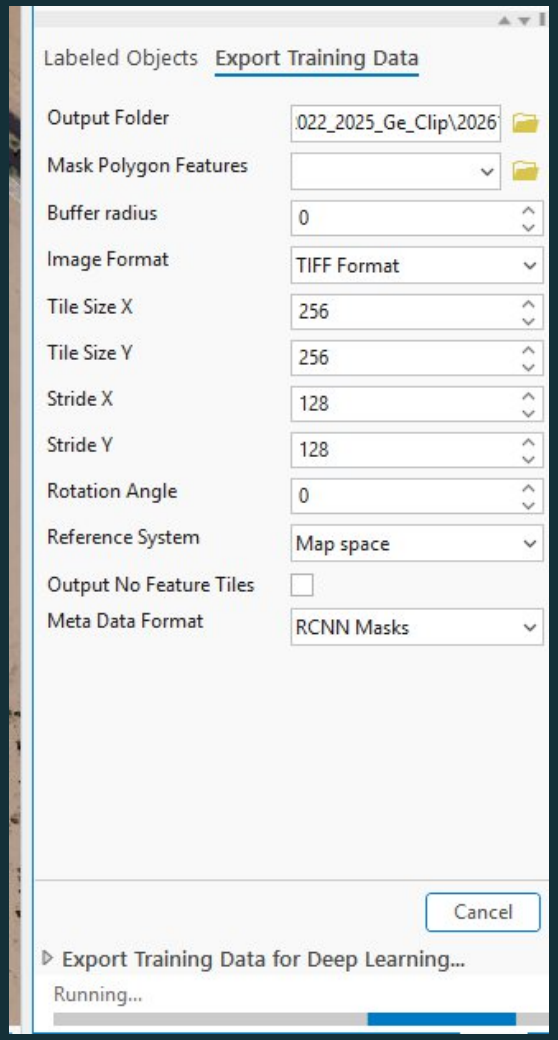

استخراج بيانات التدريب الخاصة بالنموذج

منهجية العمل

شكل عينات التدريب.

