

الكشف التلقائي عن مخالفات البناء باستخدام صور الطائرات بدون طيار وتقنيات الذكاء الاصطناعي: دراسة تطبيقية في مدينة جدة

أ. محمد يوسف المنتشري¹، أ. د. مفرح بن ضايم القرادي²، د. عادل سعيد الشمراني³

1. طالب دراسات عليا في قسم الجغرافيا . جامعة الملك سعود (المملكة العربية السعودية).
2. أستاذ في قسم الجغرافيا جامعة الملك سعود (المملكة العربية السعودية).
3. أستاذ مشارك بكلية علوم وهندسة الحاسب . جامعة جدة (المملكة العربية السعودية).

441106743@student.ksu.edu.sa

الملخص

تهدف هذه الدراسة إلى تدريب واختبار نموذج تعلم عميق باستخدام تقنيات الذكاء الاصطناعي (YOLOv4) من أجل الكشف التلقائي عن مخالفات بناء الملاحق من صور الطائرة بدون طيار في الوقت الفعلي في حي الأجاويد بمدينة جدة. تم تدريب النموذج على مجموعة بيانات تدريبية تحتوي على 800 صورة وتم استخدام موارد الحوسبة السحابية من Google Colab. بعد التدريب، تم تطبيق النموذج على صور الدرون لاكتشاف المخالفات في منطقة الدراسة. حيث تم رصد 256 عينة، منها 67 مبنى مخالف حيث تتجاوز فيها مساحة بناء الملحق عن 50% مقابل 189 مبنى لم يكن فيه مخالفة. أظهر النموذج دقة عالية في التنبؤ بالمخالفات بنسبة 91% و 87%، وكذلك دقة استدعاء عالية بنسبة 98% و 93% وبدرجة F1 بنسبة 0.95 و 0.90 وقدرة على تحديد التداخل المكاني بنسبة 84% و 79% في مجموعتي بيانات التدريب والاختبار على التوالي. كما أظهر النموذج دقة هندسية متوسطة بنسبة 7.1%. خلصت الدراسة إلى أهمية التقنيات الحديثة في دعم مراقبة مخالفات البناء، وتشير إلى إمكانية استخدام نموذج YOLOv4 المدرب لاكتشاف المخالفات وانتهاكات اشتراطات البناء بالوقت الفعلي.

الكلمات المفتاحية: الكشف التلقائي، مخالفات البناء، الوقت الفعلي، صور الطائرات بدون طيار الذكاء الاصطناعي، YOLOv4، مدينة جدة.

Automatic Detection of Building Violations Using Drone Imagery and Artificial Intelligence Techniques: An Applied Study in Jeddah

MohammadAl Montashri¹, Mufareh Alquradi², Adel Alshamrani³

1. Graduate Student in the Department of Geography, King Saud University (Saudi Arabia).
2. Professor in the Department of Geography, King Saud University (Saudi Arabia).
3. Associate Professor in the College of Computer Science and Engineering, University of Jeddah (Saudi Arabia).
441106743@student.ksu.edu.sa

Abstract

This study aims to train and test a deep learning model using artificial intelligence techniques, specifically You Only Look Once version 4 (YOLOv4), for real-time automatic detection of building extension violations from Drone images in Al-Ajaweed district (Jeddah city). The model was trained on a dataset of 800 images, and cloud computing resources from Google Colab were utilized. After training, the model was applied to Drone images to detect violations in the study area, where 256 samples were monitored. Among these samples, 67 buildings had violations, with the extension area exceeding 50%, while 189 buildings had no violations. The model showed high accuracy in predicting violations at 91% and 87%, as well as high recall accuracy at 98% and 93%, with an F1 score of 0.95 and 0.90. It also demonstrated the ability to detect spatial overlap at 84% and 79% in the training and test datasets, respectively. Furthermore, it showed an average geometric accuracy of 7.1%. The study emphasized the significance of modern technologies in supporting building violation monitoring and highlighted the potential of the trained YOLOv4 model for real-time detection of violations and non-compliance with building regulations.

Keywords: Automatic detection, building violations, real-time, aerial Drone images, artificial intelligence, YOLOv4, Jeddah city.

1. المقدمة

يعتبر الذكاء الاصطناعي (Artificial Intelligence AI) أحد الأركان الأساسية في الوصول لنموذج المدينة الذكية المستدامة، من خلال قدرته على تحليل مجموعات كبيرة من البيانات بشكل حسابي للكشف عن الأنماط التي تستخدم لإثراء عملية صنع القرار وتعزيزها (Bibri, 2019).

يشكل التعامل مع النمو الحضري، أحد التحديات التي تواجه البلدان النامية، في ظل عدم توافر وسائل تكنولوجيا للتعامل مع البيانات حول مخالفات البناء المختلفة (درويش، 2022)، لذلك تولي المملكة العربية السعودية أهمية كبيرة للاستفادة من البيانات الضخمة التي لديها سواء كانت مكانية أو غير مكانية لتحسين الأداء الإداري، وتحقيق رؤية 2030 التي تتبنى ضرورة تحقيق التنمية المستدامة (الغبيري وحسن، 2019).

في مدينة جدة يعتبر النشاط العمراني، أحد التحديات التي تواجه التحول نحو الاستدامة، نظراً لضرورة المحافظة على النسق العمراني للمدينة، لذلك تولي الجهات المختصة أهمية كبرى لمتابعة البناء من تشييد وتمديد وتعديل، حيث يمثل عدم احترام الرخص الممنوحة للبناء نوعاً من المخالفة التي يفترض رصدها ومتابعتها لعدم تنامي هذه الظاهرة بانعكاساتها على المحيط العمراني. على سبيل المثال تنص اشتراطات البناء، في مدينة جدة على أن بناء ملاحق الأسطح يجب ألا يزيد عن نسبة 50% من نسبة السطح الكلي، وتعتبر الزيادة في ملحق السطح مخالفة من المخالفات التي تسعى إدارة المدينة إلى التعامل معها لما لها من انعكاسات سلبية.

