

YOLOv4 による船舶検出のための Color Space Transformations Color Space Transformations for Ship Detection using YOLOv4

岩本 修弥[†] 北風 裕教[†] 松村 遼[†]
Shuya Iwamoto Hironori Kitakaze Ryo Matsumura

1. はじめに

近年、船舶の大型化や高速化が進んでおり、船舶同士の衝突が発生した場合、被害が重大化する可能性が高い。船舶衝突事故原因の割合としては見張り不十分が最も高く[1]、事故防止のためにも航海士の見張りが重要となる。しかし、これは非常に負担のかかる業務でもあり、負担軽減に取り組むことも求められている。

船舶同士の衝突事故は 2010 年の 356 回をピークに 2021 年では 199 件まで減っており[2]、減少傾向にある。しかしながら未だ件数は多く、更なる減少が課題となっている。そこで、本研究では YOLOv4 を用いた船舶検出システムの開発により、航海士の見張りを支援し衝突事故の減少に寄与することを目標とする。

本研究において、船舶検出は船首や艦橋などに搭載するカメラから得られる画像を対象に行う。画像認識を用いた見張り支援に求められる要件として、1 海里(1852m)先の漁船等の小型船舶が検出可能なことが挙げられる[3]。我々はこの要件に対応するため、著者所属が所有する練習船大島丸を活用し、学習・実験用データの撮影を行っている。しかしながら、気象条件によっては霧により視程が短くなり、遠方の船舶が不鮮明に撮影されてしまい、このような学習用データの割合が増加すると、検出精度が低下するという問題が発生した。

そこで、本稿では不鮮明な画像の改善を目的としたトーンカーブによるコントラスト変換を用いた Color Space Transformations を提案する。本手法により構築したデータセットで YOLOv4 [4] を学習し、船舶検出精度が向上することを実験により示す。

2. Color Space Transformations

2.1 Color Space Transformations

YOLOv4 を始めとした畳み込みニューラルネットワーク(Convolutional Neural Network : CNN)では学習に大量のデータが必要であり、学習データ数の増加によって検出精度の向上や過学習を抑えることが可能となる。学習データ数を増加させる手法として Data Augmentation が挙げられる。本研究では、船舶検出に Data Augmentation の一種である Color Space Transformations(CST)を導入する。CST は、カラーヒストグラム調整など色空間を操作することで Data Augmentation を行う手法である。本稿においては船舶を撮影した画像に対して、トーンカーブによるコントラスト調整を行うことで霧の影響を低減させ不鮮明な画像を改善し、検出対象の視認性を向上させる CST を提案する。

提案手法で使用したトーンカーブを図 1 に示す。また、霧の有無による影響を比較した画像を図 2 に示す。(a) に比べ (b) では霧の影響により船舶の輪郭がぼやけ、視認性が低下している。このような画像で学習を行った場合、輪郭等の特徴が正しく学習されず精度が低下すると考えられる。





図 1 Tone Curve



(a) 霧なし (b) 霧あり

図 2 霧の影響による船舶の視認性の比較



図 3 提案手法による変換

図 2(b) に対して、提案手法による変換を行った結果を図 3 に示す。コントラストの変化により船舶の輪郭を強調することができ、霧による影響が低減していることがわかる。

2.2 データセット構築

CNN の学習には小型船舶、大型船舶が撮影された画像データを用いる。実際のシステム運用時に想定される状況で船舶の学習を行うため、船載カメラから撮影された小型船舶 4,763 隻、大型船舶 3,816 隻が写る 7,727 枚の画像を学習用データセットに使用する。このうち、霧の影響により視認性が低下している画像（以下、霧画像とする）が 1,155 枚存在する。これに対して提案手法を適用して増加させた計 8,882 枚を精度比較のための学習用データセットとして使用する。この時、前者のデータセットから霧画像を 346 枚に削減し、計 6,918 枚としたデータセットも用意する。

検出精度評価用のデータセットとして、学習用データセットと同じく船載カメラから撮影した小型船舶 1,560 隻、大型船舶 1,472 隻を含む 2,789 枚の画像を使用する。

3. 船舶検出実験

3.1 実験条件

YOLOv4 の学習及び船舶検出実験を行い、検出精度を評価する。精度評価には mean Average Precision(mAP)を用い

表 1 検出実験結果

モデル(a)			モデル(b)			モデル(c)		
	小型船舶	大型船舶		小型船舶	大型船舶		小型船舶	大型船舶
物体数	1560	1472	物体数	1560	1472	物体数	1560	1472
TP	1495	1422	TP	1502	1421	TP	1512	1429
FP	86	66	FP	97	67	FP	79	72



