

可視光・遠赤外線画像と深層学習による 浦賀水道航路の通航船舶の検出

小林 充*, 丹羽 康之*, 福戸 淳司**, 岩崎 一晴***

Ship Detection Experiments in Uraga Channel using Visible Light / Far-Infrared Images and Deep Learning

by

Kobayashi Mitsuru, Niwa Yasuyuki, Fukuto Junji and Iwasaki Kazuharu

Abstract

Radar and the Automatic Identification System (AIS) are the most common electronic methods for detecting the position of other ships. However, there are still many ships that are not equipped with AIS, such as small ships, and they are sometimes difficult to detect even with radar. To develop a complementary sensor system for understanding the movements of such ships, we captured landscape images with a high-definition camera and a far-infrared camera, detected ships, and recognized ship types using deep learning.

* 知識・データシステム系, ** 研究監, *** 日本エヌ・ユー・エス株式会社

原稿受付 令和3年1月22日

審査日 令和3年3月4日

目 次

1. まえがき	30
2. 設置機材と構成	31
3. 深層学習による検出器の作成	32
4. 景観画像からの船影の検出と船種認識	34
4.1 航路上の船舶の検出	34
4.2 小型船による検出実験	35
4.3 異なるアルゴリズムとの船影検出における比較	36
4.4 気象等の環境条件における限界	37
5. まとめと展望	39
5.1 まとめ	39
5.2 今後の展望	39
参考文献	40

1. まえがき

現在、輻輳航路において、わが国では海上保安庁海上交通センターが船舶の安全運航のための情報提供と航行管制を行っている。ここでは電子的な船舶検出手段としてレーダーと AIS (Automatic Identification System : 船舶自動識別装置) が用いられている。

これには次のような課題がある。

- AIS は旅客船を除く 500GT 未満の内航船, 300GT 未満の外航船には搭載義務はない。2019 年度内航登録船のうち隻数ベースで 4 分の 3 以上が 500GT 未満にあたる。安全航行のため自主的に AIS を搭載する船舶もあるが、小型船を中心に AIS を搭載していない船舶も依然として多い。
- AIS は船位、速度等を暗号化せず平文で送信しているため、特定の船舶を狙った妨害により AIS 上の存在情報を消したり、実際には存在しない船舶を AIS 上に出現させたりすることが近傍からの簡易な無線機材で実現できる¹⁾。
- レーダーでは小型船や鋼以外の材質の船は検出できないことがある。小型船安全規則第八十四条の三には「小型船舶 (昼間のみを航行するものを除く.) には、効果的な航海用レーダー反射器を備え付けなければならない。ただし (後略)」とあり、昼間における小型船舶の検出はレーダーのみでは不十分であることを示唆している。

このため、通航船舶の検出をより確実に行うためには補完的なセンサシステムを用いることが必要である。今回はレーダーと AIS を補完するセンサシステムとして、カメラによる景観画像から船影を検出するシステムを一例として挙げ、可視光ハイビジョンカメラ、および遠赤外線カメラにより観音崎レーダー施設から浦賀水道航路を俯瞰的に撮影し、深層学習により通航船舶の検出と船種認識を行った。この結果について報告する。

これまで、自動運航船などではカメラを用いた他船検出を行うシステムを船舶に搭載したものがあったが、それに採用されている技術は競争領域として詳細を公開しているものはなく、推測の域を出ることがなかった。本論文はこのようなシステムの構築に際し、基礎的な知見を与えるものとして報告する。

既存研究としては、既存の画像処理による検出手法として、HOG (Histograms of Oriented Gradients : 勾配方向ヒストグラム) を用いて SVM (Support Vector Machine) による分類を利用した船舶検出の先行事例²⁾や、Haar Cascade 検出器を利用した自動車検出の事例³⁾がある。これらは景観画像中を小窓が走査し特徴パターンを逐次マッチングを行う方式のため、特に小さい船影を検索する場合に処理が遅く (1~数十秒/枚)、本研究は 4 章で記す通り 0.1 秒/枚程度と革新的であるとともに実用面からみても重要である。

また、本論文に記載した景観画像からの船舶の検出に関する知見は、陸上からの通航船舶の監視のみならず船上に設置したカメラによる航海当直の支援システムの構築の際にも共通して適用できる。