يمثل توفر البيانات حول البناء ووضعيتها في المدينة تحدياً رئيسياً لعملية المتابعة. في حالات كثيرة لا يستطيع المراقب الوصول إلى المخالفة، مما يصعب من عملية رصد المخالفات. لذلك من المناسب اللجوء إلى استخدام الطائرات بدون طيار لما توفره من صور عالية الدقة، ومعالجتها من خلال خوارزميات الذكاء الاصطناعي المختلفة للكشف التلقائي عن مخالفات البناء.

2. مشكلة الدراسة

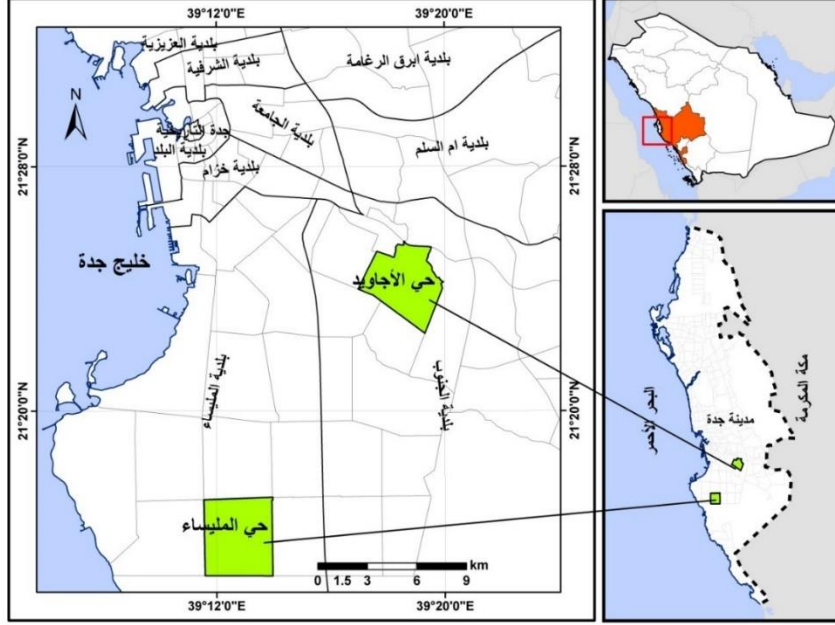
تشمل الطريقة الحالية للسيطرة على مخالفات البناء عمليات التفتيش الميداني على أساس المعرفة البشرية والتي تحتاج إلى إنفاق الموارد المالية والوقتية والبشرية الباهظة، أو حتى الفشل في تحديد مخالفات البناء في الوقت المناسب (Fahmideh Modami et al., 2022). من جهة أخرى، تواجه مراقب البلدية في مجال مخالفات البناء بعض العوائق أثناء عمله، ومن تلك المعوقات صعوبة رصد بعض المخالفات التي يصعب الوصول لها وكذلك صعوبة الحصول على بيانات الرخصة من المالك، مما يحول دون إتمام عملية اكتشاف تلك المخالفة وإثباتها (جمال، 2013).

يمكن صياغة مشكلة الدراسة من خلال التساؤلات الرئيسية التالية:

1. هل يمكن تدريب نموذج تعلم عميق في الذكاء الاصطناعي لاستخلاص مخالفات بناء الملاحق من صور الدرون في مدينة جدة؟
2. ما هو الدور الذي يمكن أن تلعبه الطائرات بدون طيار في رصد وتصوير بيانات مخالفات البناء في مدينة جدة، وما هي كفاءة النموذج المقترح في استخلاص هذه المخالفات؟

3. منطقة الدراسة

تقع الحدود المكانية للدراسة في أقصى المنطقة الغربية لمكة المكرمة، وتحديدًا مدينة جدة المطلة على البحر الأحمر. تقع مدينة جدة بين دائرتي عرض (10° 21' - 16° 21') شمال الدائرة الاستوائية، وخطي طول (5° 39' - 20° 39') شرق جرينتش، الشكل 1. أما الموقع الخاص فيشمل منطقتين داخل مدينة جدة؛ المنطقة الأولى حي الملبس، والمنطقة الثانية حي الأجاويد. تم اختيار منطقتي الدراسة لتطبيق النموذج على النسيج العمراني المتنوع لمدينة جدة، وذلك لاختبار مدى قدرة وملائمة النموذج في العمل على استكشاف ورصد مخالفة بناء الملاحق العلوية آلياً.



الشكل 1. الموقع الجغرافي لمنطقة الدراسة

المصدر: اعداد الباحث من بيانات أمانة مدينة جدة

4. أهمية وأهداف الدراسة

تتبع أهمية الدراسة من خلال توظيف التقنيات الحديثة ولا سيما الذكاء الاصطناعي عبر معالجة وتحليل صور الطائرات دون طيار ذات الدقة العالية لرصد مخالفات البناء، مما يساهم في خفض المخالفات والتشوه البصري وتخفيف الضغط على البنية التحتية، ويعزز الوصول لتحقيق أهداف التنمية العمرانية المستدامة. تهدف الدراسة بشكل رئيسي إلى تدريب واختبار نموذج تعلم عميق باستخدام تقنيات الذكاء الاصطناعي YOLO v4 من أجل الكشف التلقائي عن مخالفات بناء الملاحق من صور الدرون في منطقة الدراسة.

5. طرائق البحث ومواده

1.5 كشف الأشياء من الصور

يعتبر كشف الأشياء من الصور أحد مهام الرؤية الحاسوبية (computer vision)، تتضمن تحديد الأشياء وتحديد موقعها في الصور أو مقاطع الفيديو (Kaur & Singh, 2022). وهو جزء مهم في العديد من التطبيقات، مثل المراقبة أو الروبوتات أو حتى كشف المخالفات. يمكن تقسيم خوارزميات اكتشاف الأشياء إلى فئتين رئيسيتين: خوارزميات الكشف ذات اللقطة الواحدة (single-shot detectors) وخوارزميات الكشف ذات اللقطتين (two-stage detectors) (Kaur & Singh, 2022).