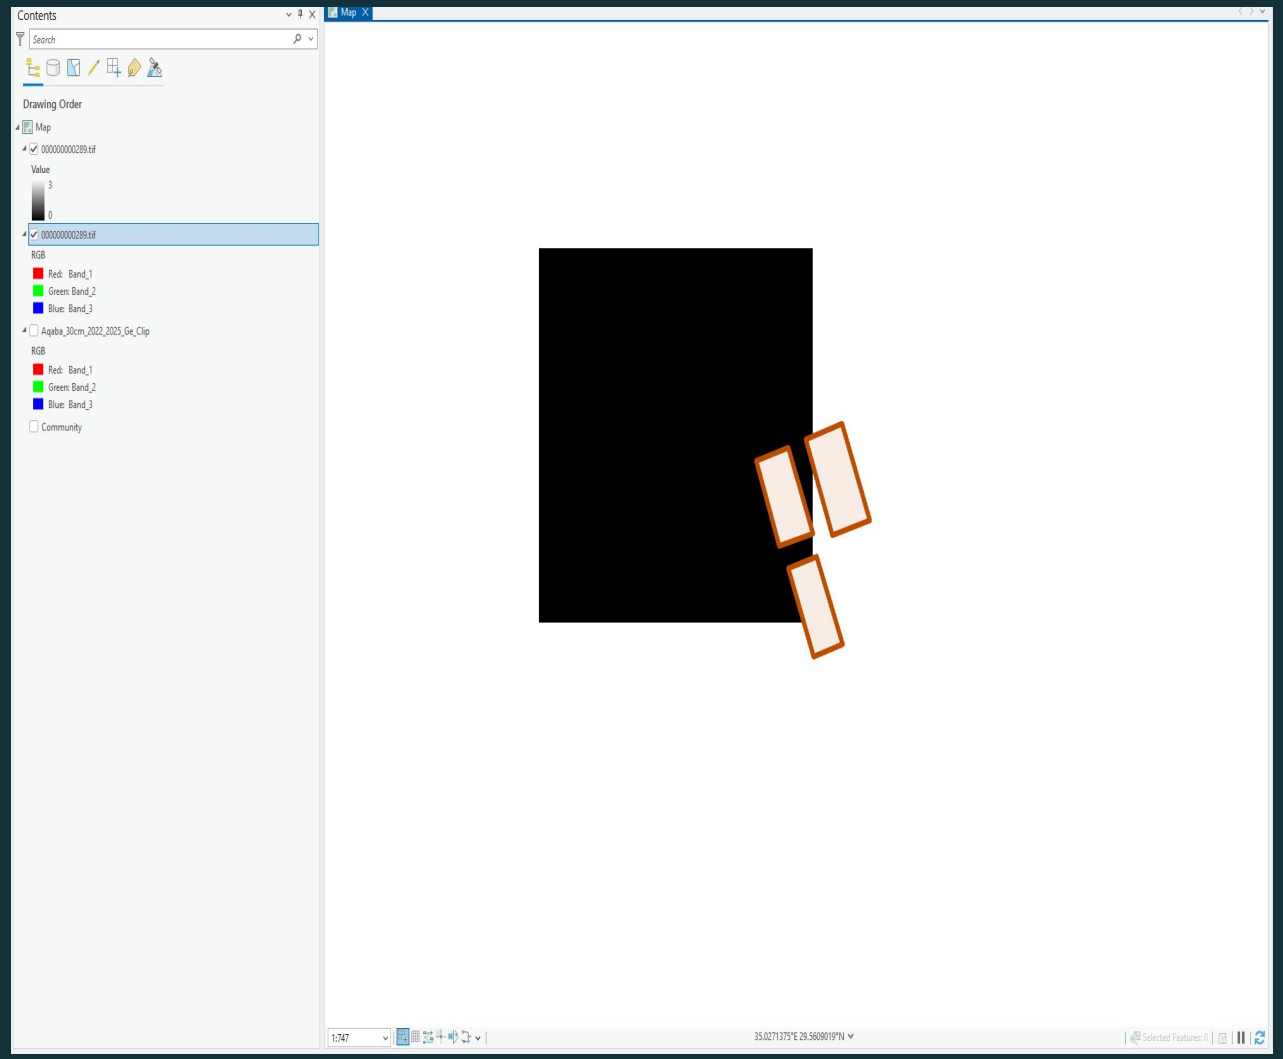

شكل عينات التدريب بعد المعالجة

منهجية العمل

إعداد نموذج التعلم.

