



2023年度

内航船等の操船者の負荷低減を実現する普及型夜間画像  
認識システムの技術開発

2024年3月

一般社団法人 日本船用工業会

## はしがき

本報告書は、BOAT RACE の交付金による日本財団の助成金を受けて、2022年度及び2023年度に一般社団法人日本舶用工業会が実施した「内航船等の操船者の負荷低減を実現する普及型夜間画像認識システムの技術開発の技術開発」の成果をとりまとめたものである。

本開発は、2022年度、2023年度の2年計画で、JRCS 株式会社に委託して実施しており、2年度分の報告書をここにまとめたものである。

ここに、貴重な開発資金を助成いただいた日本財団、並びに関係者の皆様に厚く御礼申し上げる次第である。

2024年3月  
(一社)日本舶用工業会

## 目 次

1. 事業の目的 .....	1
2. 事業の目標 .....	1
2.1 2022 年度の目標 .....	1
2.2 2023 年度の目標 .....	1
3. 2022 年度の実施報告 .....	2
3.1 2022 年度の実施内容 .....	2
3.1.1 サンプル画像の収集（夜間） .....	2
3.1.2 サンプル画像の前処理（夜間） .....	8
3.1.3 AIによる学習（夜間） .....	10
3.1.4 学習結果の実証（夜間） .....	11
3.1.5 製品への反映 .....	35
3.1.6 視界制限下の検討と検証（雨天・霧） .....	37
3.2 2022 年度の目標達成状況 .....	44
3.2.1 サンプルデータの収集実績（夜間） .....	44
3.2.2 サンプルデータの前処理実績（夜間） .....	44
3.2.3 AIの学習データの構築実績（夜間） .....	44
3.2.4 実証試験の実績（夜間） .....	44
3.3 2022 年度の実施内容の概要 .....	45
3.3.1 サンプル画像の収集（夜間） .....	45
3.3.2 サンプル画像の前処理（夜間） .....	45
3.3.3 AIによる学習（夜間） .....	45
3.3.4 学習結果の実証（夜間） .....	45
3.3.5 製品への反映（夜間） .....	46
3.3.6 視界制限下の検討と検証（雨天・霧） .....	46
4. 2023 年度の実施報告 .....	47
4.1 2023 年度の実施内容 .....	47
4.1.1 サンプル画像の収集（雨天・霧） .....	47
4.1.2 サンプル画像の前処理（雨天・霧） .....	52
4.1.3 AIによる学習（雨天・霧） .....	55
4.1.4 学習結果の実証（雨天・霧） .....	61
4.1.5 製品への反映 .....	83

4.2	2023年度の目標達成状況 .....	85
4.2.1	サンプルデータの収集実績（雨天・霧） .....	85
4.2.2	サンプルデータの前処理実績（雨天・霧） .....	85
4.2.3	AIの学習データの構築実績（雨天・霧） .....	85
4.2.4	実証試験の実績（雨天・霧） .....	85
4.3	2023年度の実施内容の概要 .....	86
4.3.1	サンプル画像の収集（雨天・霧） .....	86
4.3.2	サンプル画像の前処理（雨天・霧） .....	86
4.3.3	AIによる学習（雨天・霧） .....	86
4.3.4	学習結果の実証（雨天・霧） .....	87
4.3.5	製品への反映（雨天・霧） .....	87
5.	今後の予定 .....	88
5.1	視界制限下の学習データの収集 .....	88
5.2	視界不良の要因対策 .....	88
5.3	波による影響の対策 .....	88
5.4	販売計画について .....	88
6.	まとめ .....	88
7.	出典および参考文献 .....	89

## 1. 事業の目的

船舶の航行において、狭水域や輻輳海域、漁業操業エリアでの操船者の負担軽減ならびに衝突・座礁をはじめとする事故リスクを低減する為に、一般産業用カメラ（以下可視光カメラ）によるコンピュータービジョン技術（以下CV技術）及び画像処理技術を用いた操船支援システムを開発する。現状、CV技術では夜間や雨天、霧などによる視界制限下での認識性能が課題として挙げられ、高額な遠赤外線カメラやレーザーカメラに依存することから普及率が上がっていない状況である。本開発では、夜間を含めた視界制限下での物体の認識を、可視光カメラと画像処理により実現し、既存技術と比較してコストを1/10程度に抑え、更にセンサーフュージョンにより正確性を向上させる事で、海運業界に広く普及させ船舶の安全運航と海上物流の安全性向上に貢献する。

本事業の目的は以上の通りであるが、既に開発が完了している昼間を対象としたカメラによる物体認識システムとあわせ、広く普及させられる価格帯で且つ本船の周辺状況を正確に把握する画像認識システムの作成と上市を早期に実現する必要がある。正確性に関連しては、光学カメラと共にLiDARセンサーとの統合（センサーフュージョン）も含めて本事業内容として実施する。既存のLiDARセンサーを用いたソリューションはLiDARからの信号を直接プロセッサで処理し、距離を計測する方式が一般的であるが、本開発事業ではカメラ画像と統合し、画像認識による物体検知精度をより向上させる目的で使用される。また、これらのセンサーフュージョンに際しては、一般的な可視光カメラを単独で使用する場合と比較して高額になることが見込まれるが、従来技術と比較したコストメリットを重視し、広く普及させる事が可能な価格帯（1/10程度のコスト感）を実現させる。

\*視界制限の定義は海上衝突予防法3条12に準じた霧、もや、降雪、暴風雨、砂あらしその他これらに類する自由により視界が制限されている状態とする。

## 2. 事業の目標

### 2.1 2022年度の目標

- (1) 夜間の物体認識距離を1,000m以上とする。
- (2) 夜間における1,000m以下での物体の認識率を90%以上とする。

### 2.2 2023年度の目標

- (1) 霧及び降雨による視界制限下で物体の認識可能な距離を1,000m以上とする。
- (2) センサーとの統合を含め、1,000m以内での物体の認識率を90%以上とする。

### 3. 2022 年度の実施報告

#### 3.1 2022 年度の実施内容

##### 3.1.1 サンプル画像の収集（夜間）

可視光カメラによる夜の物体認識を実現するにあたり、AI が学習する教師データを作成するため、サンプル画像を収集する必要がある。これらのサンプル画像の収集は夜間を航行する阪九フェリー株式会社の船舶である「いずみ」（以下「いずみ」と記載）に図 1 で示す構成の録画システムを装備し、夜間の船舶の画像、航海用の航路浮標やブイなどの漁業施設の画像を収集した。

[阪九フェリー株式会社 いずみ]

船種	Ro-Ro/Passenger
サイズ	全長 195m, 全幅 30m
総トン数	15,897 t

##### 3.1.1.1 録画用システムの構成

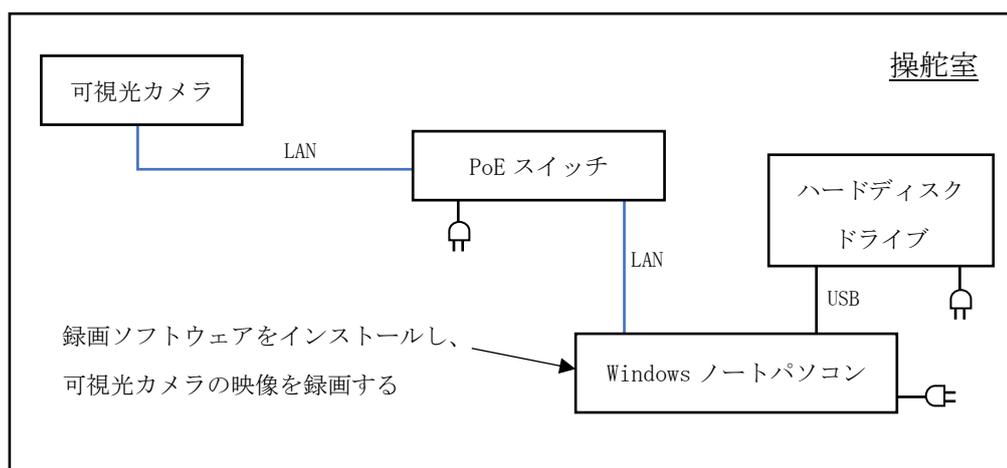


図 1：録画システムの構成

可視光カメラの接続インターフェースは PoE (Power over Ethernet) 規格であるため、LAN ケーブルで電源供給が行える PoE スイッチを使用した。可視光カメラの映像は、録画ソフトウェアをインストールした Windows ノートパソコンで収録し、録画データは外付けのハードディスクドライブに記録させた。これにより、録画データの回収はハードディスクドライブを交換するだけとなり、容易に回収作業を行うことができた。録画データの回収周期はおよそ 1 ヶ月で行った。

可視光カメラから出力される映像データの通信容量は非常に大きいため、システムで利用する機器や LAN ケーブルの仕様はギガビット対応のものでなければならない。可視光カメラの映像は 5M ピクセルの解像度で夜間の映像をより明るく調整できるようにするため 1 ピクセルあたり 16 ビットの階調で映し

出すようにしている。このため1フレームの通信容量は80Mビットとなり、動画(10fps)の場合は800Mビット/秒の通信容量が必要となる。ネットワークを構成するLANケーブルはCat5e規格以上のケーブルを利用する必要があり、本録画システムではCat7規格のLANケーブルを使用した。同様にPoEスイッチについてもギガビット仕様のものを選定して利用している。

録画ソフトウェアはWindowsノートパソコンにインストールして映像データをハードディスクドライブに記録するが、可視光カメラの映像フォーマットはGVSP(GigE Vision Streaming Protocol)の非圧縮フォーマットのデータであり、このデータをそのまま録画すると数日でテラバイトを超える記録データとなってしまう。図2に示す通りGVSPプロトコルのデータをRTSPプロトコルのH.264圧縮データに変換し、そのデータをハードディスクドライブに記録するようにした。

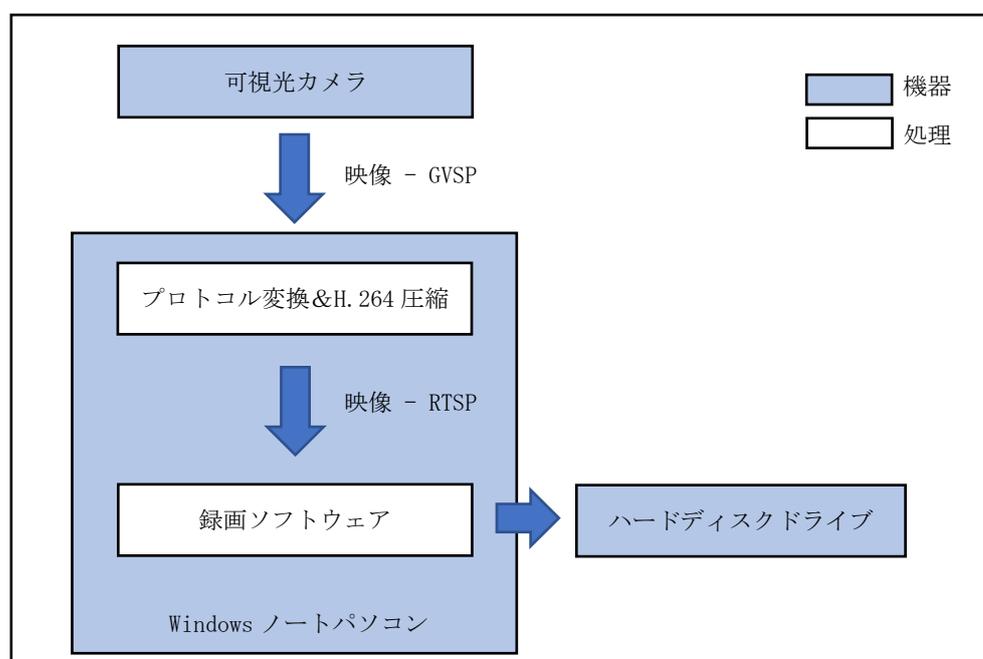


図2：プロトコル変換と映像録画のフロー

この処理により、4TBのハードディスクドライブに映像を6ヶ月間記録することができるようになった。

操舵室へ搭載した可視光カメラは自船と行き交う船が多く存在する左舷側を映すように設置した。しかし、可視光カメラを操舵室のガラスの内側に設置しているため、ガラスの反射により操舵室内の映像の映り込みが発生した。この映り込みを防止するため、図3に示す暗幕で可視光カメラとガラスの隙間を覆う対策を施した。



図 3 : ガラスの反射による映り込みの防止対策

その他の Windows ノートパソコンや周辺機器は図4に示すように操舵室中央の前方に設置した。操舵室内は夜間航行中、船外の様子を見やすくするため通常真っ暗にしている。このため、これらの機器が放つ光 (LED ランプ) などは、光を漏らさないように銀色のテープで覆い、通常業務に支障を起こさないよう対策を施した。