يستخدم اكتشاف الأشياء بلقطة واحدة تمريرة واحدة للصورة المدخلة لإجراء تنبؤات حول وجود الأشياء وموقعها في الصورة. فهو يعالج الصورة بأكملها في مسار واحد، مما يجعلها فعالة من الناحية الحسابية. يمكن استخدام مثل هذه الخوارزميات لاكتشاف الأشياء في الوقت الفعلي في البيئات المحدودة الموارد (Kaur & Singh, 2022; Pham et al., 2020). يعد اكتشاف الأشياء ذات اللقطتين أكثر دقة من اكتشاف الأشياء بلقطة واحدة ولكنه أيضاً أكثر تكلفة من الناحية الحسابية (Kaur & Singh, 2022; Pham et al., 2020).

1.1.5 خوارزميات كشف الأشياء من الصور في الوقت الفعلي

يعتبر اكتشاف الأشياء في الصور في الوقت الفعلي مهمة رؤية حاسوبية تتضمن تحديد الأشياء محل الاهتمام وتحديد موقعها في الصور أو تسلسلات الفيديوها في الوقت الفعلي مع الحفاظ على مستوى أساسي من الدقة (Kaur & Singh, 2022). يتم حل هذه المشكلة عادةً باستخدام الخوارزميات التي تجمع بين تقنيات اكتشاف الأشياء وتتبعها بدقة في الوقت الفعلي (Kaur & Singh, 2022; Redmon & Angelova, 2015). (May)

2.1.5 خوارزمية YOLO — You only look once

في مجال اكتشاف الأشياء في الوقت الفعلي، حظيت سلسلة نماذج YOLO باهتمام كبير لسرعتها ودقتها. YOLO هو نموذج للكشف عن الأشياء في الوقت الفعلي. تم

تطوير YOLO لأول مرة بواسطة الباحث جوزيف ريدموند وفريقه في جامعة واشنطن في عام 2015. ويعتبر YOLO نموذجاً شهيراً وقوياً في مجال الرؤية الحاسوبية والذكاء الاصطناعي (Redmon & Angelova, 2015).

تعمل طريقة YOLO عن طريق تقسيم الصورة إلى شبكة من الخلايا أو البكسلات. يتم تدريب YOLO على مجموعة واسعة من الصور التي تحتوي على تصنيفات الأشياء المختلفة ومربعات الحدود (bounding boxes) التي تحيط بتلك الأشياء. يتعلم النموذج من هذه الصور لتوقع التصنيفات وحدود المربعات في الصور الجديدة (Redmon & Angelova, 2015; Nair et al., 2021).

بدلاً من تقسيم الصورة إلى عدة أجزاء صغيرة، يستخدم YOLO الشبكة الكاملة للتنبؤ بالأشياء مباشرة. يقوم النموذج بإخراج مجموعة من المربعات والتصنيفات المحتملة للكائنات في الصورة. يتم توليد هذه المربعات والتصنيفات بنفس الوقت، وبالتالي فإن YOLO يقوم بكشف الأشياء في الوقت الفعلي (Redmon & Angelova, 2015).

تستخدم YOLO شبكة عصبية عميقة مع بنية Darknet أو بنية معدلة منها لتنفيذ عملية الكشف. يتم استخدام الشبكة لتوليد مجموعة من حدود المربعات المقترحة ويحتوي كل مربع على تصنيف محتمل ودقة توقع الكائن. يتم استخدام عملية تصفية لاحقة للحد من عدد المربعات وتحسين الدقة (Pham et al., 2020).

من مزايا YOLO أنه يعمل بسرعة عالية وقادر على كشف الأشياء في الوقت الفعلي. كما أنه يمكنه التعامل مع صور متعددة الأشياء وكشف الأشياء المتداخلة. بفضل تصميمه الفريد، فإن YOLO يعتبر أحد الخيارات الشائعة لتطبيقات مثل التحكم في حركة المرور والتصوير الجوي وكشف المخالفات والعديد من التطبيقات الأخرى (Kaur & Singh, 2022).

قمنا في هذا البحث باستخدام YOLOv4، الإصدار الرابع من هذه السلسلة. YOLOv4 هو نتاج للجهود التعاونية لمجتمع البحث، مع مساهمات ملحوظة من Alexey Bochkovskiy، فريق Ultralytics، وجوزيف ريدموند، المبتكر الأصلي لسلسلة YOLO.

يستخدم YOLOv4 في جوهره أسلوب المرور الفردي لاكتشاف الأشياء. وهذا يعني أنه يتنبأ في الوقت نفسه بالمربعات المحيطة بالكائن واحتمالات فنتها في تمرير أمامي واحد عبر الشبكة العصبية (Nair et al., 2021).

يسمح استخدام صناديق الربط لـ YOLOv4 بالتنبؤ بمواقع الأشياء بشكل فعال بغض النظر عن أحجامها ونسب العرض إلى الارتفاع. تمكن هذه القدرة على تكيف النموذج للتعامل مع الأشياء المتنوعة الموجودة في المشهد دون الحاجة إلى تعديلات معقدة أو تغيير حجم مربعات التثبيت. يتضمن YOLOv4 العديد من التحسينات دون المساس بالدقة. كما تعمل خيارات التصميم الفعالة على تبسيط العمليات الحسابية. تساهم هذه التحسينات بشكل جماعي في زيادة سرعة النموذج (Carrinho & Falcao 2023,) (Alahmadi et al., 2023).