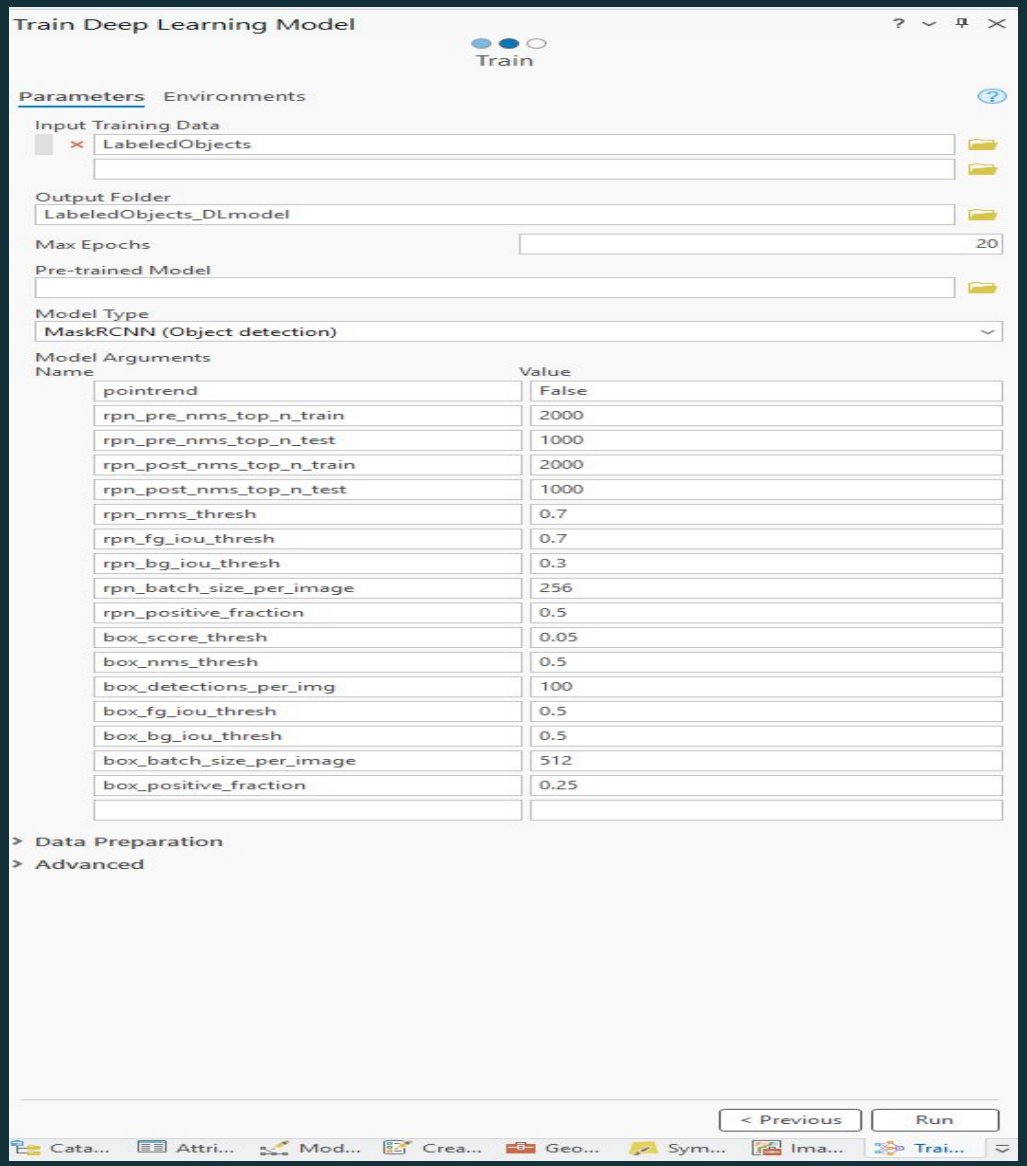

ملخص تجربة التدريب الأولى

المدة التدريبية

20 = Max Epochs

نوع النموذج

(Mask R-CNN (Object detection

البيانات

LabeledObjects

الفترة الزمنية

6 دقائق و 52 ثانية

مؤشرات عملية التدريب

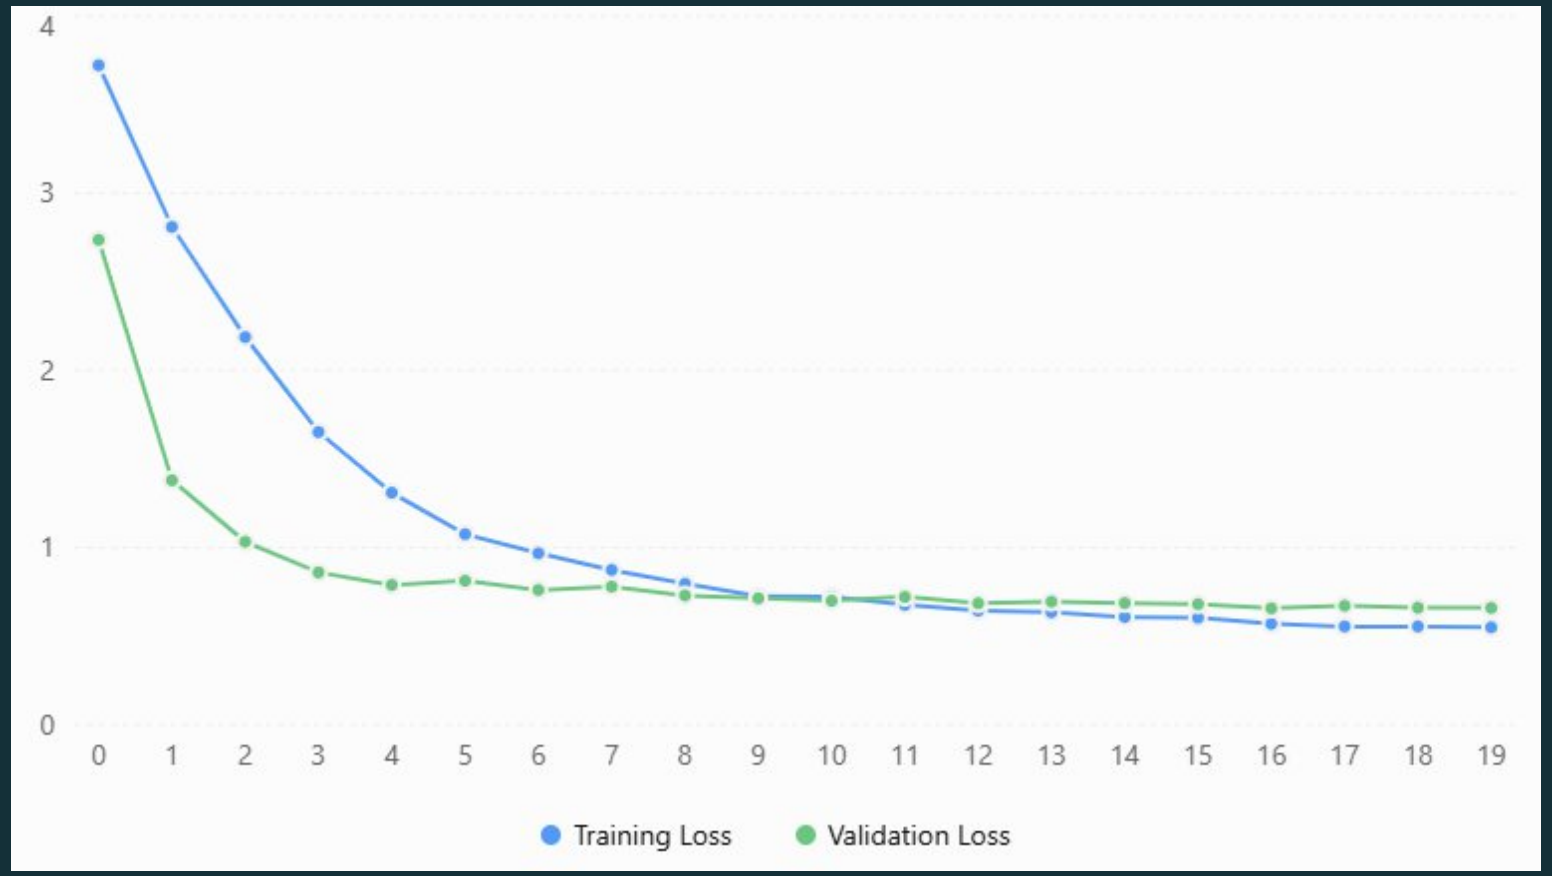

Training Loss

انخفض من 3.72 إلى 0.55

Validation Loss

انخفض من 2.74 إلى 0.66

انخفاض الخسارتين يعني أن النموذج أصبح أفضل في ملائمة بيانات التدريب، مع تحسن مماثل على بيانات التحقق، و قدرة النموذج على تعلم خصائص المعالم المستهدفة.

منهجية العمل

الكشف والتقييم المبدئي.

- تظهر المخرجات الأولية وبالكشف البصري عدم تعرف النموذج على كافة فئة المباني ضمن منطقة الدراسة.
- النموذج بحاجة إلى إعادة تعلم.

