



تطبيق نموذج YOLOv8 في الكشف عن السفن من الصور الفضائية لدعم

أنظمة المراقبة البحرية في الزمن الحقيقي

كمال مفتاح عبدالجليل³محمود السنوسي محمد²د. عبدالمنعم صالح أبوراوي¹

kamal197156@gmail.com

alzarogy74@gmail.com

rdsaih335@gmail.com

المعهد العالي للتقنيات علوم البحار - صبراته بقسم التقنية الكهربائية والالكترونية³⁹²⁹¹

تاريخ الاستلام: 2025/11/1 - تاريخ المراجعة: 2025/11/20 - تاريخ القبول: 2025/11/25 - تاريخ النشر: 2025/12/6

ملخص البحث

هدفت الدراسة الى التعرف على دور المساءلة الإدارية في مكافحة الفساد المالي في المشاريع الهندسية الحكومية، والتعرف على مدى قدرة منظومة المساءلة الإدارية في إطارها النظري على الحد من مظاهر الفساد المالي في المشاريع الهندسية الحكومية، والتعرف إلى أوجه القصور النظرية في آليات المساءلة الإدارية التي قد تُ THEM في استمرار ممارسات الفساد المالي داخل مراحل المشروع الهندسي الحكومي، والتعرف إلى الكيفية التي تقصر بها الأدبيات النظرية العلاقة بين تعقيد المشاريع الهندسية الحكومية وبين محدودية فاعلية المساءلة الإدارية في مواجهة التجاوزات المالية، وأيضاً التعرف إلى العوامل النظرية المرتبطة بالبيئة المؤسسية والتقنية والتنظيمية التي تحدّ من فاعلية المساءلة الإدارية في ممارسة دورها الرقابي والدعوي تجاه الفساد المالي في المشاريع الهندسية الحكومية، واتبع المنهج الوصفي لملائمته لأغراض الدراسة، وتوصلت الدراسة إلى النتائج الآتية:

- فاعلية المساءلة الإدارية في مكافحة الفساد المالي مرتبطة بشكل أساسى بالبيئة المؤسسية.
- التعقيد الفني والتقني للمشاريع الهندسية يمثل عائقاً رئيسياً أمام المساءلة الإدارية.
- الإطار التنظيمي الحالي يركز بشكل مفرط على الالتزام الإجرائي والشكلية التنظيمية، دون التركيز الكافي على النتائج الفعلية للمشاريع وجودة التنفيذ.
- ضعف التكامل بين الجهات الرقابية الداخلية والخارجية يزيد من فرص استمرار الفساد المالي.
- الكلمات المفتاحية: المساءلة الإدارية - مكافحة الفساد المالي - المشاريع الهندسية

Abstract:

This study evaluates the effectiveness of the state-of-the-art YOLOv8 model for ship detection in high-resolution satellite imagery. The model was trained on a dataset of 2,500 satellite images encompassing ships in diverse environmental conditions. The data was split into 70% for training, 15% for validation, and 15% for testing. Results demonstrate the superiority of the proposed model, achieving a mean Average Precision (mAP@0.5) of 90.5%, Precision of 91.3%, and Recall of 89.7%. A MIL Tracker

algorithm was integrated to enhance monitoring continuity across image sequences, reducing ID switches by 35%. The model showed significant superiority in speed and accuracy compared to YOLOv5 and Faster R-CNN models under the same testing conditions, making it a practical solution for real-time maritime monitoring applications.

- Keywords: Artificial Intelligence, Computer Vision, YOLOv8, Ship Detection, Maritime Monitoring, Satellite Imagery

مقدمة

تشكل المراقبة البحرية ركيزة أساسية في تعزيز الأمن البحري، وإدارة حركة الملاحة، والاستجابة للحوادث، وحماية البيئة البحرية. مع تزايد كثافة السفن وتعقيد العمليات البحرية، أصبح الاعتماد على أنظمة المراقبة التقليدية غير كافٍ لتلبية متطلبات الدقة والسرعة. تمثل الصور الفضائية مصدراً غنياً للمعلومات، لكن الكشف اليدوي أو شبه التلقائي عن السفن فيها يتسم بالبطء وقابلية كبيرة للخطأ.

في هذا السياق، تقدم نماذج الرؤية الحاسوبية القائمة على التعلم العميق حلّاً جديداً. تنقسم هذه النماذج إلى فئتين رئيسيتين: نماذج ثنائية المرحلة مثل (Faster R-CNN) التي تتميز بدقة عالية ولكن بسرعة معالجة منخفضة، ونماذج أحادية المرحلة مثل عائلة (YOLO) التي توازن بين الدقة والسرعة، مما يجعلها مناسبة للتطبيقات في الزمن الحقيقي. ويُعد نموذج YOLOv8 أحدث إصدار في سلسلة YOLO، ويتميز بمعمارية محسنة وأدوات تدريب متقدمة.