映像の録画は本船の航行時間である 18 時から翌朝の 6 時の間を常時録画できるようにスケジュールリングした。

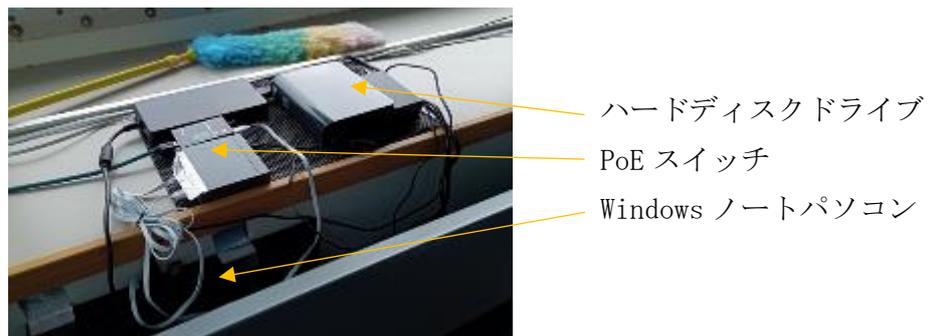


図 4 : Windows ノートパソコンおよび周辺機器

### 3.1.1.2 録画中の航行ルート

本船の航路は図5(※1:出典)に示すように、福岡県北九州市の新門司港から大阪府泉大津市の泉大津港を行き来するルートとなる。航行時間は共に18時から翌朝6時となるが、その日の天候や陸上からの灯りの量の違いにより、場所によっては夜間の映像の見え方が異なる。

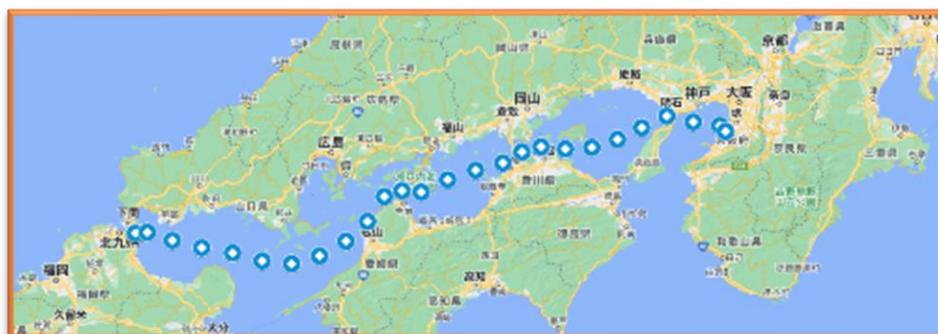
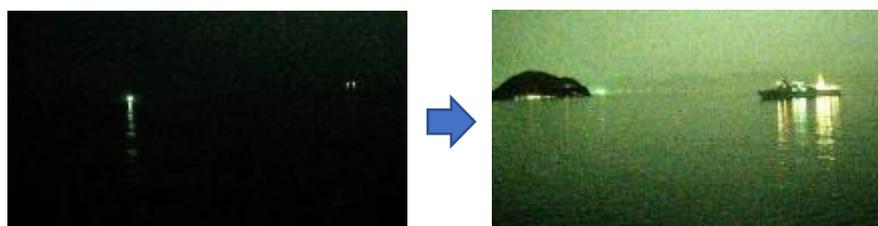


図5：航行ルート(※1)

夜間の明るさの状態によって可視光カメラのパラメータ調整が必要となるが、本録画システムでは無人で録画を行うため、都度、パラメータを調整することができない。よって、本船での録画作業においては、夜間の映像をより良く映し出す最適なパラメータを模索し、その値で録画を行うようにした。

### 3.1.1.3 夜間録画における最適なパラメータの調査

可視光カメラには明るさを調整するパラメータとしてセンサーに当たる光の量を調整する露光値と撮影素子が受光した光を電気信号へ変換する際の増幅量を調整するゲイン値がある。各々のパラメータは夜間撮影の際に自動的に最大値に設定されるが、露光値とゲイン値だけの調整では光の少ない夜の映像を明るく映し出すことはできない。本事業で使用する可視光カメラは3.1.1.1項で述べたように1色を16ビットの階調(ビット深度)で映し出すようにしており、このビット深度の利用範囲をソフトウェアでデジタル的に調節することで画像の中の明るい部分だけを抽出した映像を作り出すことができる。



ビット深度の調整前

ビット深度の調整後

図6：ビット深度の調整範囲の比較

図 6 に示す 2 つの画像はビット深度を調整していない画像（画像左）とビット深度を調整した画像（画像右）の比較となるが、ビット深度を調整した画像の方は画像全体をより明るく表示でき船舶の形を捉えていることが分かる。しかし、ビット深度の調整で明るくすればするほど利用できる色の階調数が少なくなり画像にノイズが発生し船舶の形も捉えられなくなってしまう。ビット深度の調整をどの程度に調整するのが最適であるかは非常にシビアであり最も難しい点であった。

今回、この録画システムの搭載目的は AI が学習するための画像を収集することであるため、ビット深度の調整は航海中の撮影に適した値（表 1 のビット深度レンジのレベル 3）に固定し、映像の収録を行なった。

※ 製品への組み込みの際は、画像全体の明るさをリアルタイムに判断し、その時の明るさに合ったビット深度のレンジ設定（レベル 0 からレベル 4 の 5 段階）を自動的に行うようにした。

表 1：明るさに関するパラメータ設定内容

設定内容	設定値		備考
露光値	自動		カメラによる自動調整
ゲイン値	自動		〃
ビット深度 レンジ	レベル 0	255～65535	昼の明るい時に利用
	レベル 1	48～12048	曇天で薄暗い時に利用
	レベル 2	128～6208	夕方から夜にかけて暗くなる時に利用
	レベル 3	0～5000	夜の光の少ない時に利用 (録画システムで利用)
	レベル 4	0～1000	夜の光の少ない時に利用

#### 3.1.1.4 サンプル画像の収集実績

サンプル画像は2022年6月から8月の3ヶ月間で収集し、データの形式は動画ファイル（avi ファイル）として記録した。

##### - 収集目標

AI 学習のため5万点の学習データを収集する。どのくらいのデータを学習させると物体の認識精度が良くなるかの定義はないが、本事業では5万点の学習データを前処理する作業期間がおよそ1ヶ月であるため、事業のスケジュールを考慮し、5万点の学習データを収集することを目標とした。

##### - 収集方法

阪九フェリー株式会社の船舶「いずみ」に録画システムを搭載し、録画映像を記録した。後から映像内に映る船舶の距離（1,000m 付近）を判断できるように AIS のデータも同時に記録した。

##### - 収集実績

- ① 収集した動画ファイルから、AI が学習に利用できる映像を選別した。
- ② 学習させるための前処理（アノテーション作業）を行うため、動画を静止画（jpeg ファイル）に変換した。（前処理に利用できる画像数は7万2千枚）
- ③ 7万2千枚の画像データから AI 学習用のデータ（17万9千点）を収集した。

5万点の学習データの収集目標に対し、17万9千点の学習データを収集できたことから、サンプル画像収集の目標値を大きく上回ることができた。

### 3.1.2 サンプル画像の前処理（夜間）

前項 3.1.1 で収集した学習データ 17 万 9 千点のうち、9 万 1 千 6 百点のアノテーション作業を実施した。アノテーション作業は画像に写っている物体への枠付け（マーキング）と、その物体のラベル付け（表 2 に示す 8 種類のクラス）を行った。

表 2：アノテーション作業のクラス定義

クラス ID	クラス名	説明
0	Vessel	他のクラスに定義している旅客船、漁船、小型船を除く船舶
1	Fishing_Buoy	海上に浮かぶ漁業用のブイ
2	Navigation_Buoy	海上交通のための航海ブイ
3	Passenger_Vessel	旅客船
4	Fishing_Boat	漁船
5	Small_Vessel	ボート、カヌー、ジェットスキーなどの主にレジャーとして利用される小型船
6	Fishiers_Facility	漁業用の施設（養殖用の筏や網などの施設）
7	Human	人

アノテーション作業における枠の形式は図 7 に示す矩形（赤枠）を採用し、矩形は物体の境界に合わせるように囲んでいる。これはソフトウェアがこの枠の底辺から物体の位置を特定し、推定距離の算出を行えるようにするため矩形は物体の境界に合わせるようにしている。



図 7：アノテーション画像

クラスは表 2 の 8 種類を定義したが、夜間の画像は暗くて見えづらく漁業用ブイや漁船など小さな物体を判別することが困難であった。このため、クラスの種類毎の学習データ数に大きく偏りが発生した。

### 3.1.2.1 サンプル画像の前処理の実績

収集したサンプル画像は動画データであるため、前処理を実施するにあたり動画データを静止画データ（jpeg フォーマット）に変換してアノテーション作業を実施した。アノテーションしたデータ数はおよそ9万1千6百点で、その内訳は表3の通りとなる。

表 3：アノテーション作業の実績数

クラス ID	クラス名	データ数
0	Vessel	74, 227
1	Fishing_Buoy	5
2	Navigation_Buoy	5, 393
3	Passenger_Vessel	2, 531
4	Fishing_Boat	53
5	Small_Vessel	9, 394
6	Fishiers_Facility	0
7	Human	0

計 91, 603

サンプル画像の収集方法は「いずみ」に録画システムを搭載して収集したため、表3の通り Vessel クラスのデータが多くなっている。また、夜間の録画データであること、および航路が限定されていることからデータ数が0のクラスも存在し、クラス分けのデータ数に偏りが発生した。データ数が0のクラスに関しては、夜間で利用する学習データが存在しないことになるが、実施者のシステムでは昼用の学習データと夜用の学習データを共用利用する形式をとっているため、これらの対象物に関しては認識精度が低くなってしまいが昼用の学習データが利用されることになる。その他アノテーションデータの少ないクラスに関しては、今後も継続してデータを収集しながら学習させていく。

### 3.1.3 AI による学習（夜間）

#### 3.1.3.1 AI 学習データ構築の進捗

2023 年 1 月に「いずみ」で行う実証試験のため、3.1.2 項のアノテーション作業で作成したデータを用いて AI の学習データを構築した。学習データの構築においてはおよそ 2 週間の期間が必要であり、実証試験の時期的な問題から、構築した学習データ数はおよそ 4 万 1 千 5 百点となった。その内訳は表 4 の通りとなる。

表 4：AI 学習データのクラス別内訳

クラス ID	クラス名	データ数
0	Vessel	31,834
1	Fishing_Buoy	5
2	Navigation_Buoy	3,632
3	Passenger_Vessel	1,772
4	Fishing_Boat	53
5	Small_Vessel	4,274
6	Fishiers_Facility	0
7	Human	0

計 41,570

学習データは表 4 の 8 クラスの種別で準備したが、実施者のソフトウェアがまだ 8 クラス対応されていないため、今回の実証試験では、Vessel、Navigation\_Buoy、Fishing\_Buoy の 3 種類のクラスで学習を実施した。表 4 のクラス ID が 0、3、4、5 のものは全て 0 の Vessel クラスに統合している。

なお、9 万 1 千 6 百点の学習データの構築に関しては、2023 年 2 月に 8 クラスとしての学習を実施済みである。

AI 学習データの構築方法はディープラーニングを利用している。畳み込みニューラルネットワークを使用してトレーニングを実施し、およそデータの 75%を学習用に、残りの 25%を検証用に利用している。また、物体認識したデータの出力に関しては全てのデータを出力すると検出結果の信頼度が低下するため、フィールドテストを行いながら結果出力のための最適な閾値を検討した。閾値は、AI が判定する物体認識の確からしさを示す信頼性スコア (Confidence Score) の値が 21.3%以下のものは出力しないように設定した。この値は小さな物体 (Fishing\_Buoy, Navigation\_Buoy) を正しく認識した時の最小の信頼性スコアの平均値で算出した。

### 3.1.4 学習結果の実証（夜間）

#### 3.1.4.1 製品への反映

3.1.3 項で作成した学習データを「いずみ」で実証試験する前に、関門海峡を通る船舶の映像を利用して、認識精度の評価テスト（陸上試験）を実施した。

評価テスト日時 : 2023年1月16日 21:30 ~ 21:40

評価対象船 : IZUMI MARU No.10 (LPGタンカー)

全長70m、全幅12m、平均船速7.4ノット

利用カメラ台数 : 3台 (Port Cam, Center Cam, Starboard Cam)

船舶は図8（※1:出典）の黄色の点線で示すように、画像右側の東北東から画像左側の西南西に向かっている航路となる。3台の可視光カメラは並べて配置し、各々の画角が重なるようにしている。評価対象となる船舶をいずれかの可視光カメラが映像に捉えられる構成にしている。



図8：評価テストで対象となった船舶の航路（※1）

評価基準は以下の内容とする。

認識距離 : 1,000m以下の距離にある船舶を対象とする

認識率 : 1秒間隔で認識し続ける確率（連続認識率）が90%以上

※ 物体の認識は可視光カメラが映し出す映像の中から物体を特定して認識するが、一瞬だけの認識や途切れ途切りの認識となると乗組員がそれを見逃してしまい運用レベルでの実用は困難と考える。このため、映し出される映像の中で毎秒連続して認識し続けることが実用レベルでは不可欠であると考え。