3.1.5 YOLO لتطبيقات الطائرات بدون طيار

عندما يتعلق الأمر بالكشف عن الأجسام باستخدام الطائرات بدون طيار، يبرز نموذج YOLO كحل مناسب للغاية مقارنة بالنماذج التقليدية ذات اللقطتين (Nair et al., 2021). إن كفاءة YOLO من حيث الحساب واستخدام الذاكرة تجعلها مناسبة تماماً للنشر على الطائرات بدون طيار. تسمح بنيتها المدمجة وعملية الاستدلال المبسطة بالاستخدام الفعال للأجهزة الموجودة على متن الطائرة، مما يضمن قدرة الطائرة بدون طيار على معالجة البيانات المرئية الواردة واكتشاف الأشياء دون المساس باستقرار الرحلة أو عمر البطارية (Qin et al., 2021; Koubaa et al., 2023).

أثبتت دراسة أجراها Li et al (2020) فعالية YOLO في اكتشاف الأجسام المعتمدة على الطائرات بدون طيار. تركز الدراسة على استخدام YOLO لاكتشاف وتتبع الأجسام في الوقت الفعلي من الصور التي تلتقطها الطائرات بدون طيار.

2.5 التقنيات والبرمجيات المستخدمة لتنفيذ المنهجية

تم في هذا البحث استخدام مجموعة من التقنيات والبرمجيات لتنفيذ YOLO لكشف مخالقات الأسطح بواسطة خوارزميات التعلم العميق مثل: (1) الطائرة بدون طيار من

نوع Pro 2 DJI Mavic والتي تم استخدامها لالتقاط صور بدقة مكانية عالية لمنطقة الدراسة.

(2) لغة البرمجة Python وهي مستخدمة على نطاق واسع في مجالات متعددة بما في ذلك الذكاء الاصطناعي وتحليل البيانات (Pronin, 2021; Pronin, 2021). (3) منصات Google Drive و Google Colab، حيث أصبح تدريب YOLOv4 على Google Drive باستخدام Google Colab ممارسة شائعة بسبب إمكانية الوصول وسهولة الاستخدام المتاحة عبر هذه المنصات. توفر Google Colab موارد GPU مجانية يمكن أن تسرع بشكل كبير عملية تدريب YOLOv4. تُحفظ الأوزان التي تم تدريبها في مجلد محدد على Google Drive، والتي يمكن استخدامها لاحقاً في مهام اكتشاف الأشياء. (4) منصة Google Cloud والتي تقدم العديد من المزايا عند استخدامها لتدريب YOLOv4. إحدى المزايا الرئيسية هي توافر وحدات المعالجة المركزية الرسومية القوية التي يمكن أن تسرع بشكل كبير عملية التدريب YOLOv4. وهذا يمكن أن يبسط عملية إعداد وتشغيل YOLOv4 في السحابة (Solawetz et al., 2020; Ekanayake et al., 2022; Balzano et al., 2022).

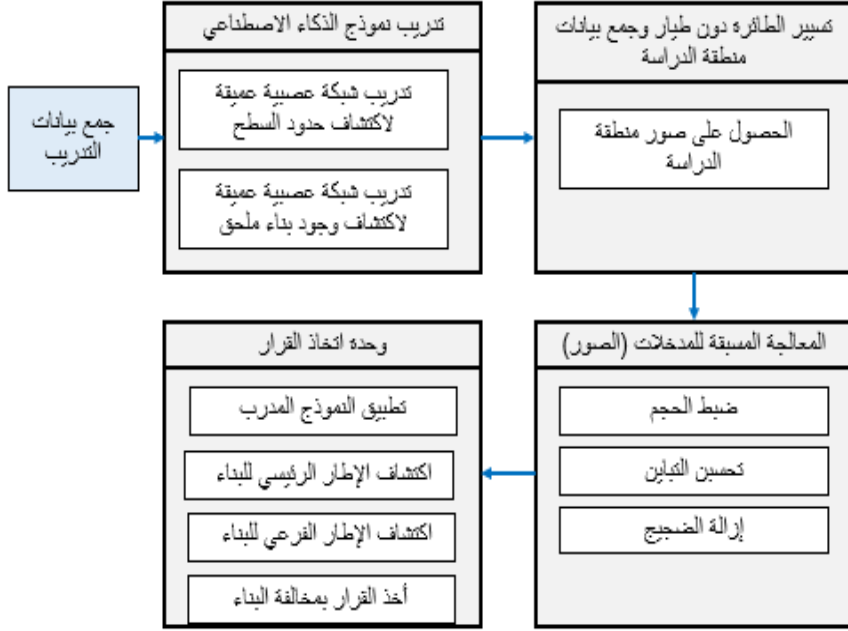
6. المنهجية والتحليل

1.6 بيانات الدراسة

إن مصادر البيانات المستخدمة لتدريب نموذج الذكاء الاصطناعي هي صور طائرة بدون طيار مأخوذة سابقاً من قبل أمانة جدة لمنطقة المليساء، بالإضافة لبعض الصور المأخوذة من منطقة الدراسة (حي الأجاويد)، حيث بلغ عدد صور التدريب حوالي 800 صورة. أما مصادر البيانات المستخدمة لاختبار نموذج الذكاء الاصطناعي فهي صور الطائرة بدون طيار من نوع DJI Mavic 2 Pro والتي بلغ عددها 256 صورة.

2.6 مراحل الدراسة

يتكون الجزء العملي لمشروع البحث من المراحل الرئيسية الموضحة في الشكل 2.



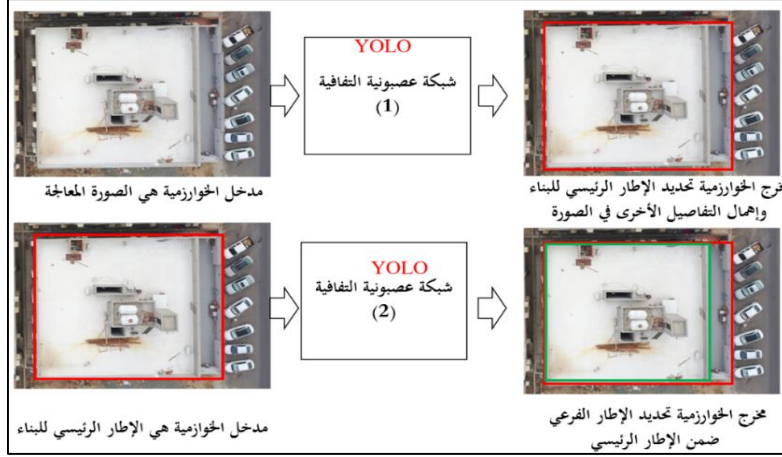
الشكل 2. المنهجية العامة المقترحة للجزء العملي.