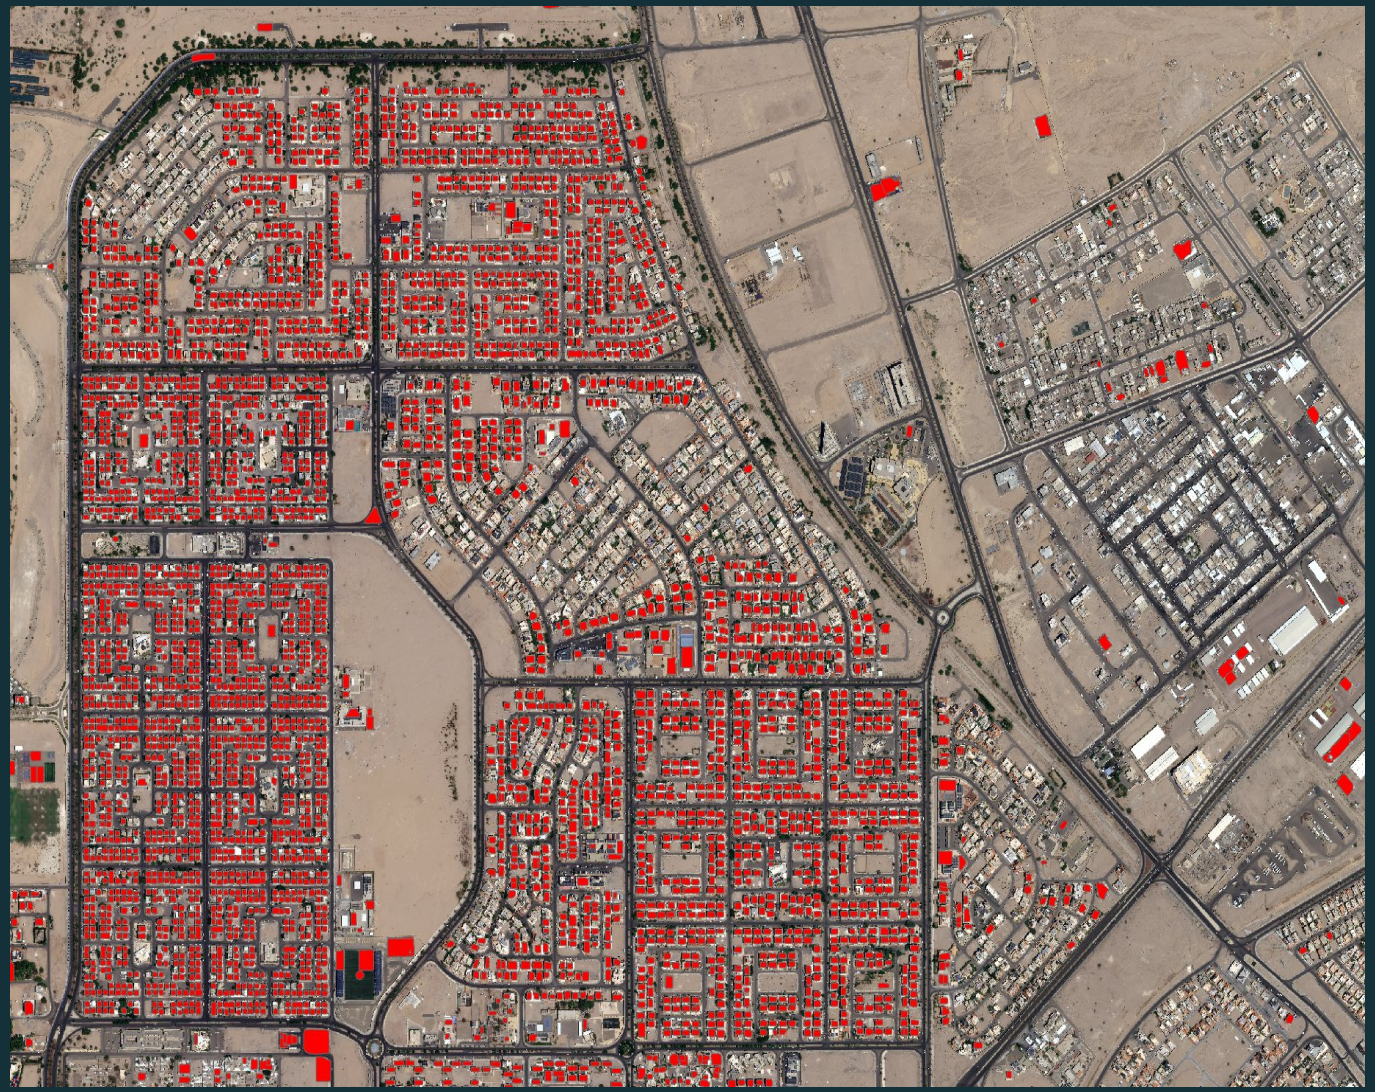

نتائج التدريب الأولية

Building
0.3542
Average Precision (AP)
≈ 35.42%

منهجية العمل

إعادة التدريب.

- تم رسم مضلعات مرجعية جديدة وإعادة عملية التدريب.