評価テストの結果は表 5 の通りとなった。

表 5：関門海峡での評価テストの結果

カメラ	左舷カメラ Port Cam	中央カメラ Center Cam	右舷カメラ Starboard Cam
最長距離	965m	765m	445m
最短距離	581m	356m	355m
連続認識率	74%	100%	100%

左舷カメラの連続認識率が悪かったのは、距離 900m から 800m の地点で、対象船とその背面にある工場の灯が重なり、船の形が捉えにくくなったのが原因だった。外乱による影響がなかった映像は全て認識精度が良かったため、この学習データを製品のソフトウェアに組み込み、「いずみ」での実証試験を進めることにした。

#### 3.1.4.2 学習データの評価

4 万 1 千 5 百点の学習データについてその評価指標のスコアを算出してみた。

適合率 (Precision) =  $TP / (TP + FP) = 0.73$

再現性 (Recall) =  $TP / (TP + FN) = 0.75$

※ TP(True Positive) 真陽性：船舶を船舶と正しく認識した数

※ FP(False Positive) 真陰性：船舶以外を船舶と間違えて認識した数

※ FN(False Negative) 偽陽性：船舶を認識しなかった数

適合率は正解の物体として予測した全ての数のうち実際に正解した数の割合を示す。上記結果を要約すると予測したうちの 73%が正解で、残り 27%が誤認識の割合になる。再現性については全ての正解の数のうち、いくつ正解があったかの割合を示す。正解の数のうち 75%が認識でき、25%が取りこぼしの割合となる。両者ともに 1.0 に近い数値が望ましいが、乗組員の意思決定支援のためのシステムであることを考慮すると、誤認識の割合が多くても取りこぼしの割合が少ないことが望ましいと考える。今後の学習データの構築目標として Recall の数値をより高められるよう学習していく必要がある。

船舶の認識データは誤認識の割合より正解の割合が多い結果が出ているが、ブイ関連のデータは正解の割合よりも誤認識の割合の方が多くなっていた。適合率および再現性の数値を上げるにはブイ関連の学習データを増やすことで学習データの精度はより高められると考える。

### 3.1.4.3 夜間認識精度の実証試験

実証試験は、サンプル画像を収集した船舶と同一の「いずみ」に実施者の製品（以下 infoceanus command と記載）をインストールして実施した。システム構成は図 9 に示すように可視光カメラ 3 台を屋外のコンパスデッキに設置し、映像から物体検知を行うエッジサーバーは屋内の電気機器室に設置した。infoceanus command では物体認識のための映像入力以外にも、航海計器からの信号入力が必要なため、操舵室にある航海計器から出力される信号をエッジサーバーに取り込むため、操舵室にある航海計器用の HUB に LAN ケーブルを配線した。

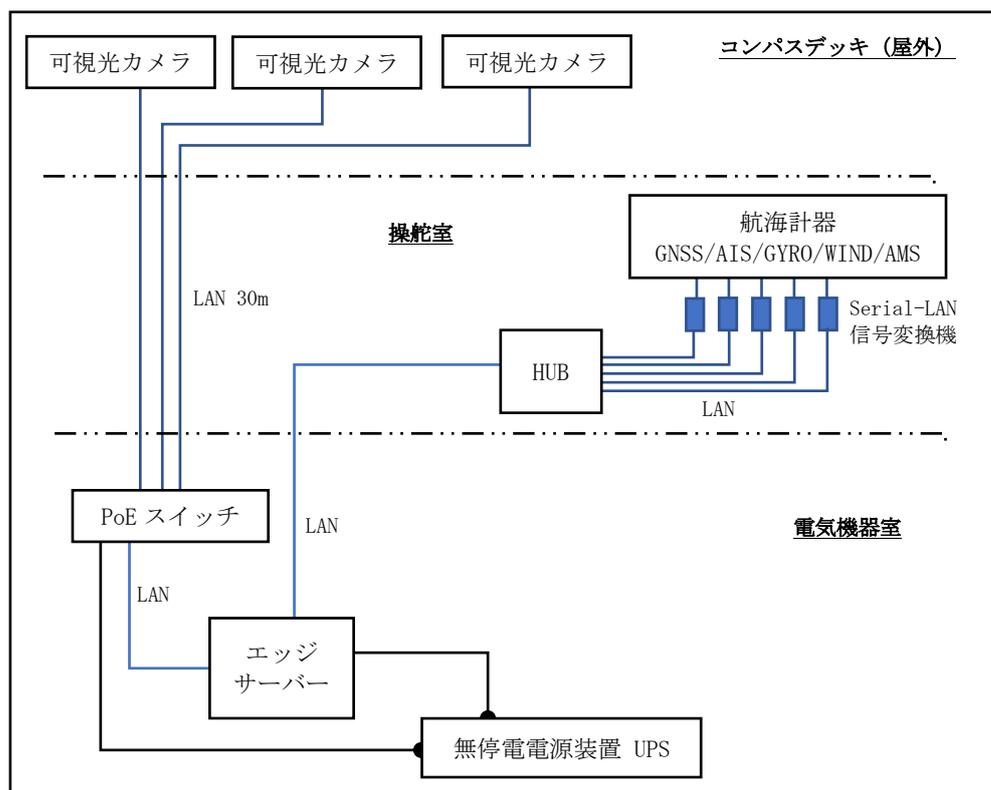


図 9：実証試験システム構成 (infoceanus command)

## 1. 可視光カメラ 3 台の設置

進行方向に見える映像を広く映し出せるように可視光カメラは正面、左舷側、右舷側の 3 箇所に設置した。可視光カメラは 50 度の画角を有しているため、可視光カメラ 3 台を利用することにより前方 150 度の範囲で他船を捉えることができる。図 10 に示すように可視光カメラは防水用のカメラハウジング内に装備しコンパスデッキに設置した。



図 10：可視光カメラの設置

このカメラハウジングの材質は塩基性および熱に強いテクノポリマーを採用しており、IP67 の防塵防水保護等級を有している。本製品は今回の実証試験用として一般商用品を取り扱ったが、infoceanus command では可視光カメラ 3 台を 1 つの筐体内に装備できる専用のカメラハウジングを設計して構築した。この製品については 3.1.5.2 製品用カメラハウジングの項に記載する。

## 2. エッジサーバーおよび周辺機器のインストール

可視光カメラの通信および電源供給用となる PoE スイッチ、エッジサーバー、無停電電源装置を電気機器室内に図 11 の構成で設置した。航海計器の信号入力は、本船内の既存システムから受信できるため、操舵室内にある HUB とエッジサーバーを LAN ケーブルで接続して受信できるようにした。

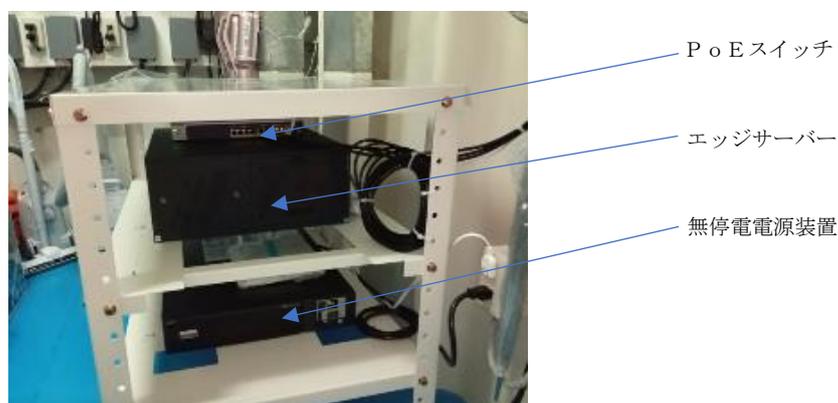


図 11：エッジサーバーおよび周辺機器の設置

#### 3.1.4.4 夜間認識精度の実証試験結果

実証試験は2022年12月と、2023年1月の2回を実施した。しかし、2022年12月の実証試験結果については、AI学習データがまだ1万6千点であったため詳細な報告は割愛する。

##### 1. 実証試験の実施日時

試験開始日時： 2023年1月20日 18:00

試験終了日時： 2023年1月21日 06:00

##### 2. 実証試験の場所

実証試験は、「いずみ」の通常運行航路である瀬戸内海の航路で行ったが、海上周辺の明るさや時間帯によって海上物の見え方が変わるため、図12（※1:出典）に示す周防灘エリア、備讃瀬戸エリア、明石エリアの3箇所の実証試験を実施した。

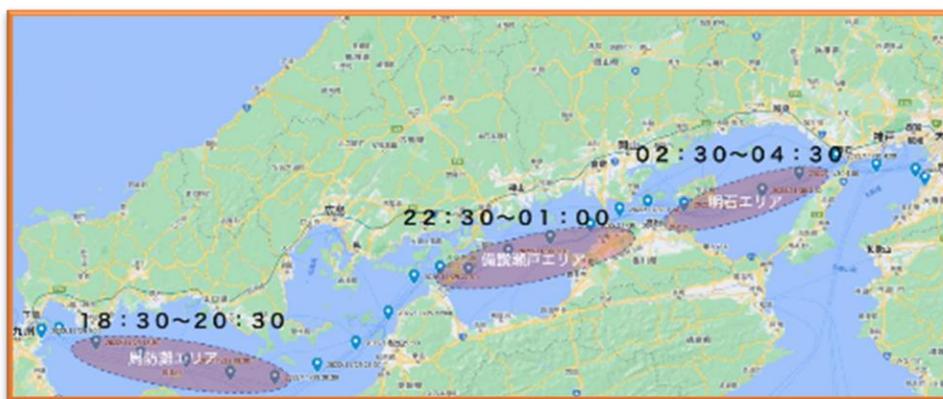


図 12：実証試験エリア（※1）

##### 3. 実証試験結果

###### (1) 実証試験の目標

夜間の物体認識距離を1,000m以上とする。

夜間における1,000m以下での物体の認識率を90%以上とする。

###### (2) 実証試験の評価方法

1,000m以下の連続認識率を評価するため、試験対象となった船舶すべての連続認識率を1km毎に分けて算出し、その平均値を持って評価することとした。また、連続認識率の分析のため、実証試験を実施した試験エリア毎、船舶の種類毎でも連続認識率を算出した。

(3) 実証試験の結果

評価を行なった対象船は計 14 隻で、表 6 の内訳となる。

表 6：実証試験の対象船リスト

船名	全長	船種	検出海域
HENG HE	76m	General Cargo	周防灘エリア
KUNIHISA No. 21	62m	General Cargo	周防灘エリア
DESERT FAITH	199m	Bulk Carrier	周防灘エリア
S MERMAID	81m	General Cargo	周防灘エリア
MIKAGE	96m	Container	備讃瀬戸エリア
FERRY OSAKA II	183m	Passenger	備讃瀬戸エリア
TOMOEMARU	59m	Chemical Tanker	備讃瀬戸エリア
HIBIKI	195m	Passenger	備讃瀬戸エリア
NAGATA MARU	74m	General Cargo	備讃瀬戸エリア
DONGJIN FORTUNE	130m	Container	明石エリア
RITSURIN 2	116m	Passenger	明石エリア
LI ZE	76m	General Cargo	明石エリア
ORANGE OSAKA	199m	Passenger	明石エリア
KOUSEN MARU	50m	Chemical Tanker	明石エリア

実証試験の評価結果を表 7 にまとめた。表 6 で示した各船舶の連続認識率を距離毎に平均して算出した値である。ちなみに、これらの船舶の中で最も長い距離で検出した距離は 10km であった。

表 7：距離別による連続認識率

距離	0～1km	1～2km	2～3km	3～4km	4～5km	5～10km
連続認識率	92%	80%	93%	96%	94%	69%

1km～2km の連続認識率が他の距離と比べて 80%と低くなっているが、5km までの連続認識率は 90%を超える精度の高い結果が得られた。以前に実施した実証試験（2022 年 12 月：学習データ数は 1 万 6 千点）に比べ、連続認識率は高くなっていることから、1km～2km にある船の学習データを増やすことでこの連続認識率の向上が期待できる。

表 8 は海域別での連続認識率を比較したものとなる。図 13 は各海域での検出画像となるが、周辺の明るさは街明かりの多い明石エリアが最も明るい。周防灘エリアおよび備讃瀬戸エリアは島が多く

陸上までの距離もあるため、全体的に暗い映像となっているが、4kmまでの連続認識率の平均を比較すると、各々およそ 90%の認識率であることから、これらの海域別で連続認識率に大きな変化は見られなかった。

表 8：海域別の連続認識率

海域	0～1km	1～2km	2～3km	3～4km	4～5km	5～10km
周防灘	100%	65%	94%	100%	92%	69%
備讃瀬戸	87%	93%	92%	84%	---	---
明石	94%	74%	94%	100%	100%	---