3.6 معالجة البيانات

1.3.6 تدريب الشبكات العصبونية العميقة

في هذه الخطوة قمنا بتدريب شبكة عصبونية التلافيفية من نوع YOLOv4 ومدخل هذه المرحلة هي الصور التي خضعت لمعالجة مسبقة، أما مخرجها فهو بداية تحديد الإطار الخارجي للبناء المراد اكتشاف وجود المخالفة فيه والذي سندعوه الإطار الرئيسي للبناء ومن ثم تحديد المساحات المشغولة داخله وذلك عن طريق تحديد وجود بناء (أو ملحق) فيه، وفي حال وجوده سيتم تحديده بإطار والذي سنطلق عليه الإطار الفرعي للصورة. يوضح الشكل 3 مدخلات ومخرجات الشبكة.

لتدريب نموذج YOLOv4، استخدمنا موارد الحوسبة السحابية من Google Colab. لقد استخدمنا إطار عمل Darknet، وهو تطبيق يستخدم على نطاق واسع لنموذج YOLOv4، لهذا الغرض. أثناء التدريب، تعلم النموذج كيفية تحديد أسطح المباني بناءً على مجموعة البيانات.



الشكل 3. مدخلات ومخرجات الشبكة العصبونية الالتفافية

عند الانتهاء من عملية التدريب، قمنا بحفظ أوزان نموذج YOLOv4 المدرب على Google Drive. أتاحت لنا هذه الخطوة تخزين معلمات النموذج المدرب وتكويناته بشكل آمن في السحابة، مما يضمن الحفاظ على المعرفة المكتسبة وتمكين المشاركة بسهولة مع المتعاونين أو الأنظمة الأساسية الأخرى. تم دمج أوزان النماذج المخزنة بسلاسة في بيئة Cloud Google. من خلال استخدام APIs Cloud Google، أنشأنا رابطاً بين نموذج YOLOv4 المُدرَّب والتطبيقات المستندة إلى السحابة، مما يجعل إمكانات اكتشاف النموذج متاحة لمهام اكتشاف الأشياء في الوقت الفعلي على الطائرات بدون طيار. لقد أتاحت لنا هذا التكامل الاستفادة من دقة النموذج وكفاءته في التحليل الفوري للصور الملتقطة بطائرة بدون طيار.


2.3.6 المعالجة المسبقة للمدخلات

بعد النقاط الصور من الطائرة بدون طيار يتم إرسالها إلى النظام والذي يقوم بدايةً بمعالجة الصورة لجعلها مناسبة لتكون مدخلاً للمرحلة التالية. وهي مجموعة من الخطوات الرئيسية التي تهدف إلى زيادة دقة ووضوح الصورة لأن دقة المدخلات تؤدي إلى دقة المخرجات وهذه الخطوات هي: إزالة الضجيج من الصورة في حال وجوده من خلال تطبيق الفلتر

((Filter Gaussian) على الصورة والذي يستخدم بشكل عام لإزالة الضجيج الناتج عن ظروف البيئة غير المناسبة لحظة التقاط الصورة ((2018, Nair and Singh). كما تم تحسين التباين في الصورة بتطبيق تقنية معايرة الرسم البياني (Histogram Equalization) وهي مهمة جداً في تحسين جودة الصورة، وبالنسبة لعملمنا فقد تكون الصورة الملتقطة تحتوي على جزء مظلم قليلاً نتيجة ظروف جوية غير مناسبة بشكل كاف، ولذلك فإن هذه التقنية تجعل الرسم البياني للصورة متوزع بشكل منتظم على كامل المجال اللوني للصورة (al et Sangaiah, 2022). وفي نهاية هذه المرحلة لا بد من ضبط حجم الصورة لتتناسب مع دخل الشبكات العصبونية في المراحل التالية.

3.3.6 وحدة اتخاذ القرار

لقد أطلقنا على هذه المرحلة اسم "وحدة اتخاذ القرار"، وذلك نظراً لأن الهدف الرئيسي لها هو اتخاذ قرار نهائي بشأن وجود تعدي أو عدمه فيما يتعلق بالبناء. يعتبر مدخل هذه المرحلة هو الصور المحسنة، وذلك بفضل إجراء عمليات إزالة الضوضاء وتحسين التباين وتوحيد حجم الصورة. في هذه المرحلة، وقبل البدء بعملية تطبيق نموذج الذكاء الاصطناعي الذي تم تدريبه في المرحلة الأولى للبحث نقوم باختبار شرط الارتفاع (عتبة الارتفاع) والتي تم تحديدها بثمانية أمتار، فإذا كان ارتفاع البناء ضمن العتبة، فهو ضمناً غير مخالف ويستثنى البرنامج من المعالجة وإلا يتم المتابعة في عملية التطبيق، حيث يتم الحصول على نتائج تشمل كل من الإطار الفرعي والإطار الرئيسي للبناء المدروس. يوضح الشكل 4 طريقة الحصول على ارتفاع البناء أثناء عملية التقاط الصور بالدرسون.



الشكل 4. طريقة الحصول على ارتفاع البناء

بعد ذلك، ستتم المقارنة بين الإطار الفرعي والإطار الرئيسي ويتم حساب مساحة كل منهما. هذا يساعدنا في تحديد ما إذا كان البناء مخالفاً أم لا، وما هي نسبة التعدي في هذا البناء. تعتمد هذه المرحلة على مقارنة مساحة الإطار الفرعي مع الإطار الرئيسي، وفي حالة تجاوز نسبة الإطار الفرعي نسبة 50% من الإطار الرئيسي، يتم اعتبار البناء مخالفاً. وبناءً على ذلك، يُحسب مقدار التعدي والذي يكون هو النسبة التي تزيد على 50% من مساحة الإطار الرئيسي.