なお、本研究は日本船舶海洋工学会講演会等で概要を説明したものである⁴⁾⁵⁾。本論文では手順と検出実験結果、検出限界等について詳述する。

2. 設置機材と構成

神奈川県横須賀市の観音崎レーダー施設（研究当時の名称は海上保安庁第三管区海上保安本部東京湾海上交通センター）の庁舎屋上に、表1に示す可視光カメラと遠赤外線カメラ各1台を設置し、一定時間間隔で浦賀水道航路を図1で示す撮影範囲で撮影した。同時に、AIS受信機を設置し航路上の航行船舶のAIS情報を取得した。これら画像および受信AIS情報は屋内に設置したPCで記録した。遠赤外線カメラからはJPEG画像ファイルが取得できるが、画像ファイル中に不可視情報として二次元温度情報が記録されており、本研究ではJPEG画像ではなく温度情報から最高・最低温度で正規化した画像を再構成し、船影の検出処理を行うこととした。




図1 撮影範囲（破線は浦賀水道航路）

表1 可視光・遠赤外線カメラの型式、仕様と撮影条件

	可視光カメラ	遠赤外線カメラ
メーカー 型番 一般的な用途	ソニー SNC-WR632 防犯監視等の汎用、屋外設置型	日本アビオニクス株式会社 R500 工場配管等の設備診断用 ⁶⁾ 筐体を屋外設置用に変更
解像度 [pixels] (水平×垂直)	1920×1080	640×480, 超解像処理により 1280×960
視野角 [deg.] (水平×垂直), ズーム設定	ズーム off 時 64×36 本研究では2倍ズーム設定	32×24 ズーム機能なし
1 ファイルあたり 画像容量 [MB]	約 0.95 (JPEG)	約 2.5 (JPEG, 超解像, 温度情報あり)
本研究における撮影 インターバル	約 3.4 秒	10 秒

3. 深層学習による検出器の作成

深層学習による景観画像からの物体検出 (Object Detection) ・画像認識 (Image Recognition) を行うアルゴリズムとしては, Faster-RCNN⁸⁾を採用した. このアルゴリズムやその派生版が PASCAL VOC (The PASCAL Visual Object Classes Challenge), ILSVRC (ImageNet Large Scale Visual Recognition Challenge) や COCO (Common Objects in Context) といった物体検出コンペティションで優勝し物体検出アルゴリズムのデファクトスタンダードとなっているものの1つである. 本アルゴリズムの開発者により Python を用いた実装が公開されており⁹⁾, これを利用して学習および検出を行った.

まず, 2016 年 3 月および 7~10 月に撮影した景観画像から船影部分を枠で囲むアノテーションを行い, 教師画像データベースを作成した. 船影の例を図 2 に示す. 小型の船影については検証時と同一の小型船 (4 章・表 3 に示す Boat-A, Boat-B) を航行させることにより画像を得, 長辺 8pixels 以上の船影を教師画像に含めた.

教師画像データベースに含まれるトレーニング用船影数を表 2 に示す. 画像認識の対象となる同表の船種カテゴリーとして, ITU⁷⁾で定義された AIS Message 5 情報に含まれる Type of Ship クラスを用い, さらにこのクラスで貨物船として一括りになっているコンテナ船, 自動車専用船や, タンカーにおける LNG 船は目視で判別できるためこれらを細分化した. また, AIS 情報の発信されていない船舶についても目視で判別した.

ただし, 遠赤外線画像においては船影画像からの情報量が少なく, 形状による船種カテゴリー認識が困難だったため検出器の作成においては船舶の検出のみを学習させ, カテゴリーは「Ship」の 1 種類のみとして船種認識を行わないこととした. 可視光画像においては検出器の作成の際に船舶の検出と船種カテゴリー認識の学習を行ったものの, 小型船影からの船種認識や, 通航船舶の大部分を占める一般貨物船とタンカー, 漁船とプレジャーボートのように類似した船型の認識が目視でも難しく, 正確なトレーニングデータや検証用データの作成が困難なため船種認識についての正確性の検証は行わず, 検出成績のみを検証対象とした.