図 13：海域別の検出映像の比較

次に対象船の種類別に連続認識率の違いを表9に比較してみると、Bulk Carrierの1km～2kmの認識率が低くなっていることが分かる。

表 9：船種別の連続認識率

船種	0～1km	1～2km	2～3km	3～4km	4～5km	5～10km
Bulk	---	39%	88%	100%	100%	71%
Cargo	91%	85%	97%	100%	83%	67%
Container	100%	91%	93%	100%	100%	---
Passenger	---	83%	93%	84%	---	---
Tanker	88%	73%	---	---	---	---

これは、図14のように1隻で認識していた船舶が途中で2隻に分離したことで異なる船になったと判断され、連続的に認識できなくなっていたのが原因であった。対象船が遠くから近くなるにつれ、船首灯と船尾灯の距離が離れ、さらに映像が暗いことにより船舶の形が捉えられていないことから、2隻であると判断されたものと思われる。これは可視光カメラの明るさのパラメータ調整をもっと明るくすることで回避できると考える。

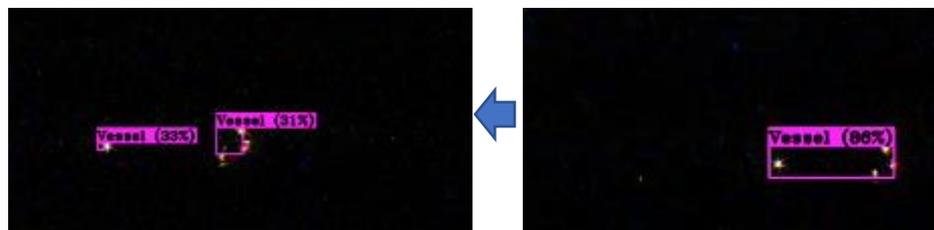


図 14：船舶の認識が1隻から2隻に分離

今回の目標の1つである夜間の物体認識距離1,000m以上については、表7の結果から5km以上も検出できているため目標を達成することができた。また、もう1つの目標である1,000m以下の物体認識率90%以上についても、表7に示すように92%の結果が得られたことから、こちらも目標を達成することができた。

### 3.1.4.5 夜間認識精度の実証試験結果（詳細）

各認識した船舶の情報と認識した時の距離および連続認識率を以下に記載する。距離については自船の座標と対象船となる船舶の座標を AIS から取得し、座標計算によって算出した。

#### ① 実証試験結果 1

船名	HENG HE
船種	General Cargo
大きさ	全長 76m / 全幅 12m
計測時間、状況	1 分 11 秒、前方の同じ方向に進む船舶
最長認識距離	891m～1, 261m
連続認識率	100%



図 15：対象船の写真(※2)



図 16：認識時の映像

図 15 は対象船舶の写真（※2:出典）、図 16 に認識時の画像、図 17 に検出時の航路（※1:出典）をそれぞれ示す。図 17 に示すように対象船の左側から追い越す航路となり、対象船との距離は 1.2km から 891m に近づく形となる。図 16 は中央の可視光カメラで捉えた船舶（HENG HE）の画像となるが、可視光カメラのフォーカスが若干合っていないため船舶の光が発散している。しかし、100%の連続認識率で船舶として捉え続けることができた。



図 17：検出時の航路（※1）

② 実証試験結果 2

船名	KUNIHISA No. 21
船種	General Cargo
大きさ	全長 62m / 全幅 10m
計測時間、状況	4 分 0 秒、右舷側を行き交う船舶
最長認識距離	2, 227m～5, 582m
連続認識率	92%



図 18 : 対象船の写真 (※2)

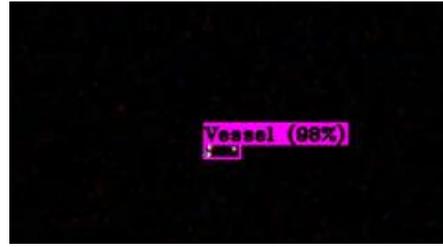


図 19 : 認識時の映像

図 18 は対象船舶の写真 (※2:出典)、図 19 は右舷カメラが捉えた船舶 (KUNIHISA No. 21) の認識画像、図 20 は検出時の航路 (※1:出典) をそれぞれ示す。図 20 に示すように対象船と右舷側を行き交う航路で、5.5km 先から 2.2km に近づく船舶を認識した。4.5km 付近から 2.2km まで、連続認識率は 100%であった。



図 20 : 検出時の航路 (※1)

③ 実証実験結果 3

船名	DESERT FAITH
船種	Bulk Carrier
大きさ	全長 199m / 全幅 32m
計測時間、状況	7分52秒、前方から近づく船舶
認識距離	3,233m ~ 10,649m
連続認識率	80%



図 21：対象船の写真（※2）

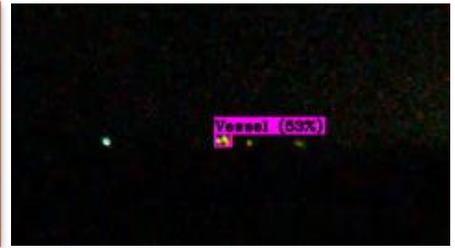


図 22：認識時の映像

図 21 は対象船舶の写真（※2:出典）、図 22 は中央カメラが捉えた船舶（DESERT FAITH）の認識画像、図 23 は検出時の航路（※1:出典）をそれぞれ示す。全長 199m と大きな船舶ではあるが図 23 のように最長 10.6km 先で検出することができた。前方から近づく船舶で、距離 8km 付近からの連続認識率 95%と良い結果が得られた。

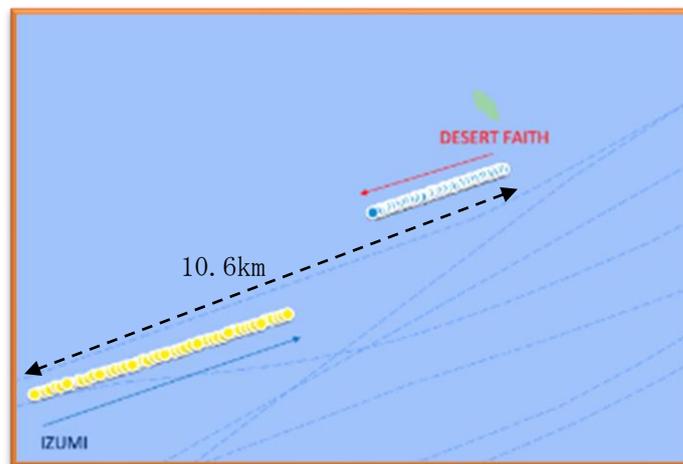


図 23：検出時の航路（※1）

④ 実証実験結果 4

船名	DESERT FAITH
船種	Bulk Carrier
大きさ	全長 199m / 全幅 32m
計測時間、状況	1 分 53 秒、左舷側を行き交う船舶
認識距離	1, 614m ~ 2, 458m
連続認識率	54%



図 24 : 対象船の写真 (※2)

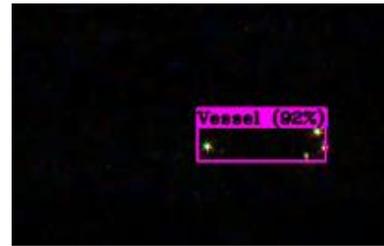


図 25 : 認識時の映像

図 24 は対象船舶の写真 (※2:出典)、図 25 は左舷カメラが捉えた船舶 (DESERT FAITH) の認識画像、図 27 は検出時の航路 (※1:出典) をそれぞれ示す。図 27 に示すように左側を行き交う船舶を認識している。距離 2.3km 付近に近づくまでは連続認識率が 93%と良い結果だったが、それ以降連続認識率が低下し、結果 54%の連続認識率となった。この原因は、3.1.4.4 項で説明した内容と同様で、図 26 に示すように 1 隻の船舶が異なる 2 隻の船舶として認識され、57 秒間対象船としての認識が途切れてしまったことによるものとなる。

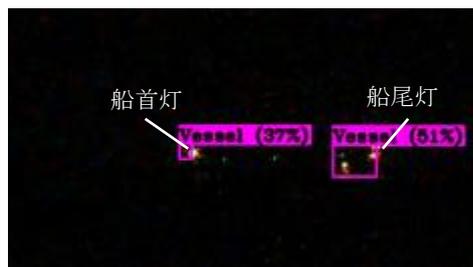


図 26 : 1 隻の船舶が 2 隻として認識



図 27 : 検出時の航路 (※1)

⑤ 実証実験結果 5

船名	S MERMAID
船種	General Cargo
大きさ	全長 81m / 全幅 14m
計測時間、状況	1 分 10 秒、左舷側を行き交う船舶
認識距離	1,340m ~ 2,129m
連続認識率	92%



図 28 : 対象船の写真 (※2)

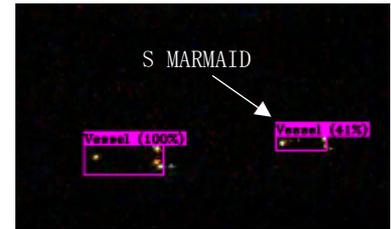


図 29 : 認識時の映像

図 28 は対象船舶の写真 (※2:出典)、図 29 は左舷カメラが捉えた船舶 (S MERMAID) の認識画像、図 30 は検出時の航路 (※1:出典) をそれぞれ示す。図 30 に示すように左舷側を行き交う船舶 2 隻を認識した。1.7km に近づくまで連続認識率は 82%だったが、その後 98%と向上し、結果、連続認識率は 92%となった。

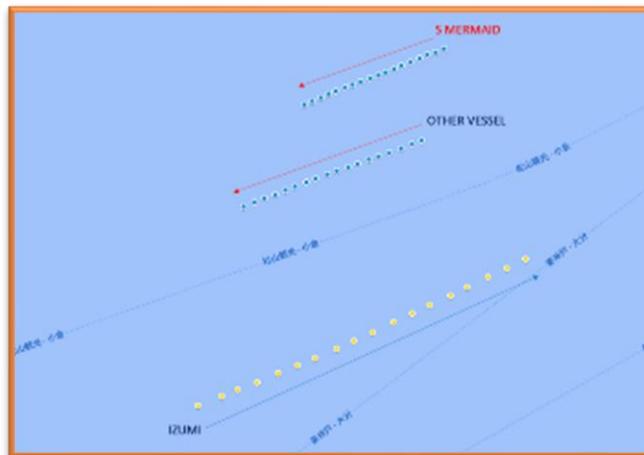


図 30 : 検出時の航路 (※1)

⑥ 実証実験結果 6

船名	MIKAGE
船種	Container
大きさ	全長 96m / 全幅 14m
計測時間、状況	2分0秒、左舷側を行き交う船
認識距離	1,076m ~ 2,605m
連続認識率	93%



図 31 : 対象船の写真 (※2)

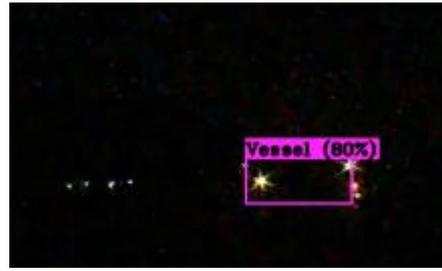


図 32 : 認識時の映像

図 31 は対象船舶の写真 (※2:出典)、図 32 は左舷カメラが捉えた船舶 (MIKAGE) の認識画像、図 33 は検出時の航路 (※1:出典) をそれぞれ示す。図 33 に示すように対象船は左舷側を行き交う船舶で、自船は若干左舷側に旋回しながら対象船を認識している。連続認識率は距離 2.2km に近づくまでは 77%と低く、その後、距離が近づくに連れ 98%の連続認識率に改善した。認識した船舶の背後には陸上の灯りがあり、その灯りと重なることもあったが、影響なく認識し続けることができた。

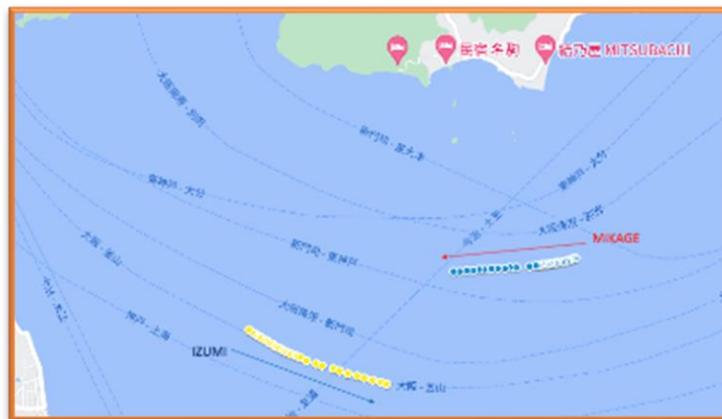


図 33 : 検出時の航路 (※1)

⑦ 実証実験結果 7

船名	FERRY OSAKA II
船種	Passenger
大きさ	全長 183m / 全幅 27m
計測時間、状況	2分31秒、左舷側を行き交う船舶
認識距離	1,573m ~ 3,725m
連続認識率	91%