من أجل القيام بما سبق تم تطوير برنامج سطح مكتب وسيط بين طائرة DJI بدون طيار و Google Cloud AP باستخدام لغة بايثون حيث يوضح الشكل 5 واجهة البرنامج.

الشكل 5. برنامج سطح المكتب المطور والمستخدم لسحب بيانات الصورة من وحدة تحكم الطائرة بدون طيار

من خلال تطوير هذا البرنامج، نجحنا في عرض حل لاكتشاف الأشياء في الوقت الفعلي. تعمل معلمات البرنامج القابلة للتكوين من قبل المستخدم والاتصالات المبسطة على إنشاء جسر بين الصور التي تلتقطها الدرون وخوارزميات الكشف عن الأشياء المتقدمة.

7. النتائج والمناقشة

1.7 نتائج تدريب النموذج YoloV4

لتقييم أداء نموذج YoloV4، قمنا بإجراء حساب الدقة اعتماداً على مجموعة من المعايير أهمها دقة الاسترجاع ودقة الصحة ودقة القياس (Recall, Precision, F-measure) (Powers, 2020; درويش وآخرون، 2021) بالإضافة للتقاطع عبر الاتحاد (IoU).

يوضح الجدول 1 النتائج التي حصلنا عليها نتيجة تطبيق النموذج YoloV4 من أجل اكتشاف السطح.

الجدول 1. نتائج مقاييس الدقة في اكتشاف السطح باستخدام YoloV4

| Dataset | Precision | Recall | F1 | IoU |
|---------|-----------|--------|--------|---------|
| Train | 0.9133 | 0.9833 | 0.9460 | 84.2466 |
| Test | 0.8733 | 0.9334 | 0.9023 | 79.0145 |

من خلال النتائج الموضحة في الجدول 1 تبين ما يلي:

من حيث مقياس Precision: في مجموعة بيانات "التدريب"، يحقق نموذج YoloV4 دقة قدرها 0.9133، مما يشير إلى أن حوالي 91.33% من الإيجابيات المتنبأ بها هي إيجابيات حقيقية. من الناحية العملية، يعني ذلك أنه عندما يتعرف النموذج على سطح في مجموعة البيانات التدريبية، فإنه صحيح بنسبة حوالي 91.33% من الأوقات. بالمثل، في مجموعة بيانات "الاختبار"، تبقى الدقة عالية بنسبة 0.8733 (87.33%)، مما يظهر قدرة النموذج على الحفاظ على دقة التعرف على الأسطح في البيانات غير المرئية (لم تكن معروفة مسبقاً للنموذج).

من حيث الاسترجاع Recall: في مجموعة بيانات "التدريب"، يظهر نموذج YoloV4 استدعاءً بنسبة 0.9833، مما يشير إلى أنه يتعرف بشكل صحيح على حوالي 98.33% من الحالات الفعلية للأسطح أثناء التدريب. في مجموعة بيانات "الاختبار"، يكون الاسترجاع 0.9334 (93.34%)، مما يشير إلى استمرار أداء النموذج بشكل جيد في التعرف على الأسطح في بيانات جديدة. الاسترجاع العالي يشير إلى أن النموذج يقلل

من السلبيات الزائفة، وهو أمر حاسم في التطبيقات حيث يمكن أن يكون غياب الحالات الإيجابية له تأثير كبير.

من حيث دقة القياس F1: في مجموعة بيانات "التدريب"، يحقق نموذج YoloV4 درجة F1 قدرها 0.9460، مما يشير إلى توازن متناغم بين الدقة والاسترجاع أثناء التدريب. في مجموعة بيانات "الاختبار"، تبقى درجة F1 عالية بنسبة 0.9023، مما يظهر قدرة النموذج على الحفاظ على توازن بين هذه المقاييس الحيوية عند التعامل مع بيانات غير مرئية مسبقاً. وهذا مهم بشكل خاص حيث يشير إلى قوة النموذج في مجموعة متنوعة من السيناريوهات.

أما من حيث اتحاد التقاطع عبر الاتحاد (IoU): في مجموعة البيانات "التدريب"، يُسجل نموذج YoloV4 درجة IoU تبلغ 84.25، مما يشير إلى تطابق كبير بين توقعاته ومواقع الأسطح الفعلية أثناء التدريب. بالمثل، تكون درجة IoU في مجموعة بيانات "الاختبار" هي 79.01، مما يشير إلى قدرة النموذج على تعميم فهمه للعلاقات المكانية إلى حالات جديدة.

تُظهر نتائج اكتشاف السطح YOLOv4 أن النموذج قادر على اكتشاف الأسطح بدقة وموثوقية. كما أن درجات IoU مرتفعة أيضاً، مما يشير إلى أن النموذج قادر على تحديد موضع الأسطح في الصور بدقة.

يعمل النموذج بشكل أفضل قليلاً في مجموعة بيانات التدريب مقارنةً بمجموعة بيانات الاختبار. ويرجع ذلك على الأرجح إلى حقيقة أن مجموعة بيانات التدريب أكبر وأكثر تنوعاً من مجموعة بيانات الاختبار. ومع ذلك، لا يزال أداء النموذج جيداً في مجموعة بيانات الاختبار، مما يشير إلى أنه قادر على التعميم على البيانات الجديدة.

بشكل عام، تعد نتائج اكتشاف السطح YOLOv4 واعدة جداً وتشير إلى أنه يمكن استخدام YOLOv4 لتطوير نظام قوي وموثوق للكشف عن السطح لمجموعة متنوعة من التطبيقات. حيث أظهر نموذج YOLOv4 أداءً استثنائياً في مهام كشف الأسطح. إنه يتميز بدقة واسترجاع ودرجة F1 عالية، بالإضافة إلى تداخل كبير مع المناطق الحقيقية الأساسية، سواء في مجموعة البيانات التدريبية أو الاختبارية. تُظهر هذه النتائج

قوته في التعرف على الأسطح بدقة وقدرته على تعميم هذه القدرة إلى بيانات جديدة. يوضح الشكل 6 بعض صور نتائج الاختبار للكشف عن السطح مع دقة الكشف عن السطح.