(a) モデル(b)での検出



(b) モデル(c)での検出

図 4 検出結果



(a) 入力画像



(b) 結果画像

図 5 遠方船舶の検出例

る。学習時のパラメータは入力解像度を 640×640 ピクセル、batch サイズを 8、epoch 数を 8,000 と設定した。

まず、霧画像の割合が少ない計 6,918 枚のデータセットで学習したモデル(a)、(a)でのデータセットよりも霧画像の割合が大きい計 7,727 枚のデータセットで学習したモデル(b)の精度比較により、霧の影響による精度低下について示す。そして、提案手法の有効性を検証するため、モデル(b)と(c)でのデータセットの霧画像に対し、提案手法を適用して画像数を増加させたデータセットで学習したモデル(c)を比較し評価する。

3.2 実験結果及び考察

表 1 に実験結果を示す。True Positive(TP)は検出対象を検出できており、クラスも正しく推論できている場合、False Positive(FP)は検出対象以外を検出している、対象を検出しているがクラスの推論が正しくない場合を表す。

この時、各モデルの mAP は(a)が 0.984、(b)が 0.982、(c)が 0.987 となった。1 章で述べたようにモデル(b)で使用したデータセットは、モデル(a)で使用したデータセットに比べ、データ数自体は増加しているが霧画像の割合が多くなっているため、mAP が減少し精度が低下する結果となっている。また、モデル(b)とモデル(c)を比較すると小型船舶、大型船舶ともに TP の増加が確認できた。このことから霧画像に対して提案手法を適用して視認性を改善し、霧画像の割合を減らした学習用データセットの構築によって船舶の検出精度が向上することを確認した。しかし(c)のモデルと(a)、(b)のモデルを比較した際、大型船舶の FP が減少すると予測していたが増加する結果となった。FP となった例には背景や海上に浮かぶブイなどが存在しており、この原因として提案手法により、大型船舶が検出対象でない背景領域やブイと似た色へと変化し、これをモデルが学習したからだと考えられる。

図 4 に実際の検出結果を示す。図 4 (a)はモデル(b)の検出結果を示しており、画像左側の大型船舶は検出できているが、右側の小型船舶が未検出となっている。図 4 (b)の画像はモデル(c)での検出結果を示しており、大型船舶に加え、小型船舶も正しく検出できている。小型船舶は大型船舶に比べ、その大きさから霧の影響を受けやすく、学習時にお

いて特徴を捉えづらい状態になっていると予想される。提案手法を用いた船舶の視認性向上により、学習時に小型船舶の特徴を捉えやすくなったことが、このように検出可能になった要因だと考えられる。

また、遠方の小型船舶の検出結果を図 5 に示す。1 章で述べたように、見張り支援には 1 海里先の小型船舶が検出可能なことが要件として挙げられている。新保らは、横解像度 2560 ピクセルのカメラで通常望遠倍率により海上を撮影した場合、1 海里先の全長 15m の漁船は 50 ピクセル程度の幅で画像に写りこむと述べている[3]。図 5(a)に示す実験で用いた画像の解像度は 1920×1080 であり、この時の小型船舶とカメラとの距離は練習船のレーダーの情報から約 1.5 海里と推定されている。また、画像中の小型船舶の幅は約 40 ピクセルである。図 5(b)の結果から YOLOv4 によって 1 海里以上先の幅 50~100 ピクセルで映り込む小型船舶の検出が可能であることがわかった。先述したように、提案手法によって学習時に小型船舶の特徴を捉えやすくなっている。遠方に存在し低解像度で写り込む小型船舶においても同様であり、このような船舶の特徴も学習することが可能だと考えられる。

4. まとめ

本稿では、トーンカーブによるコントラスト変換を用いた Color Space Transformations を提案した。船舶検出実験より、提案手法により構築したデータセットで学習したモデルの検出精度向上を確認した。今後は本手法を検出の前処理として利用することを考えている。そのため、霧の有無を判定する手法の開発に取り組む予定である。

参考文献

- [1] 海上保安庁, “海難の発生と救助の状況”, https://www6.kaiho.mlit.go.jp/info/keihatsu/20220606_state_measure01.pdf (2022-06-20 参照)
- [2] 国土交通省 運輸安全委員会, “船舶事故の統計”, <https://jtsb.mlit.go.jp/jtsb/ship/ship-accident-toukei.php> (2022-06-08 参照)
- [3] 新保雅俊, 周立輝, 山本茂広, “航海見張りを支援する画像処理手法の検討”, 日本航海学会論文集, No.119, pp.91-97, 2008.
- [4] Alexey Bochkovskiy, Chien-Yao Wang, and Hong-Yuan Mark Liao. "Yolov4: Optimal speed and accuracy of object detection." arXiv preprint arXiv:2004.10934, 2020.