図 34 : 対象船の写真 (※2)



図 35 : 認識時の映像

図 34 は対象船舶の写真 (※2:出典)、図 35 は左舷カメラが捉えた船舶 (FERRY OSAKA II) の認識画像、図 36 は検出時の航路 (※1:出典) をそれぞれ示す。図 36 に示すように旅客船のため船舶の光が多く認識しやすいと思われたが、認識し始めの 3.7km から 3.3km までは途切れ途切りの認識となり連続認識率は 60%と低くなった。その後、3.3km から 1.5km までは 96%と高い連続認識率を得た。

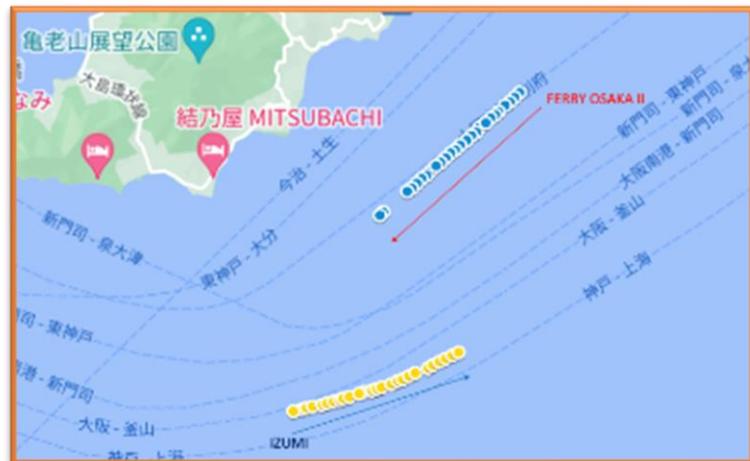


図 36 : 検出時の航路 (※1)

⑧ 実証実験結果 8

船名	TOMOEMARU
船種	Chemical Tanker
大きさ	全長 59m / 全幅 9m
計測時間、状況	2分25秒、対象船の右側を追い抜き
認識距離	1,007m ~ 1,872m
連続認識率	73%



図 37 : 対象船の写真 (※2)

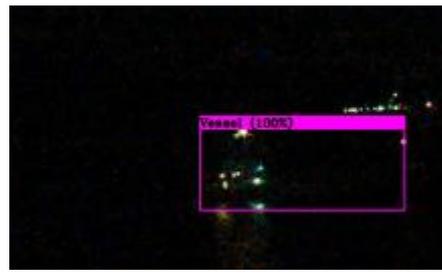


図 38 : 認識時の映像

図 37 は対象船舶の写真 (※2:出典)、図 38 は左舷カメラが捉えた船舶 (TOMOEMARU) の認識画像、図 40 は検出時の航路 (※1:出典) をそれぞれ示す。図 40 に示すように対象船の右側から追い越す航路となる。距離 1.8km から 1.3km まで近づく間の連続認識率は 95%と高かったが、1.3km より近づくと連続認識率は低くなった。この原因は図 39 に示すように、1 隻の認識が 2 隻の認識になる現象と同じであるが、このケースの場合は 2 隻が重なって認識されている。大きな枠で認識された船舶はそれまでに認識していた船舶と同じ認識であれば良かったのだが、この実証試験では異なる船舶と認識されたため、連続認識率の低下が発生した。

2 隻が重なっている  
認識のパターン

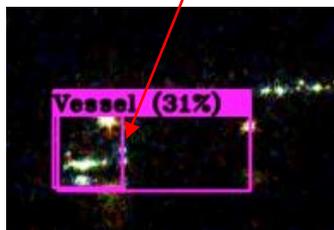


図 39 : 1 隻の船舶を 2 隻として認識

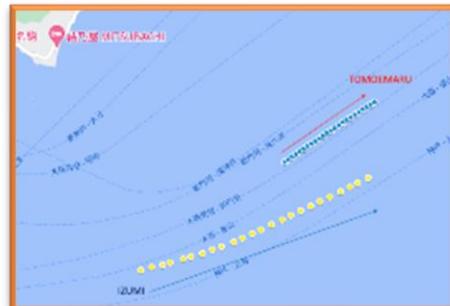


図 40 : 検出時の航路 (※1)

⑨ 実証実験結果 9

船名	HIBIKI
船種	Passenger
大きさ	全長 195m / 全幅 30m
計測時間、状況	1 分 33 秒、左舷側を行き交う船舶
認識距離	1, 446m ~ 3, 422m
連続認識率	100%



図 41 : 対象船の写真 (※2)



図 42 : 認識時の映像

図 41 は対象船舶の写真 (※2:出典)、図 42 は左舷カメラが捉えた船舶 (HIBIKI) の認識画像、図 43 は検出時の航路 (※1:出典) をそれぞれ示す。図 42 に示すように旅客船のため明るく映っており船体の形状がはっきりと分かる。光により船舶の形が捉えられているため、3km を超える距離でも 100%の連続認識率を得ることができた。

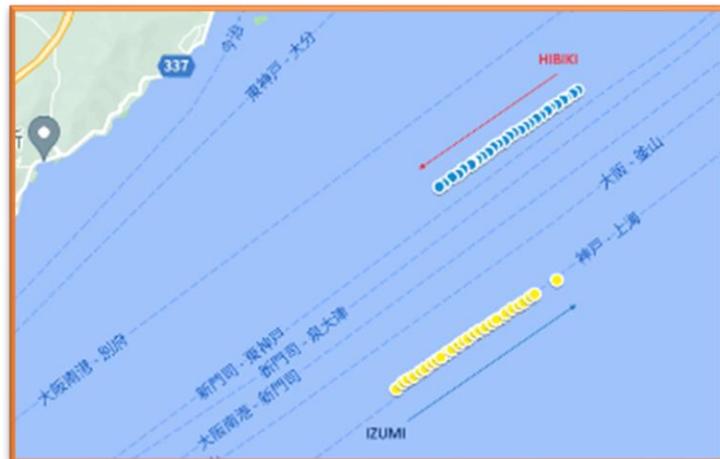


図 43 : 検出時の航路 (※1)

⑩ 実証実験結果 10

船名	NAGATA MARU
船種	General Cargo
大きさ	全長 74m / 全幅 12m
計測時間、状況	1分56秒、対象船の右側を追い抜き
認識距離	775m ~ 391m
連続認識率	74%



図 44 : 対象船の写真 (※2)



図 45 : 認識時の映像

図 44 は対象船舶の写真 (※2:出典)、図 45 は左舷カメラが捉えた船舶 (NAGATA MARU) の認識画像、図 47 は検出時の航路 (※1:出典) をそれぞれ示す。連続認識率が低いのは図 46 のように、およそ 500m から 700m 地点で 1 隻の認識が 2 隻の認識になっているのが原因であり、実証実験結果 8 と同様となる。



船舶後部の灯りのみで  
1 隻と認識

図 46 : 1 隻の船舶を 2 隻として認識



図 47 : 検出時の航路 (※1)

⑪ 実証実験結果 1 1

船名	DONGJIN FORTUNE
船種	Container
大きさ	全長 130m / 全幅 20m
計測時間、状況	2分5秒、前方から近づく船舶
認識距離	2,461m ~ 4,460m
連続認識率	98%



図 48：対象船の写真（※2）

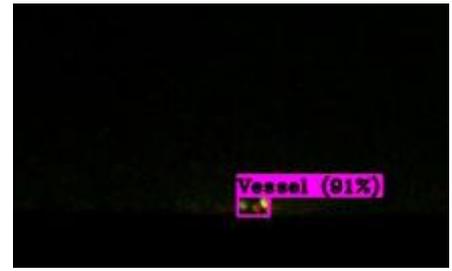


図 49：認識時の映像

図 48 は対象船舶の写真（※2:出典）、図 49 は中央カメラが捉えた船舶（DONGJIN FORTUNE）の認識画像、図 50 は検出時の航路（※1:出典）をそれぞれ示す。中央の可視光カメラで問題なく継続して認識し続けることができた。途中、距離 2.5km 付近で 2 秒間陸上の灯りと重なり認識が途切れたが、その後も継続して認識することができた。



図 50：検出時の航路（※1）

⑫ 実証実験結果 1 2

船名	DONGJIN FORTUNE
船種	Container
大きさ	全長 130m / 全幅 20m
計測時間、状況	1 分 41 秒、左舷側を行き交う船
認識距離	1, 413m ~ 2, 641m
連続認識率	87%



図 51 : 対象船の写真 (※2)

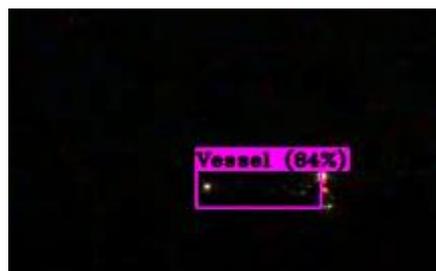


図 52 : 認識時の映像

図 51 は対象船舶の写真 (※2:出典)、図 52 は左舷カメラが捉えた船舶 (DONGJIN FORTUNE) の認識画像、図 53 は検出時の航路 (※1:出典) をそれぞれ示す。実証実験 1 1 と同一船で、左舷の可視光カメラで捉えた画像となる。距離 2.6km から 1.5km までは連続認識率 95%と良かったがそれ以降の連続認識率が低下した。船舶が近寄って大きく映し出された際、一時的に 2 隻の認識になってしまったのが連続認識率低下の原因となる。

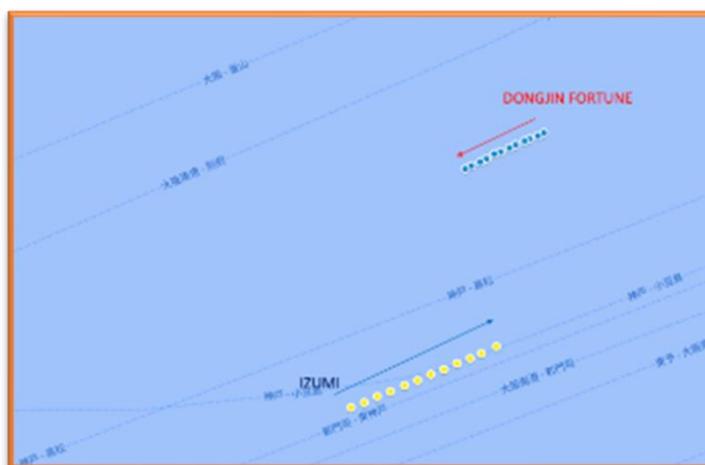


図 53 : 検出時の航路 (※1)

⑬ 実証実験結果 1 3

船名	RITSURIN 2
船種	Passenger
大きさ	全長 116m / 全幅 20m
計測時間、状況	1 分 36 秒、左舷側を行き交う船舶
認識距離	1, 573m ~ 2, 619m
連続認識率	85%



図 54 : 対象船の写真 (※2)

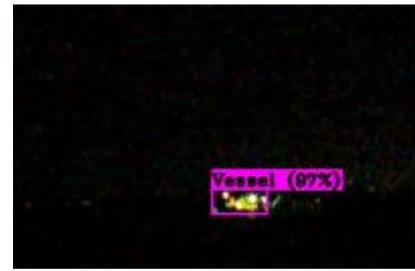


図 55 : 認識時の映像

図 54 は対象船舶の写真 (※2:出典)、図 55 は左舷カメラが捉えた船舶 (RITSURIN 2) の認識画像、図 56 は検出時の航路 (※1:出典) をそれぞれ示す。図 55 に示すように、時々光の明るい箇所のみ認識されて枠の大きさが変化してしまっているが、連続して同じ船舶である認識ができています。

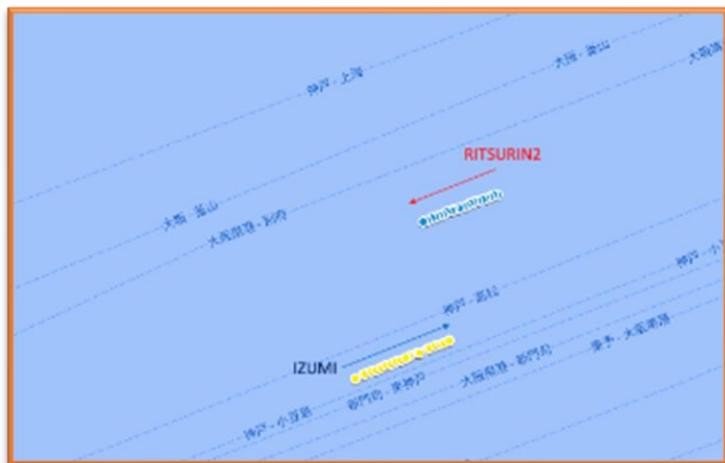


図 56 : 検出時の航路 (※1)

⑭ 実証実験結果 1 4

船名	LI ZE
船種	General Cargo
大きさ	全長 76m / 全幅 12m
計測時間、状況	1 分 9 秒、左舷側を行き交う船舶
認識距離	850m ~ 3, 107m
連続認識率	90%