الشكل 6. بعض صور نتائج الاختبار للكشف عن السطح مع دقة الكشف عن السطح

2.7 نتائج التصوير بطائرة الدرون


يوضح الشكل 7 بعض الصور الناتجة عن الأعمال الحقلية بالتصوير بطائرة الدرون، والتي توضح نماذج مختلفة من أشكال الملاحق والسطوح. حيث تم رصد 256 عينة في حي الاجاويد، منها 67 مبنى مخالف حيث تتجاوز فيع مساحة بناء الملحق عن 50 بالمية مقابل 189 مبنى لم يكن فيه مخالفة.



الشكل 7. بعض الصور الناتجة عن الأعمال الحقلية بالتصوير بطائرة الدرون

3.7 تقييم الدقة الهندسية للنتائج

بعد إجراء التحليل البصري لصور الدرون ومقارنة النتائج مع حساب النسب المخالفة، تم اكتشاف حالتين غير عاديتين حيث لم يتم رصد أي مخالفات بالرغم من تسجيل النظام نسبا مخالفة بلغت 65.48 و 93.5. يمكن رؤية هاتين الحالتين في الشكل 8 حيث تظهر صور الدرون ونجد أنه لا توجد مخالفات ظاهرة.



الشكل 8. صورتين درون تم تسجيل فيهما نسب مخالفة بناء بالخطأ: صورة (a) نسبة 93.53 وصورة (b) نسبة 65.48

يمكن تفسير هذا الوضع بوجود أشكال معقدة قد تكون غير واضحة بشكل كافٍ للنظام الذي يقوم بالتحليل، وقد يصعب التعرف على هذه الأشكال بشكل دقيق. بالإضافة إلى ذلك، قد يكون هناك تحديات في تحديد الأطر الرئيسية والفرعية لهذه الأشكال بشكل صحيح بسبب تعقيدها، مما يجعل النظام يعطي نسب مخالفة على الرغم من عدم وجود مخالفات حقيقية.

هذه النتائج تشير إلى ضرورة تحسين أداء النظام في التعامل مع الأشكال المعقدة والمعالجة المتقدمة لتحليل صور الدرون بهدف تقليل الاشتباهات وزيادة دقة الكشف عن المخالفات الفعلية في المستقبل.

من أجل تقييم الدقة الهندسية للمنهجية، يجب علينا أن نقارن بين نسبة المخالفة المحسوبة باستخدام النموذج ونسبة المخالفة الفعلية والمقاسة في الواقع. تم اختيار ثلاثة مباني (تمكنا من الذهاب إليها حقلياً) بغرض دراستها على أرض الواقع. تم القياس الحقلي وحساب نسبة مساحة الملاحق العلوية من مساحة الأسطح لثلاثة أبنية مختلفة (ثلاثة نماذج) في حي الأجاويد. يوضح الجدول 2 نتائج حساب نسب المخالفات بالطريقة الحقلية، بالإضافة للنسب الناتجة عن استخدام نموذج YoloV4، كما يبين الأخطاء المطلقة.

الجدول 2: نسب المخالفات المحسوبة بالطريقة الحقلية وباستخدام نموذج YoloV4

| رقم الصورة | الرقم التعريفي للمخالفة | نسبة محسوبة بالقياس الحقلي | نسبة محسوبة باستخدام نموذج YoloV4 | الخطأ المطلق Absolute Error (AE) |
|------------|-------------------------|----------------------------|-----------------------------------|----------------------------------|
| DJI_0215 | 2467 | 0.78 | 0.874 | 0.094 |
| DJI_0204 | 2454 | 0.8 | 0.844 | 0.044 |
| DJI_0235 | 2502 | 0.537 | 0.613 | 0.076 |
| | | | | MAE= 0.071 |

بناءً على الجدول 2، يمكننا ملاحظة أن نسبة المخالفة المحسوبة باستخدام نموذج YoloV4 تختلف عن نسبة المخالفة المحسوبة بالقياس الحقلي بخطأ مطلق متوسط يبلغ 0.071 (7.1 بالمئة). مما يعني أن توقعاته كانت على متوسط يبعد بمقدار 0.071

عن قياسات الحقل. هناك عدة أسباب محتملة لهذا الخطأ، مثل جودة الصور وتعقيد المشاهد وتنوع الأشياء وقيود نموذج Yolo نفسه. لذا، يُوصى بتحسين نموذج YoloV4 لتحقيق دقة أفضل في هذه المهمة.

الخلاصة

أظهرت النتائج فعالية التقنيات الحديثة، مثل الذكاء الاصطناعي والطائرات بدون طيار، في دعم جهود مراقبة مخالفات البناء. وهذا يمكن أن يساهم في تحسين عملية اتخاذ قرارات أفضل بشأن إدارة المخالفات. بالإضافة إلى ذلك، يعتبر نموذج YOLOv4 الذي تم تطويره لمنطقة الدراسة جزءاً أساسياً من تحول مدينة جدة نحو أن تصبح مدينة ذكية مستدامة، ويساهم بشكل كبير في تعزيز أداء أمانة جدة وزيادة فعاليتها في مجال مراقبة المخالفات. يمكن استخدام هذا النموذج لاكتشاف المخالفات وانتهاكات اشتراطات البناء، ومع ذلك، يشير وجود الأخطاء إلى أن هناك مجالاً للتحسين. لذلك، ينبغي أن تكون هناك أولوية للتحقق من مخالفات البناء، ويمكن تحقيق ذلك من خلال دراسة صور الدرون والقياس عليها للتحقق وتوثيق المخالفات بشكل دقيق. يجب أن يتم هذا التحقق قبل اتخاذ أي إجراءات أخرى.