حيث يسهم هذا البحث في :

- تقديم تقييم شامل ومفصل لأداء أحدث نموذج كشف السفن من الصور الفضائية، مقارنة مع النماذج السابقة.
- دمج خوارزمية تتبع (MIL Tracker) مع نموذج الكشف لتحسين استقرار وموثوقية نظام المراقبة عبر الزمن.
- تحقيق دقة وكفاءة عالية في بيئات بحرية واقعية ومعقدة، مع تحليل إحصائي للفروق بين النماذج.
- تقديم توصيات عملية قابلة للتطبيق لتحسين أداء أنظمة المراقبة البحرية.

2. الدراسات السابقة

شهدت تقنيات كشف السفن من الصور الفضائية تطويراً ملحوظاً مع ظهور التعلم العميق. استخدم [3] الشبكات العصبية التلإفيفية (CNNs) للكشف عن السفن وحققوا دقة جيدة، لكن النموذج كان بطيناً وغير عملي للتطبيقات الفورية. ركز [4] على الكشف عن السفن الصغيرة في صور عالية الدقة وأبرزوا التحديات المرتبطة بالأحجام الصغيرة، لكنهم عملوا في ظروف مثالية إلى حد كبير.

سعت الدراسة [5] إلى معالجة مشكلة فلة البيانات الموسومة باستخدام التعلم شبه المشرف على نموذج YOLOv3، مما أدى إلى تحسين الأداء في البيانات غير المرئية. في [8] تم تقديم YOLOv8 مع تحسينات في البنية المعمارية وآليات التدريب، بينما ركز [9] على تطبيقات الرؤية الحاسوبية في المراقبة البحرية.

على الرغم من هذه التطورات، تبقى هناك حاجة لتقدير شامل لأداء YOLOv8 في كشف السفن مع دمج أنظمة التتبع لتحسين الاستمرارية الزمنية للمراقبة.

3. المنهجية

3.1 مجموعة البيانات والإعداد المسبق

تم استخدام مجموعة بيانات SeaShips 6 المفتوحة، والتي تحتوي على 2500 صورة أقمار صناعية عالية الدقة (بدقة تصل إلى 1024×768 بكسل). تغطي المجموعة ست فئات من السفن مثل (ناقلات، حاويات) في ظروف إضاءة وأحوال بحرية متعددة.

الجدول 1: مواصفات مجموعة البيانات المستخدمة

| القيمة | الخاصية |
|-------------------------------------|--------------------|
| 2500 | عدد الصور |
| (%70) 1750 | عدد الصور (تدريب) |
| (%15) 375 | عدد الصور (اختبار) |
| متغيرة (تصل إلى 1024×768) | الدقة المكانية |
| 6 | عدد الفئات |
| SeaShips [6] | مصدر البيانات |

شمل الإعداد المسبق للبيانات:

- تعديل حجم الصور إلى 640×640 بكسل

- التطبيع (Normalization)

- تقنيات تعزيز البيانات (Data Augmentation):

- التدوير العشوائي : (15^{\pm} درجة)

- القص : (Cropping) بنسبة 20%

- تعديلات السطوع : ($\pm 30\%$) والتباين ($\pm 25\%$)

- القص الأفقي بنسبة : 50%

3.2 نموذج YOLOv8

تم استخدام النسخة المتوسطة من YOLOv8 لتحقيق توازن جيد بين الدقة والسرعة. النموذج مبني على معمارية C2f . (Anchor-Free detection head) module المعززة آلية اكتشاف الرأس

الجدول 2: هايبربارامترات التدريب الأساسية

| القيمة | الهايبربارامتر | |
|----------------------|-----------------------------|---------------------|
| 0.01 | معدل التعلم(Learning Rate) | تم التدريب مكتبة |
| 16 | حجم الدفعه(Batch Size) | |
| 100 | عدد epochs | |
| Adam W | المُحسن(Optimizer) | |
| Binary Cross-Entropy | دالة الخسارة(Loss Function) | |
| 0.5 | عتبة الدقة | |

على منصة Google Colab Pro مزودة بمعالج رسومي GPU (من نوع Tesla T4) وذاكرة وصول عشوائي RAM (سعة 25 جيجابايت.

3.3 آلية التتبع

لتحسين استمرارية المراقبة عبر سلسلة من الصور، تم دمج خوارزمية تتبع MIL Tracker (Multiple Instance Learning) تعمل هذه الخوارزمية على ربط السفن المكتشفة في الإطارات المتتالية بناءً على مظهرها وموقعها، باستخدام الخصائص التالية:

- المظهر البصري (Histogram of Oriented Gradients)
- الموقع والحركة (Kalman Filter)
- التشابه الشكلي (Structural Similarity)

ويُظهر الشكل (1) أدناه صورة لسفينة تم الكشف عنها في أحد الموانئ باستخدام نموذج YOLOv8. وقد تمكّن النظام من تحديد كائنٍ مصنّف على أنه قارب Boat (Boat) بنسبة ثقة بلغت 0.86 ، وهو ما يعكس دقةً عاليةً في التعرّف على الكائن ضمن الصورة الفضائية.