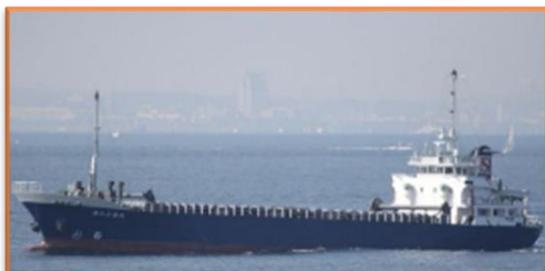


図 57 : 対象船の写真 (※2)

図 57 は対象船舶の写真 (※2:出典)、図 58 は検出時の航路 (※1:出典) をそれぞれ示す。認識時の画像は記録できなかった。対象船の距離が 3km から 1.5km までの連続認識率は 63%と低くかったが、1.5km 以下の連続認識率は 100%であった。

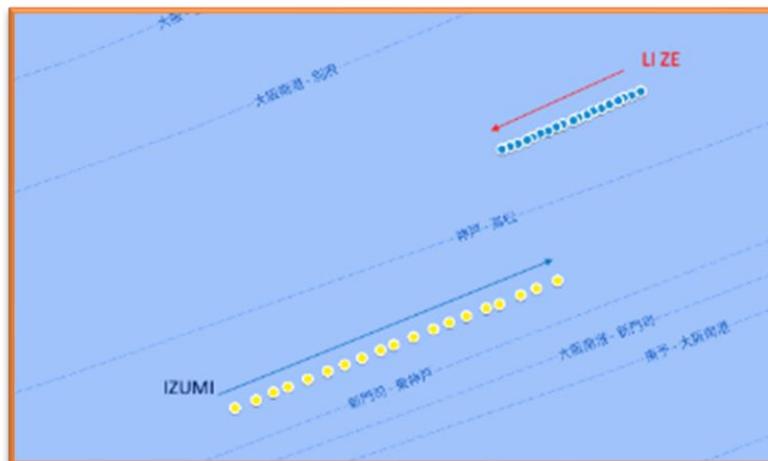


図 58 : 検出時の航路 (※1)

⑮ 実証実験結果 15

船名	ORANGE OSAKA
船種	Passenger
大きさ	全長 199m / 全幅 27m
計測時間、状況	55 秒、左舷側を行き交う船舶
認識距離	1,043m ~ 1,875m
連続認識率	50%



図 59 : 対象船の写真 (※2)



図 60 : 認識時の映像

図 59 は対象船舶の写真 (※2:出典)、図 60 は左舷カメラが捉えた船舶 (ORANGE OSAKA) の認識画像、図 62 は検出時の航路 (※1:出典) をそれぞれ示す。図 60 に示すように光の明るい箇所と暗い箇所がはっきりと別れている。船体が大きく映し出されるに連れて船の認識が分離してしまい、図 61 のように最大 3 隻まで認識が分離してしまった。およそ 8 秒間認識できなくなった現象が断続的に発生し、連続認識率の値が低くなる原因となった。

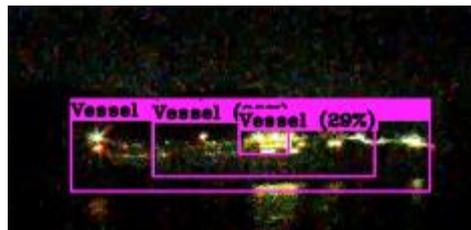


図 61 : 1 隻の船舶を 3 隻として認識



図 62 : 検出時の航路 (※1)

⑩ 実証実験結果 16

船名	KOUSEN MARU
船種	Chemical Cargo
大きさ	全長 50m / 全幅 10m
計測時間、状況	1分38秒、対象船の右側を追い抜き
認識距離	256m ~ 867m
連続認識率	88%



図 63 : 対象船の写真 (※2)



図 64 : 認識時の映像

図 63 は対象船舶の写真 (※2:出典)、図 64 は左舷カメラが捉えた船舶 (KOUSEN MARU) の認識画像、図 66 は検出時の航路 (※1:出典) をそれぞれ示す。図 66 に示すように左に旋回しながら左舷側を航行する船を追い越し、非常に近い距離での認識が続いている。最短距離での認識時は船灯の灯りが発散しており 2 隻として認識されるかと思われたが、図 65 のように上手く 1 隻として認識できていた。



図 65 : 船灯の光が発散



図 66 : 検出時の航路 (※1)

### 3.1.5 製品への反映

#### 3.1.5.1 AI 学習データの反映

夜間用の AI 学習データは 4 万 1 千 5 百点を infoceanus command へ組み込み実証試験を実施した。現状、夜間のアノテーションデータの総数は 9 万 1 千 6 百点であり、このデータの学習に関しては 2023 年 2 月に実施済みであるため、これから製品に組み込む予定である。データ数の少ないブイ関連のデータなどは新たにアノテーション作業を実施しており、今後も継続して学習データ量を増やしていく。

#### 3.1.5.2 製品用カメラハウジング

可視光カメラ 3 台を搭載できる製品用のカメラハウジング（図 67）を製作した。

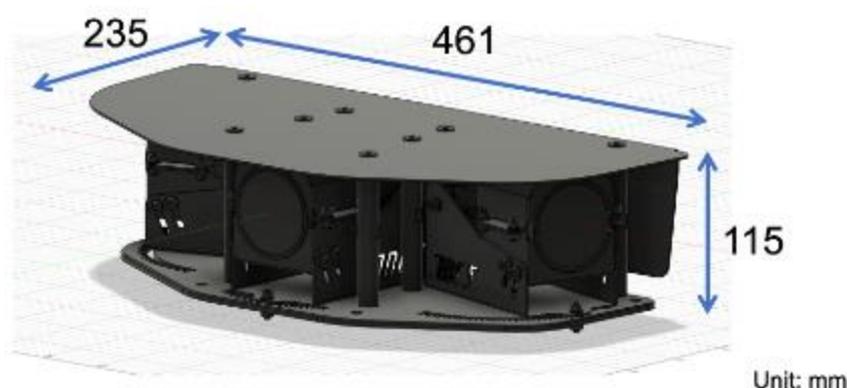


図 67：製品用カメラハウジング

カメラハウジングの特徴として防水性能があることはもちろん、可視光カメラの角度調整が行える機構を持っている。仕様は表 10 に示す。

表 10：カメラハウジング仕様

名称	カメラハウジング
全長/全幅/全高	461mm/235mm/115mm
材質	ステンレス (SUS316)
カメラ 3 台の合計最大水平視野角	225°
調整可能な水平角	0~75° (左右のカメラ) -30~30° (正面のカメラ)
調整可能な仰角	0~10°
調整可能なロール角	±5°

### 3.1.5.3 既存システムへの統合インターフェースの開発

この度開発した夜間での物体認識ソフトウェアを infoceanus command へ反映させるため、日中の AI 学習データと夜間の AI 学習データを切り替えて運用利用できるインターフェースプログラムを構築した。しかし、日中と夜間を切り替えるタイミングが時間指定では不明確となったため、日中の学習データと夜間の学習データを混合させる方針に変更した。これにより昼夜の意識をすることなく、AI が最適な学習データを選んで利用し結果を出力できるようになった。また、これらの学習データや AI プログラムはクラウド上で開発、管理する仕組みを構築しているため、遠隔地からクラウドを利用して infoceanus command へインストールすることも出来るようになった。

カメラの特性パラメータについても、パラメータ値はクラウド上で設定する仕組みを設けたため、インストールする船舶毎に最適なパラメータ値を設定することができる。

### 3.1.6 視界制限下の検討と検証（雨天・霧）

気象要因、特に海上の霧の影響による視認性の低下を克服するため、視界不良の環境下での視認性を高めるのに有効な画像処理アルゴリズムを調査した。このような画像処理機能をAIによる物体認識処理に統合することで、船員に対してより目に見える映像を提供することができると共に、AIによる物体認識精度についても性能を向上させることが可能となる。

#### 3.1.6.1 霧除去のアルゴリズムの選定

一般的に推奨されている霧除去機能について以下 3 種類アルゴリズムについて調査した。これらのアルゴリズムは、infoceanus command に容易に導入ができるものを優先して選定することにする。

##### ① DCP (Dark Channel Prior) (※3: 参考)

霧がかかった画像から白い靄を取り除く画像処理技術。画像中の霧がかかった領域が白っぽくなる特性を利用し、白くない度合いを抽出して補正する技法。

##### ② ACE (Automatic Color Enhancement) (※4: 参考)

画像を強調させるアルゴリズム。対象となる画素とその周囲の画素との明るさの関係を計算し、対象の画素値を補正してコントラストを調整する技法。

##### ③ CLAHE (Contrast Limited Adaptive Histogram Equalization) (※5: 参考)

霧による偏った画素値を、ヒストグラムを用いて平坦化し明るさの濃淡をはっきりさせる。画像全体の平坦化を行うと画像全体が明暗のどちらかに偏ってしまうため、細かなタイル（領域）に分けてヒストグラムの平坦化処理を行う。

これら 3 種類のアルゴリズムの効果を比較し、また infoceanus command へ導入するための処理の負荷についても比較した。その結果を表 11 および表 12 に示す。

表 11：霧除去効果の画像比較

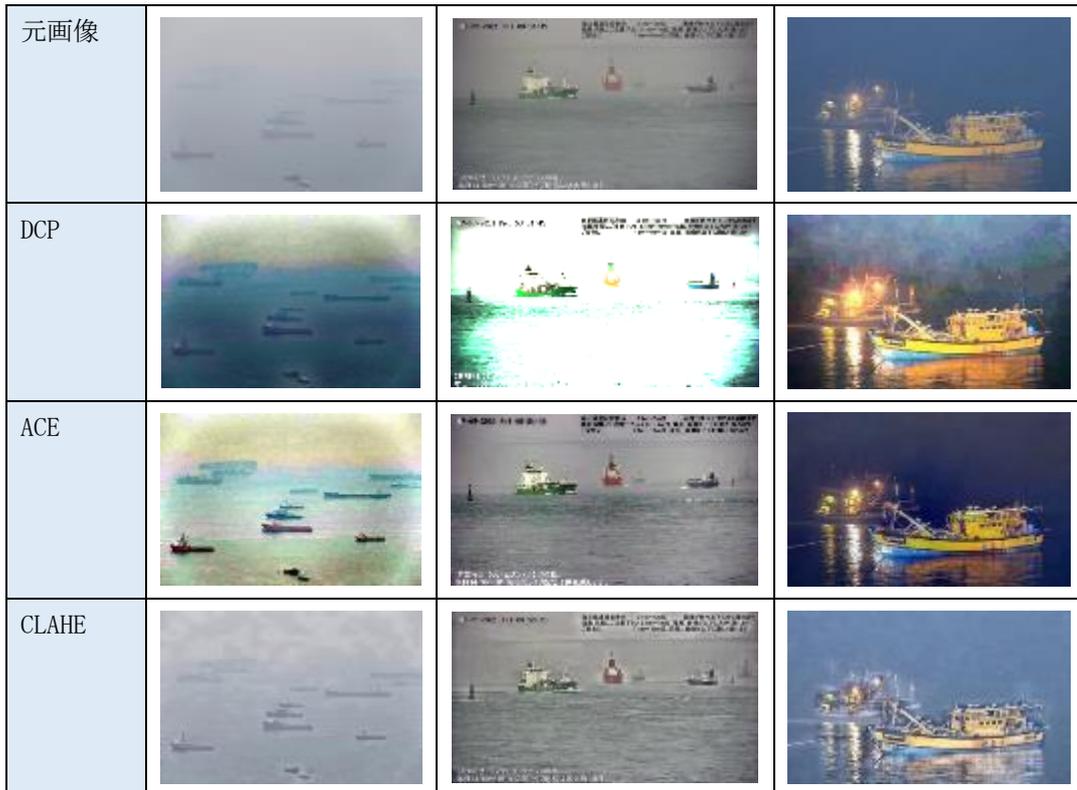


表 12：各種アルゴリズムの処理負荷の比較

	DCP	ACE	CLAHE
Processing Time	0.223sec	2.168sec	0.0054sec

画像の解像度：1920 x 1080 (pixel)

計測機器：Macbook Pro (2021 M1Pro processor)

これらの効果を比較すると、ACE のアルゴリズムは全体的に画像が自然に見え、他のアルゴリズムよりも物体を鮮明に映し出すことができている。ただし、処理計算の負荷が最も高く 1 フレームの画像を処理するのに 2 秒近くかかっている。infoceanus command では可視光カメラの映像をライブストリームで処理する必要があり、ここに 2 秒近い画像処理の仕組みを組み込むことは、システムとしての性能基準を満たすことが出来なくなってしまうため、このアルゴリズムの導入は現状、実現的ではないと言える。DCP は白く濁った箇所を取り除き、画像の濃淡をより濃くすることが出来て視認性も高めているが、画像における光の箇所が発散してしまっていることから、船灯の光が多く存在する夜間の海上の映像を処理するには適していないと考える。これらを考慮すると、画像処理の負荷が最も低く、infoceanus command への導入がしやすい CLAHE を採用して行きたいと考えている。画像の視認性を高める効果としては ACE と

