



تطبيق نموذج YOLOv8 في الكشف عن السفن من الصور الفضائية لدعم

أنظمة المراقبة البحرية في الزمن الحقيقي

كمال مفتاح عبدالجليل³

محمود السنوسي محمد²

د. عبدالمنعم صالح أبوراوي¹

kamal197156@gmail.com

alzarogy74@gmail.com

rdsaih335@gmail.com

المعهد العالي لتقنيات علوم البحار – صبراتة بقسم التقنية الكهربائية والإلكترونية^{3و2و1}

تاريخ الاستلام: 2025/11/1 - تاريخ المراجعة: 2025/20/15 - تاريخ القبول: 2025/11/25 - تاريخ النشر: 2025/12/6

ملخص البحث

يهدف هذا البحث إلى تقييم فعالية نموذج YOLOv8 الحديث للكشف عن السفن في الصور الفضائية عالية الدقة. تم تدريب النموذج على مجموعة بيانات مكونة من 2500 صورة أقمار صناعية تشمل سفناً في ظروف بيئية متنوعة. قسمت البيانات بنسبة 70% للتدريب، 15% للتحقق، و15% للاختبار.

أظهرت النتائج تفوق النموذج المقترح حيث حقق متوسط دقة (mAP@0.5) بلغ 90.5%، ودقة كشف (Precision) 91.3%، ومعدل استدعاء 89.7% (Recall). كما تم دمج خوارزمية تتبع (MIL Tracker) لتحسين استمرارية المراقبة عبر تسلسل الصور، حيث قللت من حالات تبديل الهوية (ID switches) بنسبة 35%. أظهر النموذج تفوقاً ملحوظاً في السرعة والدقة مقارنة بنماذج YOLOv5 وFaster R-CNN تحت نفس ظروف الاختبار، مما يجعله حلاً عملياً لتطبيقات المراقبة البحرية في الزمن الحقيقي.

الكلمات المفتاحية: الذكاء الاصطناعي، الرؤية الحاسوبية، YOLOv8، كشف السفن، المراقبة البحرية، الصور الفضائية-

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

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 حلاً 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 وآليات تدريب متطورة.

حيث يسهم هذا البحث في :

1. تقديم تقييم شامل ومفصل لأداء أحدث نموذج كشف YOLOv8 في مهمة كشف السفن من الصور الفضائية، متضمناً مقارنة مع النماذج السابقة.
2. دمج خوارزمية تتبع (MIL Tracker) مع نموذج الكشف لتحسين استقرار وموثوقية نظام المراقبة عبر الزمن.
3. تحقيق دقة وكفاءة عالية في بيانات بحرية واقعية ومعقدة، مع تحليل إحصائي للفروق بين النماذج.
4. تقديم توصيات عملية قابلة للتطبيق لتحسين أداء أنظمة المراقبة البحرية.

2. الدراسات السابقة

شهدت تقنيات كشف السفن من الصور الفضائية تطوراً ملحوظاً مع ظهور التعلم العميق. استخدم [3] الشبكات العصبية التلافيفية (CNNs) للكشف عن السفن وحققوا دقة جيدة، لكن النموذج كان بطيئاً 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 قلة البيانات الموسومة باستخدام التعلم شبه المُشرف 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 لتقييم 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 متنوعة.

الجدول 1: مواصفات مجموعة البيانات المستخدمة

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

شمل الإعداد المسبق للبيانات:

- تعديل حجم الصور إلى 640×640 بكسل

- التطبيع (Normalization)

- تقنيات تعزيز البيانات: (Data Augmentation)

- التدوير العشوائي: (± 15 درجة)

- القص: (Cropping) بنسبة 20%

- تعديلات السطوح: ($\pm 30\%$) 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 module المعززة وآلية اكتشاف الرأس (Anchor-Free detection head).

الجدول 2: هايبربارامترات التدريب الأساسية

| الهايبربارامتر | القيمة |
|-----------------------------|--------|
| معدل التعلم (Learning Rate) | 0.01 |
| حجم الدفعة (Batch Size) | 16 |
| عدد epochs | 100 |

| | |
|------------------------------|----------------------|
| المُحسن (Optimizer) | Adam W |
| دالة الخسارة (Loss Function) | Binary Cross-Entropy |
| عتبة الدقة | 0.5 |

تم التدريب باستخدام مكتبة Ultralytics 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) ادناه صورة لسفينة تم الكشف عنها في أحد الموائى باستخدام نموذج YOLOv8. وقد تمكّن النظام من تحديد كائنٍ مصنّف على أنه قارب (Boat) بنسبة ثقة بلغت 0.86 ، وهو ما يعكس دقّة عالية في التعرّف على الكائن ضمن الصورة الفضائية.