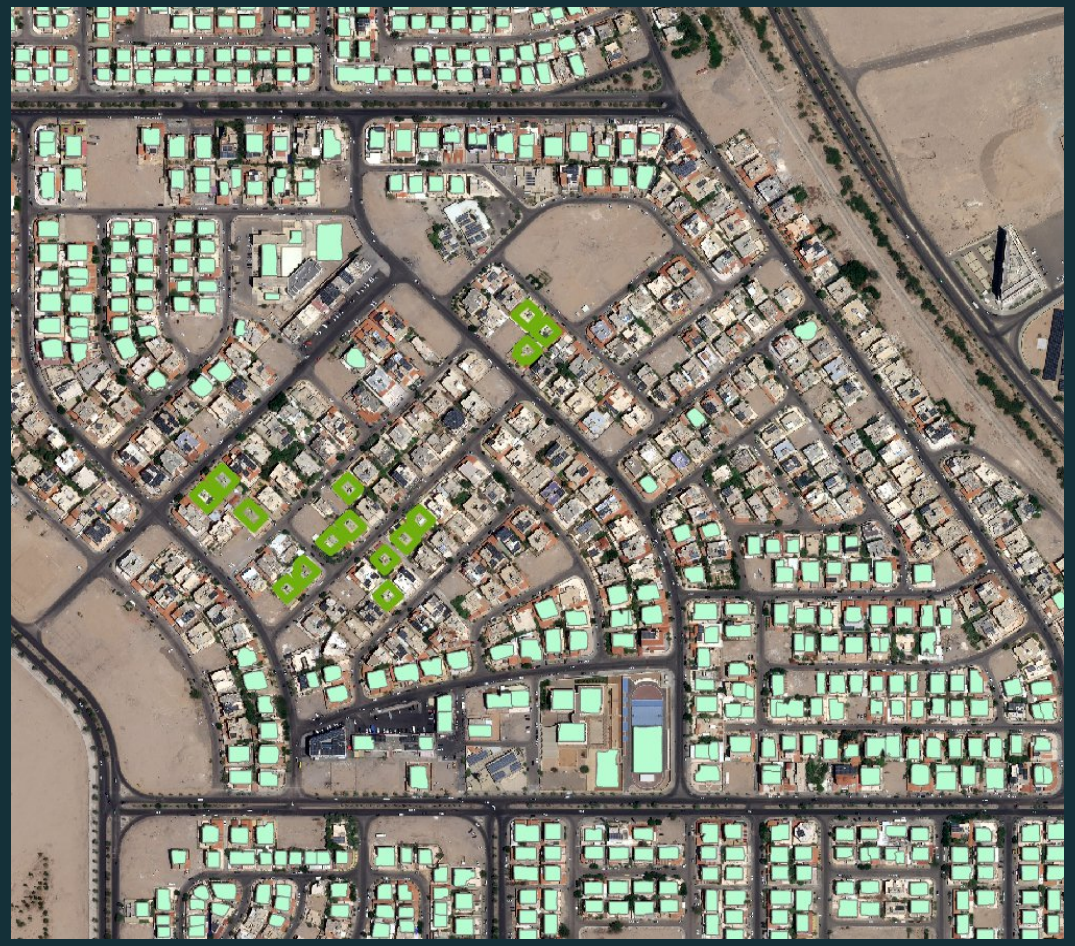

عينات التدريب الثانية

مؤشرات عملية التدريب



Training Loss

انخفض من 1.27 إلى 0.58

Validation Loss

انخفض من 1.01 إلى 0.59

منهجية العمل

إعادة الكشف والتقييم.

- تظهر المخرجات تحسن النموذج في التعرف على الفئة المستهدفة ضمن منطقة الدراسة.