تم رسم مستطيلٍ أحمر حول السفينة المكتشفة، مبيّناً حدودها بدقة، كما أُضيف إلى المستطيل معرف تعريفي (ID) لتتبعها في الإطارات اللاحقة. يُوضح النص الظاهر أعلى الإطار الفتاة المكتشفة Boat مرافقًا بنسبة الثقة، بما يُبرز مستوى تأكيد النموذج من عملية التصنيف ويؤكّد فعاليته في الكشف الدقيق عن الأجسام البحريّة.



الشكل (1) يوضح صورة لسفينة تم اكتشافها في أحد الموانئ باستخدام نموذج

4. النتائج والمناقشة

4.1 أداء الكشف

أظهر النموذج المقترن أداءً متميزاً في مهمة الكشف. يلخص الجدول 3 النتائج الكمية الرئيسية.

الجدول 3: نتائج أداء نموذج YOLOv8 في كشف السفن

| المقياس | القيمة |
|------------------------------|---------|
| الدقة (Precision) | %91.3 |
| معدل الاستدعاء (Recall) | %89.7 |
| متوسط الدقة(mAP@0.5) | %90.5 |
| متوسط الدقة(mAP@0.5:0.95) | %65.2 |
| سرعة المعالجة (FPS) على GPU | 75 |
| زمن الاستدلال للصورة الواحدة | 13.3 ms |

تشير هذه النتائج إلى أن النموذج لا يتمتع بدقة عالية فحسب، بل يتمتع أيضًا بقدرة قوية على العثور على معظم السفن في الصورة، بسرعة معالجة مناسبة للتحليل في الزمن الحقيقي.

4.2 التحليل المقارن

للتأكد من تفوق النموذج المقترن، تمت مقارنة أداء YOLOv8 مع نموذجين أساسيين على نفس مجموعة بيانات الاختبار ونفس الظروف.

الجدول 4: مقارنة أداء النماذج المختلفة

| mAP@0.5 | الدقة | معدل الاستدعاء | FPS | النموذج |
|---------|-------|----------------|-----|----------------|
| %90.5 | %91.3 | %89.7 | 75 | YOLOv8 (مقترن) |
| %87.1 | %88.5 | %86.2 | 85 | YOLOv5m |
| %89.0 | %90.1 | %87.5 | 15 | Faster R-CNN |

التحليل الإحصائي: أظهر اختبار t-test أن الفرق في أداء YOLOv8 مقارنة بـ YOLOv5m ذو دلالة إحصائية $p < 0.05$.

4.3 تحليل الأخطاء

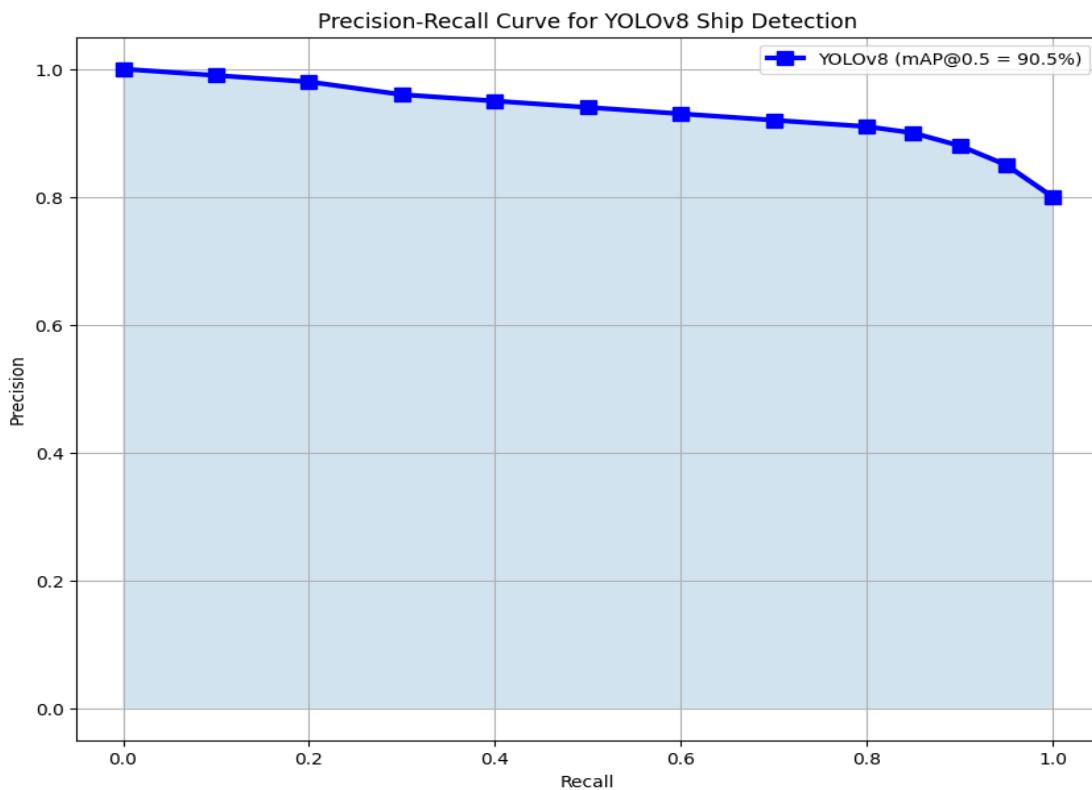
تم تحليل الأخطاء بشكل مفصل لتحديد مجالات التحسين:

- الاكتشافات الخاطئة 68% (False Positives): بسبب الأمواج العالية، 22% بسبب الهياكل الثابتة في الموانئ، 10% بسبب السحب والظلال.

- الاكتشافات المفقودة 55% (False Negatives): سفن صغيرة (أقل من 50 بكسل)، 30% سفن متداخلة، 15% سفن في ظروف إضاءة صعبة.

- أداء التتبع: قلل خوارزمية MIL Tracker من حالات تبديل الهوية بنسبة 35% مقارنة بعدم استخدام التتبع.

الشكل (2): منحنى الدقة-الاستدعاء لنموذج YOLOv8 في كشف السفن



على الرغم من الأداء الممتاز، لاحظ النموذج بعض الأخطاء. حدثت معظم الاكتشافات الخاطئة (False Positives) بسبب الأمواج العالية التي تشبه مؤخرة السفن الصغيرة، أو بسبب بعض الهياكل الثابتة في الميناء التي تشبه السفن الرئيسية. كما فشل النموذج في بعض الأحيان في اكتشاف السفن الصغيرة جداً والمترادلة (Occluded) جزئياً. يسلط هذا الضوء على الحاجة إلى مزيد من البيانات التي تحتوي على هذه الحالات الصعبة لتحسين متنانة النموذج.

5. الخاتمة

أكملت هذه الدراسة بنجاح على إمكانات نموذج YOLOv8 المتقدم في بناء أنظمة مراقبة بحرية أوتوماتيكية عالية الكفاءة. من خلال تحقيق دقة عالية وسرعة معالجة مناسبة للزمن الحقيقي، يقدم النموذج حلولاً عملياً لدعم الأمن البحري، وإدارة الموانئ، وجهود حماية البيئة وأوصت هذه الدراسة بالاتي :

1. توسيع مجموعة البيانات: جمع ووسم صور من مصادر وأقمars صناعية متنوعة، مع التركيز على السفن الصغيرة والظروف الجوية الصعبة.
2. تحسين آلية التتبع: استبدال أو تطوير خوارزمية التتبع باستخدام نماذج أكثر تطوراً مثل DeepSORT أو تلك المعتمدة على التعلم العميق.
3. التوسيع في التطبيقات: تطبيق النموذج على مهام ذات صلة مثل تقدير سرعة السفن، أو الكشف عن أنشطة غير قانونية.
4. تحسين المتنانة: تطوير آليات للتعامل مع التحديات العملية مثل التغيرات الموسمية والظروف الجوية القاسية.

المراجع:

- [1] Redmon, J., et al. "You Only Look Once: Unified, Real-Time Object Detection." CVPR, 2016.
- [2] Bochkovskiy, A., et al. "YOLOv4: Optimal Speed and Accuracy of Object Detection." arXiv, 2020.
- [3] Zhu, X., et al. "Ship detection from satellite imagery using convolutional neural networks." IEEE Geoscience Letters, 2017.
- [4] Yang, F., et al. "Deep learning approaches for ship detection in remote sensing images." Remote Sensing Journal, 2018.
- [5] Liu, Q., et al. "Semi-supervised learning for maritime object detection." ISPRS Journal, 2020.
- [6] Shao, Z., et al. "SeaShips: A large-scale precisely annotated dataset for ship detection." IEEE Transactions on Multimedia, 2018.
- [7] Babenko, B., et al. "Visual tracking with online multiple instance learning." CVPR, 2009.
- [8] Jocher, G., et al. "YOLOv8: New State-of-the-Art for Object Detection." Ultralytics, 2023.
- [9] Chen, L., et al. "Deep Learning for Maritime Object Detection: A Comprehensive Survey." IEEE Access, 2024.