比べると低くなるが、画像処理におけるシャープネスとコントラストの効果は確実に高めているのが分かる。

### 3.1.6.2 ヒストグラム均等化 (※6: 参考)

CLAHE は従来のヒストグラム均等化処理の改良版であり、画像の明るさのバランスを取りコントラストを高めるために一般的に採用されている。画像を構成するピクセル強度値のピクセル頻度をヒストグラムとして表すことができ、そのヒストグラムは図 68 のように表すことができる。この画像はコントラストが低く、全体的に色あせている（色が薄い）ことが、このヒストグラムから分かる。（グラフ横軸は明るさの階調値:0 から 255、縦軸はその階調値の画素の数）各画素の明るさが約 120 から 200 の範囲に集中しており明るさに濃淡がない。（図 68 のグラフの赤色の箇所）

低コントラスト : ヒストグラムの値の範囲が狭い  
色あせ : 値が右側に向かってヒストグラムの上限に傾いている

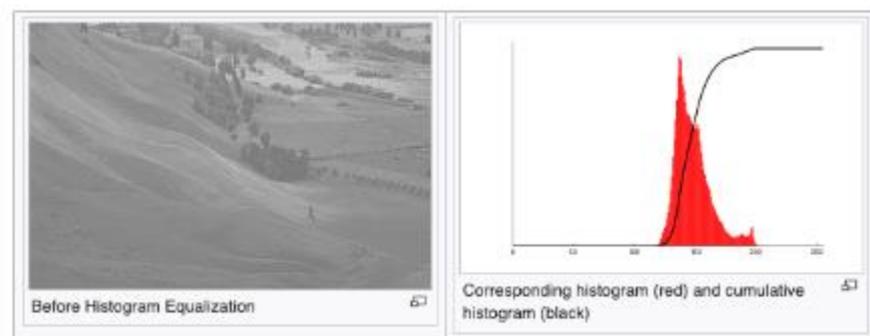


図 68 : ヒストグラム均等化前の画像

基本的なヒストグラムの均等化は、ヒストグラムの値が 0 から 255 の範囲全体に広がるようにピクセル値を調整して画像のコントラストを高めている。また、輝度のバランスもピクセル値の変換処理に含まれている。図 69 に示すように累積度数（黒い線）を均等にするため、平均ピクセル強度値がヒストグラムの全体の中央に位置するようにしている。

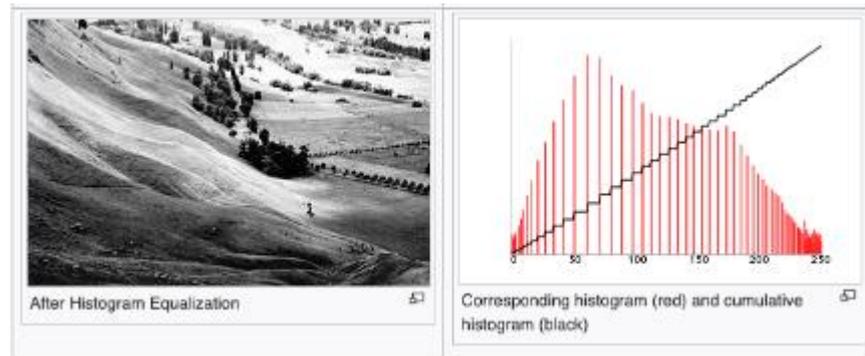


図 69 ヒストグラム均等化後の画像

### 3.1.6.3 コントラスト制限とその適応 (※6：参考)

ヒストグラム均等化された画像は通常、コントラストが改善され露出過多や露出不足などの明るさの問題が修正される。ただし、図 70 のような問題があり、この改善点がいくつかある。

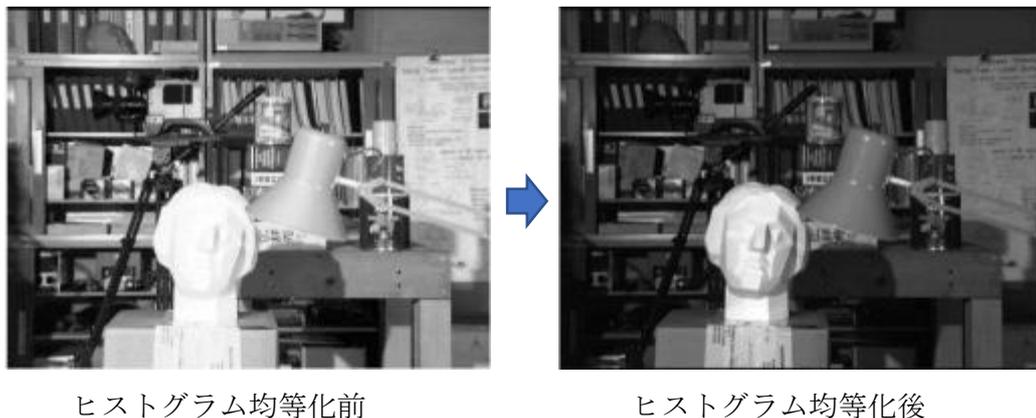


図 70 ヒストグラム均等化の問題点

図 70 の左側の画像は露出不足であり暗い領域は鮮明ではない。ヒストグラム均等化処理を行なった右側の画像は全体の明るさのバランスが改善され、暗い領域がより見えやすく改善された。しかし、元々明るかった領域がさらに明るくなり、その領域のコントラストが低下している。これは画像全体をヒストグラム均等化処理したためこの現象が発生している。この問題を解決するには、画像を定義されたグリッドのサイズ (タイル) に分割し、そのタイル毎にヒストグラム均等化処理を行うことで、図 71 のように改善される。

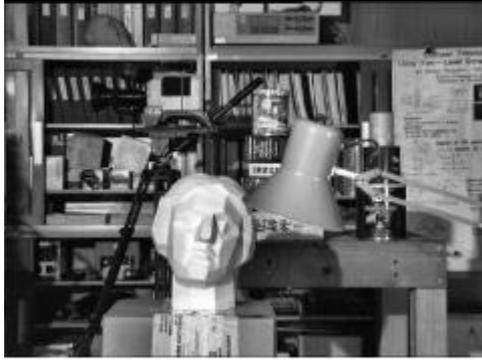


図 71 : CLAHE によるヒストグラム均等化

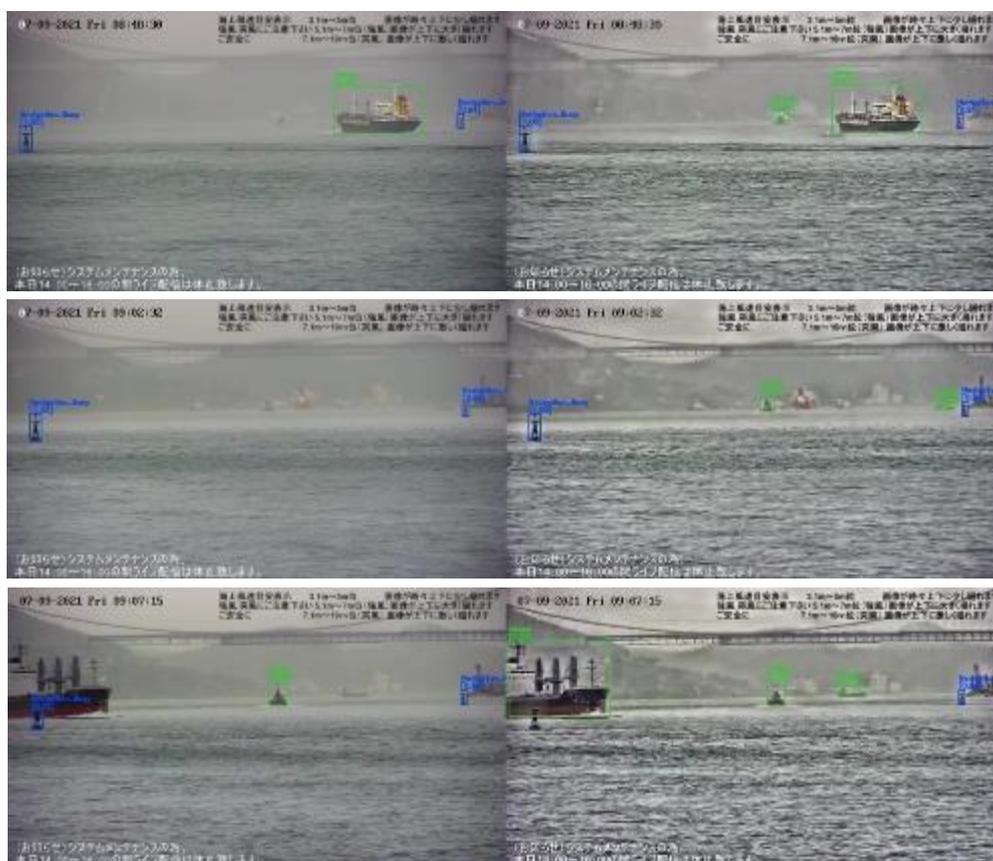
元画像にノイズが多くある場合、小さなタイルでヒストグラム均等化処理を行うとそのタイル内でノイズに合わせたヒストグラム平坦化処理が行われ、その結果、ノイズが増幅されてしまうことになってしまう。このノイズの増幅を低減させるためコントラストの制限を設定し、画素の出現頻度がその制限値を超えるような場合は他の画素に均等に分配してヒストグラム平坦化処理を行うようにする。CLAHE ではこのコントラストの制限設定を行うパラメータとタイルの大きさを設定するパラメータの 2 種類が存在する。

- コントラストクリップの制限
- グリッドサイズ

次に、海上を映した画像を使ってこれら 2 つのパラメータの最適な値を検討した。

### 3.1.6.4 視認性向上と評価

CLAHE による視認性向上の効果を確認するため、現在所有している AI の学習モデルを利用して物体認識の精度に効果が得られるか検証してみた。



オリジナル映像での検出

霧除去した後の検出

図 72 : CLAHEによる霧除去処理の効果

図 72 の左側の画像は霧除去処理を行わずに物体認識した画像で、右側の画像が霧除去後の物体認識の結果となる。明らかに遠くの船が検出しやすくなっており、物体検出できていなかったものが検出できるようになっている。この方法で、CLAHE における最適なコントラスト制限設定のパラメータを調査するため、船舶の総検出数 (Total bbox for vessel) と AI における信頼性スコアの平均値 (Average Confidence) を比較し、表 13 の結果となった。

表 13 : CLAHE によるコントラスト制限設定の効果

		Total bbox for vessel	Average Confidence
Original (Foggy)		994	0.7723
CLAHE (Defog)	Clip	Grid	
	2	30	1138
	3	30	1153
	5	30	1098
	3	16	1094
	3	50	1092

Clip: コントラストクリップの制限値

Grid: グリッドサイズ

表 13 の結果が示すように霧の映像に CLAHE を適用することで大幅に検出できる数が増加することが分かる。また、霧除去処理の効果としては、信頼性スコアよりも検出できた数の方が優先されるため、コントラスト制限設定のパラメータとしては、Clip=3, Grid=30 の組み合わせが最適である結果が得られた。

### 3.2 2022 年度の目標達成状況

#### 3.2.1 サンプルデータの収集実績（夜間）

目標	実績	
5 万点	収集画像数	7 万 2 千枚
	収集データ数	17 万 9 千点

学習用データの収集目標 5 万点に対し、17 万 9 千点分の学習データを収集できたため、目標を大きく上回ることができた。

#### 3.2.2 サンプルデータの前処理実績（夜間）

目標	実績	
5 万点	アノテーション数	9 万 1 千 6 百点

アノテーション専門業者と協力して、9 万 1 千 6 百点のアノテーション作業を実施した。

#### 3.2.3 AI の学習データの構築実績（夜間）

目標	実績	
5 万点	学習データ数	9 万 1 千 6 百点

サンプル画像の前処理で実施したアノテーションデータを全て利用して 9 万 1 千 6 百点の学習データを構築した。実証試験に関しては試験を実施するスケジュールの問題から、4 万 1 千 5 百点のデータを利用して実施した。

#### 3.2.4 実証試験の実績（夜間）

評価項目	目標	実績
夜間の物体認識距離	1, 000m 以上	10km
夜間における 1, 000m 以下での物体認識率	90%以上	92%

夜間の物体認識距離については最長 10km での認識ができたが、物体認識率 90% 以上の結果を考慮すると、最長で 5km となる。1, 000m 以下での認識率についても 92%の認識率を得ることができたため目標は達成した。

### 3.3 2022年度の実施内容の概要

#### 3.3.1 サンプル画像の収集（夜間）

AI に学習させるためのデータセットに用いるサンプル画像を、「阪九フェリー株式会社：いずみ」に録画システムを搭載してサンプル画像を収集した。夜間での画像を精度よく捉えるため、最適な可視光カメラのパラメータを検証し決定した。サンプル画像の収集は5万点を目標としたが、17万9千点を収集することができた。