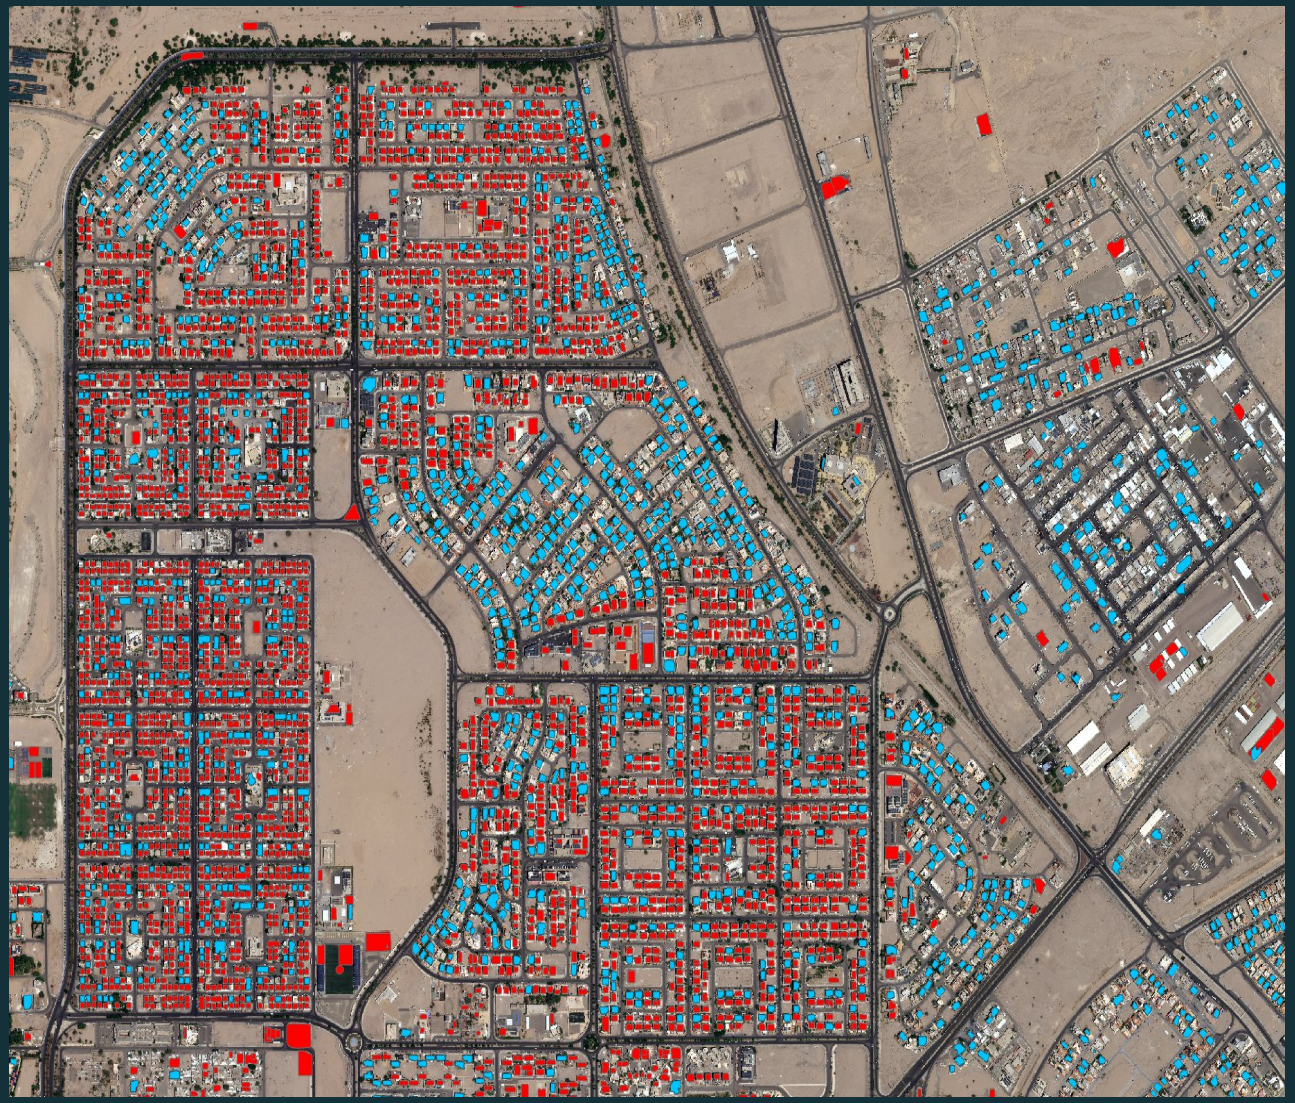

النتائج بعد إعادة التدريب

Building
0.6565
Average Precision (AP)
= 65.65%

منهجية العمل

إعادة الكشف والتقييم.

- تظهر المخرجات تحسن النموذج في التعرف على الفئة المستهدفة ضمن منطقة الدراسة.