次に, 深層学習において過学習を防ぎ検出性能を向上させるためには, トレーニングデータの多様性を維持しつつ件数を増加させることが重要である. 本研究では左右反転させたものをトレーニングデータに加える Augmentation という操作により, 実際のトレーニングデータ数を同表の影像件数の 2 倍としている.




図 2 教師画像データベース中の船影例

(それぞれ可視光カメラと遠赤外線カメラの同一船舶の影像を組で示す)

表2 教師画像データベースにおけるトレーニング用船影件数

船種カテゴリー		可視画像	赤外画像
貨物船	コンテナ船	279	125
	自動車運搬船	91	34
	ガット	204	162
	バージ	17	26
	その他	1969	1064
タンカー	LNG	44	25
	その他	187	104
官船	軍用船	55	39
	巡視船	19	28
	交通船	28	5
パイロットボート		47	69
漁船		562	649
プレジャーボート		435	288
高速船		22	17
タグボート		212	133
曳舟		13	26
帆船（ヨット）		63	9
旅客船		23	10
計		4270	2813

作成した教師画像データベースを用いて、船舶の検出器をトレーニングした。その手順を図3に示す。

Faster-RCNN では入力された画像から物体を検出しそれがどのカテゴリーに属するかを認識する一連の処理を行うため、次のような機能で構成されている。

- ① 画像全体の特徴を要約する畳み込み層(Convolutional Neural Networks)
- ② 物体候補領域を提示する Region Proposal Networks
- ③ それぞれの領域の物体を認識しカテゴリー認識する全結合層 (Fully Connected Layer)

このうち畳み込み層ではそのネットワーク構造が選択できるようになっており、ここでは AlexNet¹⁰⁾の構造を利用した。前段の畳み込み層と後段の全結合層については、BVLIC AlexNet 学習済みモデル¹¹⁾をモデルの初期値として利用して転移学習を行い、学習を効率化した。

教師画像を用いた学習について、学習率 0.001、学習繰り返し回数 40,000 回、学習時間は可視、遠赤外線画像に対し、GPU を用いてそれぞれ約 2 時間であった（PC として intel Core-i7 6700 + 32GB RAM, NVidia GeForce GTX 1080 + 8GB VRAM を使用）。GPU を用いない場合は 3 日程度と推計される。




図3 検出器のトレーニング手順

4. 景観画像からの船影の検出と船種認識

教師画像データベース中、トレーニングに使用しなかった景観画像を検出器に入力して船影を検出、可視光画像については船種の認識を同時に行った。景観画像1枚当たり処理時間は可視、遠赤外画像ともに0.06～0.09秒、GPUを用いない場合は2.0～2.7秒であった（PCのスペックは前章と同じ）。

小型船2隻をチャーターし、撮影範囲内を航行させて景観画像を撮影し、船影検出実験を行った。実験の概要を表3に記す。

表3 船影検出実験の概要

日 時	2016年12月20日15:24から16:36
天 候	12:00現在くもり、北北東の風2.6m/s、気温8.9℃
照 度	5,800Lux（15:25）～220Lux（16:35）
実験対象船舶	浦賀水道航路上の航行船舶（距離1.6km～3.0km）出現隻数65隻 小型船 Boat-A 6.6トン、11m 浦賀水道航路の手前側（距離0.6～1.6km）を航行 小型船 Boat-B 19トン、17m 浦賀水道航路の奥側（距離3.7～5.3km）を航行
景観画像枚数	可視光1,274枚、遠赤外426枚


4.1 航路上の船舶の検出

浦賀水道航路上の航行船舶の検出結果を表4、図4に示す。図はいずれも検出された船体を赤の矩形で示し、船種カテゴリーと出力層のSoftmax出力値（分類問題において通常、そのカテゴリーに適合する確率とみなされる）を青の白抜き文字で示している。追い越しやすれ違いの場面では時々船影が重なったりすることがあり、その際は重なった2隻の船舶を1隻と認識してしまったり、どちらかの船影を無視してしまった。わずかに非検出

の例があり、他船と近い、船影が小さい等の事由があるものの特に検出に支障があるとは認められなかった。また可視景観画像の船種認識では、コンテナ船、自動車運搬船のような形状に特徴のある船舶の認識は良好であった。類似した形状の船舶の区別が明確にできなかったほか、出現頻度が低く教師画像枚数が少ない船種の提示は困難であった。