ينبغي أن يتم النظر في تحسين وتطوير الخوارزميات المستخدمة للكشف عن مخالفات البناء بالاستفادة من معلومات الارتفاع ومساحة السطح. هذا يشمل القدرة على اكتشاف زيادة في عدد الأدوار المخالفة وزيادة مساحة البناء عن الحد المسموح به. كما يجب تطوير وتحسين أداء النظام المقترح في التعامل مع الأشكال المعقدة والمعالجة المتقدمة لتحليل صور الدرون بهدف تقليل الاشتباهاة وزيادة دقة الكشف عن المخالفات الفعلية في المستقبل.

المراجع

المراجع العربية:

جمال، محمد. (2013). دراسة حول مخالفات البناء في المملكة العربية السعودية.

(متاح على

الموقع: <https://www.alarabiya.net/aswaq/realestate/2013/03/07>).

- درويش، حنان. (2022). تصميم وتطوير تطبيق نظام معلومات جغرافية مستقل BVM_GIS لكشف وإدارة مخالقات البناء. مجلة جامعة البعث، سلسلة العلوم للهندسة المدنية والمعمارية، 44 (9).
- درويش، حنان؛ محمد، عدنان؛ شعبان، فادي. (2021). تطوير نموذج للتعلم العميق بالشبكات العصبونية الاصطناعية لاستخراج المناطق العمرانية من صور الاستشعار عن بعد-منطقة الدراسة: حمص- طرطوس. مجلة جامعة البعث، سلسلة العلوم للهندسة المدنية والمعمارية، 43 (7).
- الغبيري، حسن. (2019). البيانات الضخمة وأثرها في تحقيق رؤية المملكة العربية السعودية 2030 دراسة تطبيقية. مجلة الاستراتيجية والتنمية، 9 (1)، 32 - 51.

المراجع الإنجليزية:

- Alahmadi, T. J., Rahman, A. U., Alkahtani, H. K., & Kholidy, H. (2023). Enhancing Object Detection for VIPs Using YOLOv4_Resnet101 and Text-to-Speech Conversion Model. *Multimodal Technologies and Interaction*, 7(8), 77.
- Balzano, W., Barolli, L., & Zangrillo, F. (2022). Object tracking by google cloud API and data alignment for front/rear car DVR footages. In *Advances on P2P, Parallel, Grid, Cloud and Internet Computing: Proceedings of the 16th International Conference on P2P, Parallel, Grid, Cloud and Internet Computing (3PGCIC-2021)* (pp. 80-87). Springer International Publishing.
- Bibri, S.E., (2019) On the sustainability of smart and smarter cities in the era of big data: aninterdisciplinary and transdisciplinary literature review. *Journal of Big Data* 6 (25). <https://doi.org/10.1186/s40537-019-0182-7>.
- Carrinho, P., & Falcao, G. (2023). Highly accurate and fast YOLOv4-based polyp detection. *Expert Systems with Applications*, 232, 120834.

- Ekanayake, B., Ahmadian Fard Fini, A., Wong, J. K. W., & Smith, P. (2022). A deep learning-based approach to facilitate the as-built state recognition of indoor construction works. *Construction Innovation*.
- Fahmideh Modami, M., Ayaz, M., Alajeh Gardi, A., & Javanshiri, M. (2022). Analysis of intelligent model of monitoring construction violations in urban management (Case study: Mashhad metropolitan area). *Iranian Journal of Remote Sensing & GIS* .
<https://doi.org/10.52547/gisj.2022.226439.1085>
- Kaur, J., & Singh, W. (2022). Tools, techniques, datasets and application areas for object detection in an image: a review. *Multimedia Tools and Applications*, 81(27), 38297-38351.
- Li, B. S., & Liu, C. N. (2020). Research on Intelligent Recognition of Violation Based on Big Data of Urban Construction. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42, 721-724.
- Nair, K. N., Dhulipalla, R. K., Satapathy, S. C., Kanungo, A., Kannan, E., & Ch, T. B. (2021). Modified YOLOv4 for real-time Coconut Trees Detection from an Unmanned Aerial Vehicle.
- Pham, M. T., Courtrai, L., Friguet, C., Lefèvre, S., & Baussard, A. (2020). YOLO-Fine: One-stage detector of small objects under various backgrounds in remote sensing images. *Remote Sensing*, 12(15), 2501 .
- Powers, David MW.(2020)."Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation." arXiv preprint arXiv:2010.16061

Pronin, S. V. (2021). Overview of Python libraries for analysis geographical data.

Published. <https://arxiv.org/abs/2004.10934>

Redmon, J., & Angelova, A. (2015, May). Real-time grasp detection using convolutional neural networks. In 2015 IEEE international conference on robotics and automation (ICRA) (pp. 1316-1322).

Rezatofghi, H., Tsoi, N., Gwak, J., Sadeghian, A., Reid, I., & Savarese, S. (2019). Generalized intersection over union: A metric and a loss for bounding box regression. In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition (pp. 658-666).

Sangaiah Xi, W., Zuo, X., & A. K. (2022). Enhancement of unmanned aerial vehicle image with shadow removal based on optimized RETINEX algorithm. *Wireless Communications and Mobile Computing*, 2022, 1-9. doi:10.1155/2022/3204407

Singh, K., & Nair, J. S. (2018). Satellite image enhancement using DWT and gaussian filter. *International Journal of Computer Sciences and Engineering*, 6(1), 289-297. doi:10.26438/ijcse/v6i1.289297

Solawetz, J., Nelson, J., & Sahoo, S. (2020, May 21). How to Train YOLOv4 on a Custom Dataset. *Roboflow Blog*. <https://blog.roboflow.com/training-yolov4-on-a-custom-dataset/>

Пронін, С. В. (2021). OVERVIEW OF PYTHON LIBRARIES FOR ANALYSIS GEOGRAPHICAL DATA. *Вісник Харківського національного автомобільно-дорожнього університету*, 1(92), 39-39.