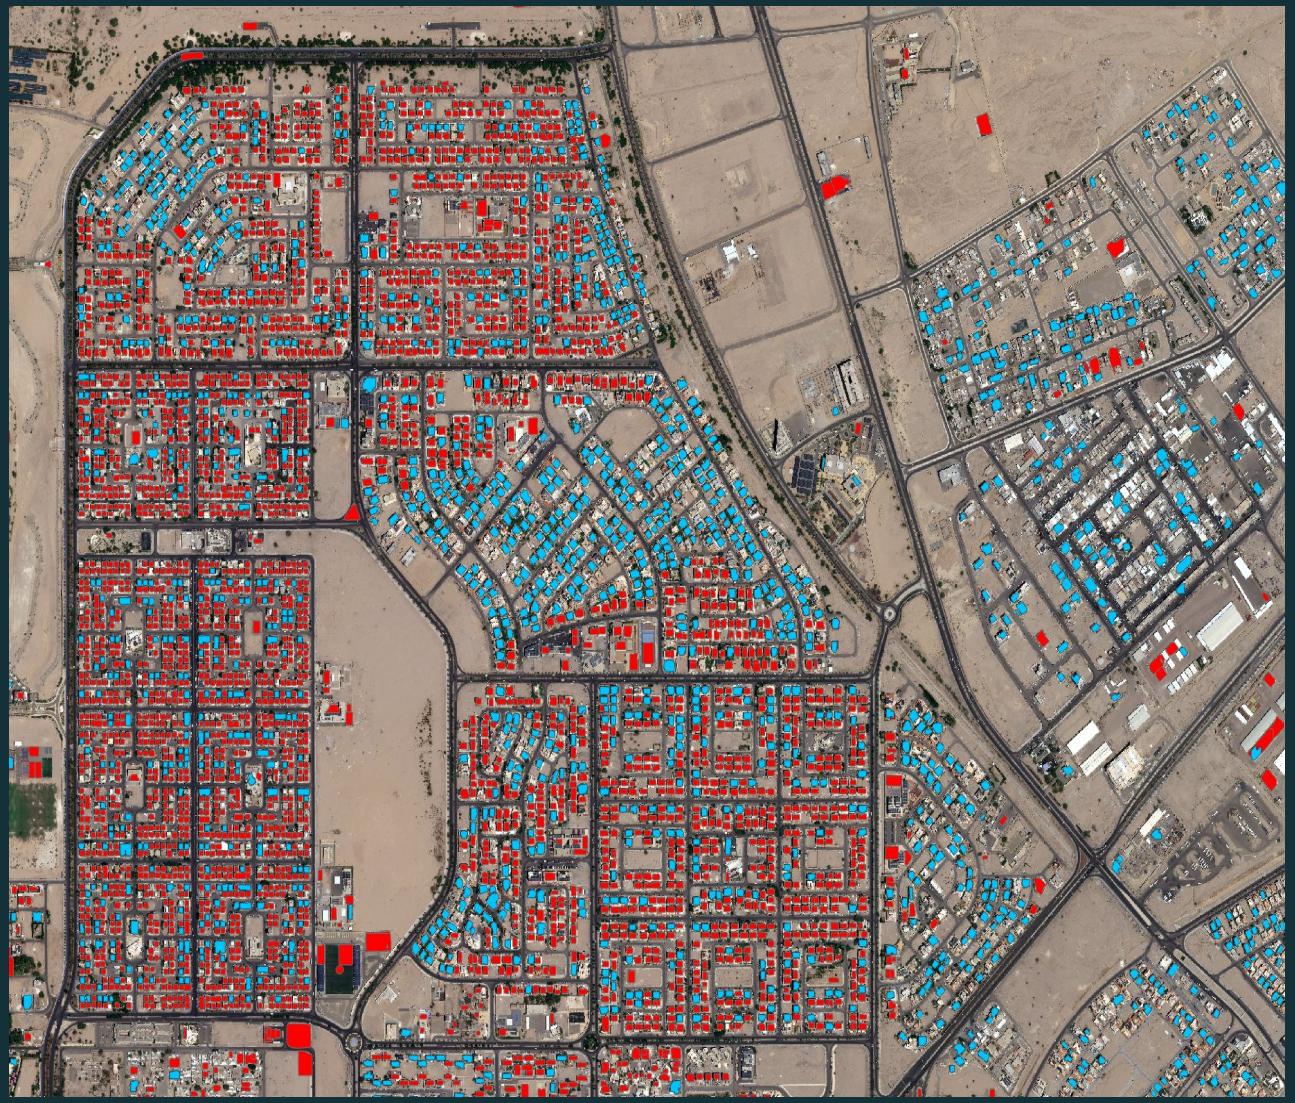

النتائج بعد إعادة التدريب

Building
0.6565
Average Precision (AP)
= 65.65%

التحديات و الضوابط

جودة البيانات

اختلاف الدقة وتاريخ البيانات ووجود فقدان أو تحييزفي بعض البيانات يؤثر في المخرجات النهائية و النتائج.

الخصوصية

البيانات عالية الدقة تتطلب حماية وضوابط وصول مع المحافظة على أمن المعلومات وحماية البيانات الجغرافية الحساسة من الإختراق وسوء الإستخدام.

التحقق

يجب فحص النتائج ومراجعتها من قبل المعنيين وكلٌ ضمن اختصاصه.

المسؤولية

القرار النهائي تخطيطي ويجب أن يبقى قابلاً للمراجعة البشرية.

التوصيات

- ربط المخرجات بقاعدة بيانات جيومكانية وإجراء تحليلات عمرانية.
- قابلية تعميم النموذج على مدن أخرى وتحويل المخرجات الى بيانات جيومكانية تدعم عملية صنع القرار.
- مراقبة التوسع العمراني ومقارنة التغيير بين تواريخ صور متعددة.
- تحديث البيانات وإتاحة طبقات قابلة للإستعلام المكاني وإنتاج الخرائط والتقارير.
- جمع جميع البيانات الجيومكانية تحت مظلة واحدة تشكل قاعدة بيانات وطنية مرجعية.
- الإبقاء على عامل التحقق البشري وعدم الإعتماد بشكل كامل على قدرة الذكاء الاصطناعي في أتمته انتاج المعلومات المكانية من الصور الفضائية.

الخلاصة

- توضح التجربة مساراً عملياً لدمج الذكاء الاصطناعي مع نظم المعلومات الجغرافية في بناء بيانات تدريب متخصصة لاستخراج المعالم من الصور الفضائية ومن ثم إنتاج طبقات مكانية، لكن القيمة الحقيقية تظهر عندما تُربط النتائج بسؤال مكاني واضح وبقرار قابل للتنفيذ قادرعلى تحقيق أهداف التنمية المستدامة.

المصادر والمراجع

- ROYAL GEOGRAPHIC CENTER DATABASE.
- Esri. (2026). Deep learning in ArcGIS Pro. doc.esri.com/en/arcgis-pro/latest/help/analysis/deep-learning/
- Esri. (2026). Detect objects. doc.esri.com/en/arcgis-pro/latest/help/analysis/image-analyst/detect-objects.html
- Esri. (2026). Detect Objects Using Deep Learning. doc.esri.com/en/arcgis-pro/latest/tool-reference/image-analyst/detect-objects-using-deep-learning.html
- He, K., Gkioxari, G., Dollár, P., & Girshick, R. (2017). Mask R-CNN. ICCV. https://doi.org/10.1109/ICCV.2017.322

شكراً لحسن استماعكم