表4 各検出手段における航路上の船舶の検出率

撮影手段	船影数	内訳		件数	割合 (%)
可視光カメラ	1,755	検出		1,665	94.9
		非検出	船影が他船と重なる	87	4.9
			特に理由は認められず	3	0.2
遠赤外カメラ	587	検出		567	96.6
		非検出	船影が他船と重なる	17	2.9
			特に理由は認められず	3	0.5



(左) 可視光画像 (右) 遠赤外線画像

図4 船舶の検出・認識結果

4.2 小型船による検出実験

第3章に示した、深層学習（Faster-RCNN）による実験対象船の検出率を表5に「Faster-RCNN」列として示す。可視カメラ画像（1,274枚）については、航路上を航行する商船の認識については複数隻の船影が重ならない限

り、概ね欠落は見られなかった。航路の手前側を航行する Boat-A が撮影範囲に存在する間は画像の左右端近傍に船が存在する場合に若干欠落があった。検出できた画像のうち、最も小さく撮影されている船影は正面を向いており船影のサイズ（幅×高さ、以下同様）が 14×19 ピクセルである。一方、航路の奥側を航行する Boat-B は、全く検出できなかった。最も大きく撮影されている船影は 11×5 ピクセルであり、船舶としての形状はほとんど確認できなかった。鳥や波を誤検出することが 6 件ほど見られた。

遠赤外カメラ画像（426 枚）については、航路上を航行する大型船の認識については複数隻の船影が重ならない限り、概ね欠落は見られなかった。航路の手前側を航行する Boat-A は欠落が 1.1%程度と、ほとんど見られなかった。検出できた画像のうち最も小さく撮影されている船影は正面を向いており幅×高さが 11×14 ピクセルである。一方、航路の奥側を航行する Boat-B は、わずかに 6.1%で検出された。検出された船影は 9×5 ピクセル程度である。波形状と太陽光の反射に起因すると思われる斑を船舶として認識する誤検出は 20 件ほど見られた。


Faster-RCNN フレームワークとして公開されているソースコードでは物体を検出する枠の最小サイズが 16×16 ピクセルとして定義されており、基本的にこれより小さい物体を検出物として提示しない。試しにこのサイズ定義をより小さくして検出実験を行ったが、小型船影の検出率は改善されなかったので、物体として認識できるアルゴリズム上の限界であると考えられる。

表 5 各検出手段における検出率

撮影手段	船舶	浦賀航路に対する船舶の位置	検出率 (%)	
			BING	Faster-RCNN
可視光カメラ	Boat-A	手前側	71.8	98.6
	Boat-B	奥側	1.8	0.0
遠赤外線カメラ	Boat-A	手前側	45.5	98.9
	Boat-B	奥側	8.7	6.1



(a) 可視（長辺 19pixels）



(b) 赤外（長辺 12pixels）

図 5 大きさが検出限界に近い対象物の例

4.3 異なるアルゴリズムとの船影検出における比較

景観画像中の物体検出を行うアルゴリズムとして BING¹²⁾がある。これは画像処理的手法を用いた物体検出手法であり、色の勾配やエッジ密度、特徴が似た画素同士を結合するなどして画像から「物体らしき部分」を検出する。船種の認識は行わないため、認識を行う場合は別途、該当部分の切り出しおよび画像認識の機構を組み合わせる必要がある。

BING は深層学習によるものではないが教師画像セットを用意しモデルをトレーニングし、目的とする物体を検出できる検出器を作成する。晴天時と曇天時等でそれぞれの場合の教師画像を使用して個別の検出器を作成し、さらにマッチコスト（物体らしさの指標）の閾値を検出結果を見ながら手作業で調整する必要がある（マッチコ

ストが適正でないと、False Positive や False Negative が増大する)。一方、Faster-RCNN では天候に応じた検出器の切り替えは必要なく、パラメータの調整も不要である。

BING の場合、景観画像からの画像抽出にかかる処理時間は、1 枚当たり 0.5～0.7 秒であった（PC のスペックは前章と同じ。なお、GPU を用いる公開されたライブラリが存在しないため、GPU を使用していない）。