تم رسم مستطيلٍ محيطٍ باللون الأحمر حول السفينة المكتشفة، مبيّنًا حدودها بدقة، كما أُضيف إلى المستطيل معرّف تعريف (ID) لتتبعها في الإطارات اللاحقة. يُوضّح النص الظاهر أعلى الإطار الفئة المكتشفة (Boat) مرفقةً بنسبة الثقة، بما يبرز مستوى تأكيد النموذج من عملية التصنيف ويؤكد فعاليته في الكشف الدقيق عن الأجسام البحرية.



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

4. النتائج والمناقشة

4.1 أداء الكشف

أظهر النموذج المقترح أداءً متميزاً في مهمة الكشف. يُلخص 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 أيضاً بقدرة قوية على العثور على معظم السفن في الصورة، بسرعة معالجة مناسبة للتحليل في الزمن الحقيقي.

4.2 التحليل المقارن

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

الجدول 4: مقارنة أداء النماذج المختلفة

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

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

4.3 تحليل الأخطاء

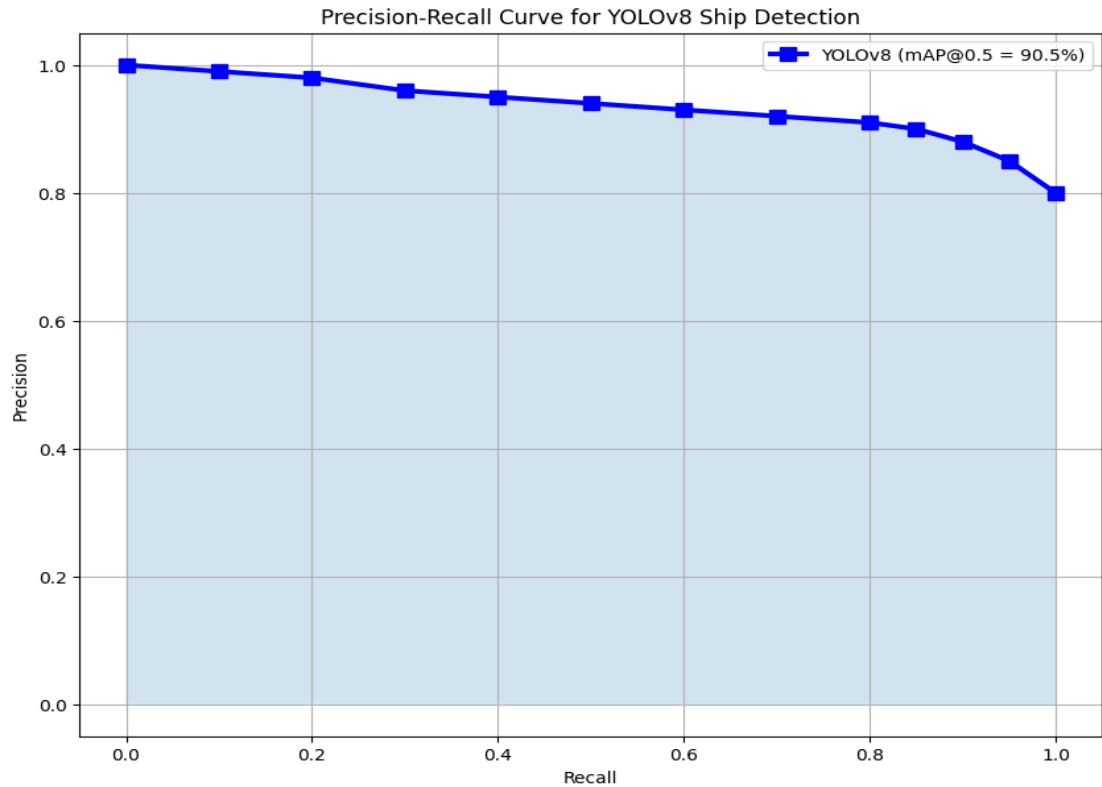
تم تحليل الأخطاء بشكل مفصل لتحديد مجالات التحسين:

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

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

- أداء التتبع: قللت 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 الراسية. كما فشل النموذج في بعض الأحيان في اكتشاف السفن الصغيرة جداً والمتداخلة (Occluded) جزئياً. يسلط هذا الضوء على الحاجة إلى مزيد من البيانات التي تحتوي على هذه الحالات الصعبة لتحسين متانة النموذج

5. الخاتمة

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

1. توسيع مجموعة البيانات: جمع ووسم صور من مصادر وأقمار 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. التوسع في التطبيقات: تطبيق النموذج على مهام ذات صلة مثل تقدير سرعة السفن، أو الكشف عن أنشطة غير قانونية.
4. تحسين المتانة: 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.