実験対象船の検出率を表 5 に「BING」列として示す。Faster-RCNN と比較し浦賀水道航路の奥側に航行し船影の小さい Boat-B の検出率が若干良いが、航路の手前を航行する Boat-A の検出率が著しく悪く、また曳き波を誤検出することが多いため総合的に劣っていることが確認できた。同じ景観画像に対する検出例を図 6 に示す。BING では曳き波を誤検出してしまっており、一方 Faster-RCNN では曳き波の誤検出がないものの、遠方にある小型船が検出できていない。

表 6 各検出手段における処理時間

		処理時間 (sec/frame)
BING	(CPU のみ)	0.5～0.7
Faster-RCNN	(CPU のみ)	2.0～2.7
	(GPU 利用)	0.06～0.09



(左)BING による検出例。曳波を船舶と誤検出してしまっている一方、画面中央の Boat-B を検出できている

(右)Faster-RCNN での検出例。

図 6 手法による検出結果の差異

4.4 気象等の環境条件における限界

2016 年 12 月 20 日夕刻において、照度を計測しながら Faster-RCNN による可視カメラ画像からの船舶検出を行ったところ、17 時 11 分 18 秒における図 7 の写真が実験対象船（中央手前）を正しく検出できる最後の画像であった。この時の照度は 0.3Lux であった。カメラのナイトモードは OFF である。これ以降は、海面に映り込んだ船舶の照明を船舶として検出してしまった。このことから、薄暮用にトレーニングされた検出器を作成すれば若干検出可能時間を延ばすことができる可能性がある。しかし、夜間、特に外洋では通常の可視光カメラでは船舶の灯火以外に得られる情報はなく、灯火から何らかの存在があることを検出するアルゴリズムが必要となる。

遠赤外線カメラ画像については、対象物の温度と背景である海水面の温度を遠赤外線により検出しており、一般的には船体は海水温より高温の物体として撮影されるが冬季の早朝では船体温度が海水温を下回ることがある。この例を図 8 に示す。また、図 9 に例示するように夜間に船体温と海水温がほぼ一致するために遠赤外線画像でも視認が困難になる時間帯も存在し、この場合は船体の検出は原理的に困難である。また、霧の発生時は可視光カメラで船影を視認できないような状況では遠赤外線カメラでも視認が困難であった。



図 7 船舶検出できる最終時点の可視光景観画像



図 8 船体温度が海面温度より低い場合の遠赤外線画像からの検出例




図 9 遠赤外線画像で船体部分がほとんど視認できない状況
(2017/01/05 20 時、左方大型船の右隣に小型船が存在する)

5. まとめと展望

5.1 まとめ

幅狭海域である浦賀水道航路を航行する船舶を光学的に検出するため、神奈川県横須賀市の東京湾海上交通センター（研究当時）に可視光・遠赤外線カメラ各1台を設置し、景観画像からの船影検出を行い、次の結果を得た。

1. 深層学習の一手法である Faster-RCNN による船影検出では、浦賀水道航路上の航行船舶の検出では約 94.9%~96.6%の船影を検出した。非検出例のほとんどは他船と重なった場合であり、特段の理由の認められない非検出例は 0.2~0.5%であった。
2. 小型船2隻をそれぞれ浦賀水道航路の手前側、奥側を航行させて検出させたところ、Faster-RCNN による船影検出では、手前を航行している小型船の検出率は約 98.6~98.9%であった。最小の船影は可視光で長辺 19 ピクセル、遠赤外光で長辺 14 ピクセルであった。奥側の場合は船影が小さく 0~6.1%であった。
3. 画像処理的手法である BING による船影検出を行い、Faster-RCNN と比較した。BING による場合は、手前側は 45.5~71.8%，奥側は 1.8~8.7%であり、かつ曳き波等の誤検出が目立った。処理速度や、事前調整の必要性を含め、全般的に Faster-RCNN が優れていたが、船型の見出しにくい小船影の検出においては BING が優れていた。
4. 可視光において小型船が正常検出できる照度の下限は 0.3Lux であった。遠赤外画像では、夜間の一部の時間帯において、船体温度と海面温度がほとんど同じ、または昼間と逆転する時間帯があり、検出が困難になる時間帯があることを示唆した。

これらの基礎的な性能に関する知見は、本研究のような通航船舶の監視システムのほか、船上での航海当直の支援システム等の構築についても適用でき、設計や ODD（Operational Design Domain：運行設計領域）といった性能ベースラインの決定等に広く応用できるものと考えられる。

5.2 今後の展望

本研究においては、可視光カメラと遠赤外線カメラにおいてそれぞれの検出限界、利用可能時間帯や天候等の環境条件を検討するため、それぞれ独立した撮影・画像転送システムや学習モデルを使用し検出を行った。本研究では運用上の理由で2台のカメラの撮影インターバルが異なるが、撮影タイミングを合わせ画像を重ねることで4つの色情報をもつ画像として扱うと、独立して扱うより高い検出性能を得られる可能性がある。ただし、ネットワークモデルが独自のものとなり転移学習のための既存の学習済みモデルを利用できないなど不利な点があることも考慮に入れる必要がある。

また本報告では省略したが、景観画像中の船舶影像の横ピクセル位置をもとに左右位置を、喫水線の縦ピクセル位置をもとに奥行方向の距離を算出し、検出船舶の位置を推定し、AIS による船位を正として精度を検証したところ、奥行方向の距離推定偶然誤差が航路上の船舶でおよそ±10%、200~300メートル程度あり、片道航路幅が700メートルである浦賀水道航路を正しく通航しているかを監視する目的において十分でなかった。原因として、船影の喫水線の位置の正確な検出が困難であったことが考えられる。そのため、海上技術安全研究所では、船舶の左右舷に計2台の可視光カメラを設置して同時に撮影し、立体視の手法で検出船舶の相対位置を推定するシステムを構築している。成果については稿を改めて報告する。

謝 辞

本研究は海上保安庁による一般財団法人日本航路標識協会との共同請負研究「平成28年度AIS非搭載船の動静把握に関する技術開発」により実施したものです。検討の一部はJSPS科研費20K04956の助成を受けて実施しました。また東京海洋大学 西崎ちひろ氏にはカメラシステム構築においてご尽力いただきました。関係各位に感謝申し上げます。

参考文献

- 1) Marco Balduzzi, Alessandro Pasta, Kyle Wihoit, A Security Evaluation of AIS Automated Identification System, Proceedings of the 30th Annual Computer Security Applications Conference, p.436-445, 2014.12
- 2) 松本洋平, HOG(Histograms of Oriented Gradient) 特徴量を用いた船舶画像認識, 日本航海学会論文集 129, pp.105-112, 2013.
- 3) Pawełczyk, M., Data augmentation for haar cascade based automobile detection, The Archives of Automotive Engineering, Vol. 82, No. 4, 2018.
- 4) 小林 充, 丹羽 康之, 福戸 淳司, 岩崎 一晴, 深層学習による景観画像からの船影の検出, 日本船舶海洋工学会講演会論文集 Conference proceedings, the Japan Society of Naval Architects and Ocean Engineers (26), 121-124, 2018-05
- 5) 小林 充, 丹羽 康之, 福戸 淳司, 岩崎 一晴, 沿岸カメラ画像からの船影の検出と船種の認識への深層学習の適用, 咸臨 : 日本船舶海洋工学会誌 (79), 28-31, 2018-07
- 6) 日本アビオニクス株式会社, ニュースリリース, <https://www.avio.co.jp/news/html/pdf/140306-r500.pdf>, 2021.1.22 閲覧
- 7) International Telecommunication Union, “Recommendation ITU-R M.1371-5 Technical characteristics for an automatic identification system using time division multiple access in the VHF maritime mobile frequency band”, 2014.2.
- 8) Ren, Shaoqing, et al. “Faster R-CNN: Towards real-time object detection with region proposal networks.”, Advances in neural information processing systems, arXiv:1506.01497, 2015.
- 9) Ross Girshick, “py-faster-rcnn”, <https://github.com/rbgirshick/py-faster-rcnn>, 2021.1.22 閲覧
- 10) Alex Krizhevsky, Ilya Sutskever, Geoffrey E. Hinton, “Imagenet classification with deep convolutional neural networks”, Advances in neural information processing systems, 2012.
- 11) https://github.com/BVLC/caffe/tree/master/models/bvlc_alexnet, 2021.1.22 閲覧
- 12) Cheng, et al. “BING: Binarized Normed Gradients for Objectness Estimation at 300fps”, <http://mmcheng.net/bing/>, 2021.1.22 閲覧