#### 3.3.2 サンプル画像の前処理（夜間）

収集したサンプル画像をもとにAI に学習させるための前処理（アノテーション作業）を行った。収集したサンプル画像は動画データであるため、フレームに分割して静止画データへ変換したのちに前処理を実施した。前処理は専門業者へ依頼し、専門業者と実施者とでデータを確認し合いながら9万1千6百点のAI 学習データを構築した。

#### 3.3.3 AI による学習（夜間）

サンプル画像の前処理で作成したAI 学習データ全てを学習させた。学習データのクラス分けは infoceanus command の製品として認識させたいカテゴリを決定し、表3に示す8種類とした。

#### 3.3.4 学習結果の実証（夜間）

3.1.3項で作成したAI 学習データを実施者の製品 infoceanus command へ組み込み、サンプル画像の収集で利用した船舶と同じ「阪九フェリー株式会社：いずみ」にインストールして実証試験を実施した。実証試験は2022年12月および2023年1月の2回で実施したが、AI 学習データ作成の進捗もあり、2022年12月の時点はAI 学習データ数は1万6千点、2023年1月の時点では4万1千5百点の学習データで実証試験を実施した。実証試験の結果として、1km 先の物体検知については最長10km 先まで検知でき、1km 以下の認識率90%に関しては92%の認識率を得ることができ目標を達成できた。実証試験において距離の計測については、AIS データを記録することで、対象となる船舶と自船の座標をもとに計算して算出した。

### 3.3.5 製品への反映（夜間）

製品への反映はAI学習データの構築ごとに実施している。昼用の学習データと夜用の学習データは当初、infoceanus command のソフトウェア内で切り替えて利用していたが、現在はこれらの学習データを組み合わせた学習データを構築し、切り替え作業なしに自動的に昼夜利用できる仕組みとした。この学習データおよび夜間用のカメラ特性のパラメータを製品へ組み込むためのインターフェースを開発し、遠隔地からクラウドを利用してインストールできるようにした。

### 3.3.6 視界制限下の検討と検証（雨天・霧）

雨天や霧など外乱の影響による視認性の低下は画像認識処理の精度に影響する。今回視認性を高める画像処理のアルゴリズムについて調査し、その効果について検証を行った。調査したアルゴリズムは3種類あり、その性能の効果および製品へ組み込むための実現性について比較し、CLAHE アルゴリズムを利用していくことを決定した。

## 4. 2023 年度の実施報告

### 4.1 2023 年度の実施内容

#### 4.1.1 サンプル画像の収集（雨天・霧）

雨天や霧などによる視界制限下での物体認識性能を向上させるため、視界制限下の画像を AI に学習させる教師データが必要となる。この視界制限下の画像を収集するにあたっては、悪天候の時を狙ってピンポイントで収集することは非常に困難であるため、画像の収集方法は可視光カメラを用いて常時録画撮影を行い、その収集した映像の中から雨天や霧による視界制限下の映像を抽出することにした。多少、抽出作業に手間がかかってしまいが短い期間で視界制限下の映像を多く集めるためには、この方法が最も効率的であると考え実施した。

昼間のサンプル画像の収集は 4.1.1.1 項に示す関門海峡沿いに開設した「評価・実証 LAB」から可視光カメラを関門海峡に向けて録画撮影し、夜間のサンプル画像の収集は、4.1.1.2 項に示す夜間を航行する船舶「いずみ」に設置している可視光カメラで録画撮影を行った。

「評価・実証 LAB」は自社で開発した CV 技術の評価及び検証を行うフィールドとして、関門海峡の東側に開設した自社管理の施設であり、関門海峡を通過する年間 6 万隻程度といわれる船舶の交通量を活かして画像データの収集、AI モデルの検証を行っている。

##### 4.1.1.1 評価・実証 LAB でのサンプル画像収集

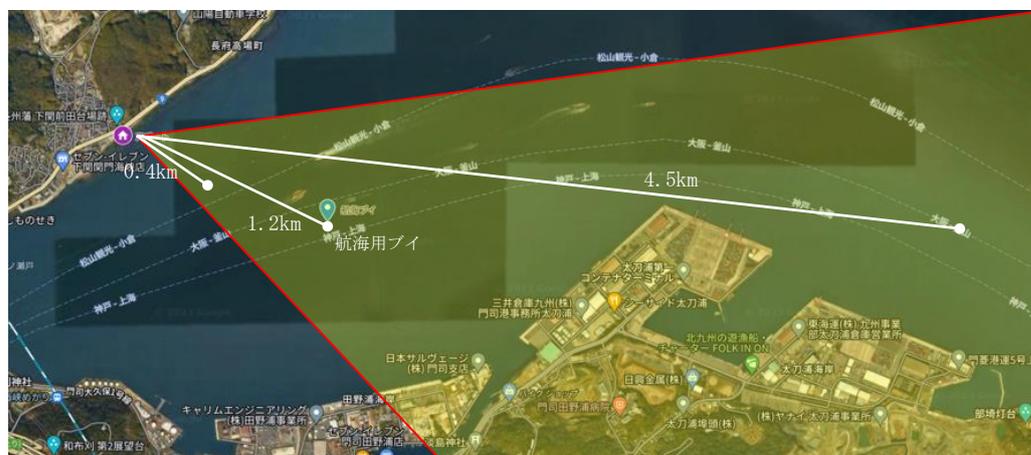


図 73：評価・実証 LAB からの撮影範囲（※1）

評価・実証 LAB には実施者の製品 infoceanus command の実証試験を行うための機材を既に設置している。この機材を利用して評価・実証 LAB から関門海峡へ向けた可視光カメラで撮影を行い、そのデータを録画してサンプル画像を収集することにした。

撮影範囲は図 73（※1:出典）に示す範囲となり、瀬戸内海と関門海峡を出入りする船舶が映せる範囲となる。可視光カメラから航路を航行する船舶までの撮影距離は、最長で約 4.5km、最短で約 400m となる。また、撮影範囲内に映る

航海用ブイまでの距離がおよそ 1.2km となっているため、その近くを通る船舶までの距離の目安にすることができる。

評価・実証 LAB には図 74 に示す構成で infoceanus command の機材を設置している。撮影には可視光カメラ 3 台を利用し、可視光カメラからの映像はエッジサーバー内のハードディスクに記録するようにした。エッジサーバーには物体を認識するソフトウェア以外に可視光カメラからの映像を録画する機能を備えているので、この機能を利用して映像を常時録画した。評価・実証 LAB 内の機材の様子は図 75 に示す。

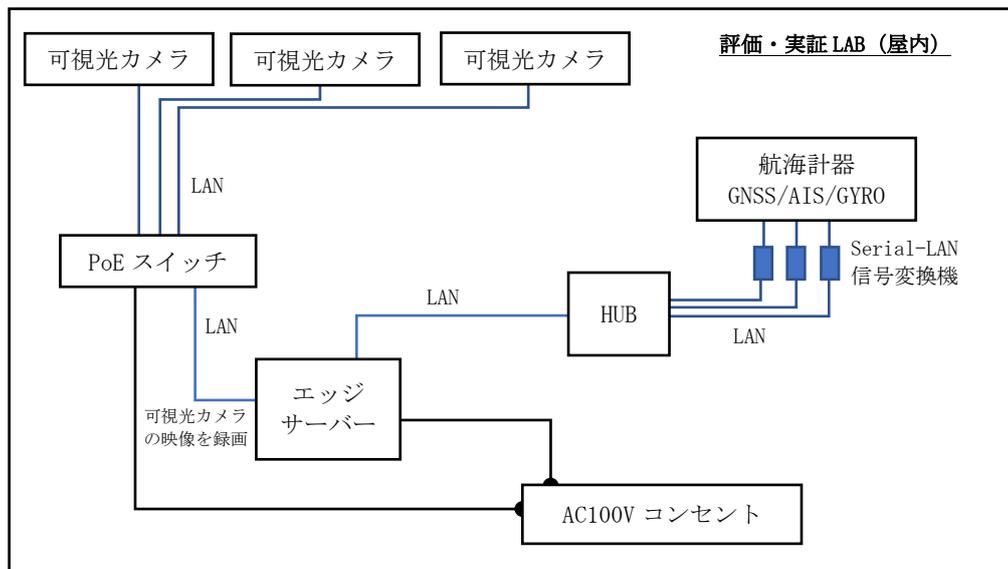


図 74：評価・実証 LAB の infoceanus command の機器構成



図 75：評価・実証 LAB に設置した試験機材

#### 4.1.1.2 「いずみ」でのサンプル画像収集

「いずみ」には、既に infoceanus command を搭載している。4.1.1.1 項と同様にエッジサーバーに搭載しているソフトウェアの録画機能を利用し、3.1.1.2 項の図 5 (※1:出典) に示す「いずみ」の航路上の映像を収集した。

「いずみ」での機器構成を図 76 に示す。可視光カメラ 3 台はコンパスデッキ (屋外) に設置されており、前方を映す中央カメラ、左舷側を映す左舷カメラ、右舷側を映す右舷カメラの構成で図 77 に示すカメラハウジングに搭載している。(このカメラハウジングについては、3.1.5.2 項の製品用カメラハウジングと同じものであり、仕様については表 10 を参照のこと)

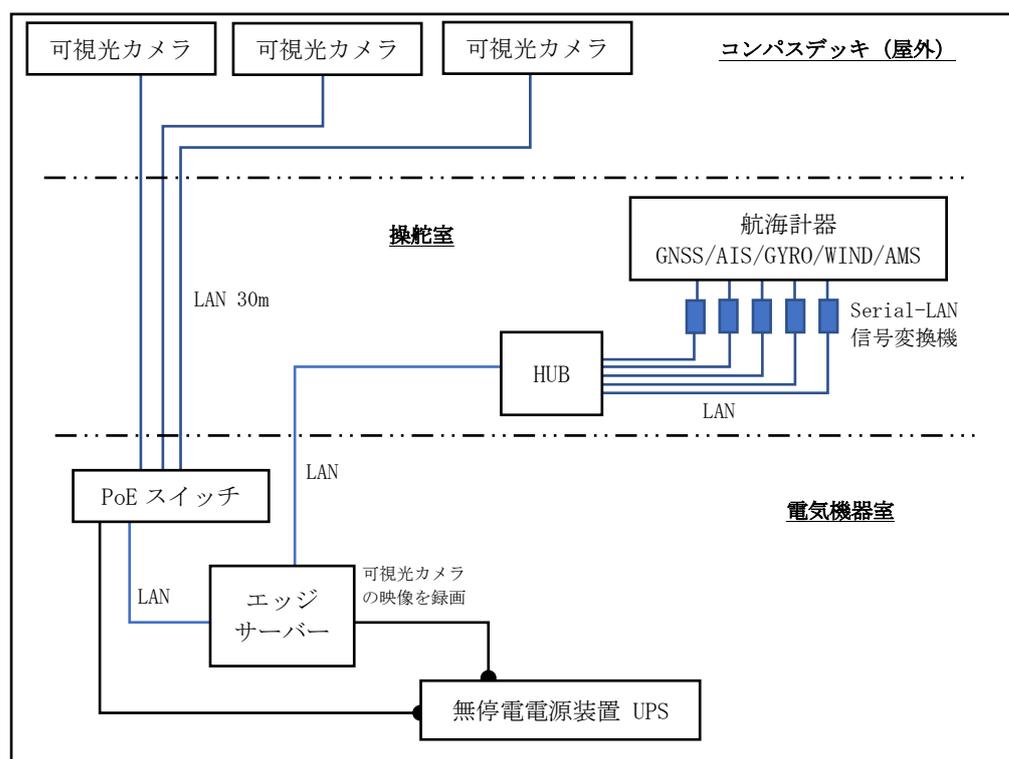


図 76: 「いずみ」の infoceanus command 機器構成



図 77: 「いずみ」に搭載している可視光カメラ

#### 4.1.1.3 視界制限下における最適なパラメータの調査

視界制限下における可視光カメラの映像をより鮮明に映し出すため可視光カメラの最適なパラメータ調整を行なった。2022年度の事業内容において夜間におけるパラメータ調査を実施し、3.1.1.3項の表1に示す5段階でのビット深度レンジを決定したが、運用レベルではこの5段階の調整では調整幅が大き過ぎ、微妙な明るさの違いによって映像を鮮明に映し出すことができないケースがあることが分かった。このため、今回はこのパラメータの調整方法を変更した。この調整方法は、図78に示すように可視光カメラから取り込んだ映像の状態(明るさ等)を数値化し、都度最適なパラメータ(ビット深度レンジ)を決定して映像を調整する仕組みとなる。調整後の映像は定めた基準の明るさの範囲になるまで繰り返し調整し続け、夜間や霧などの視界制限のある映像の状態によって最適なパラメータを都度自動で設定できるようにした。

ビット深度レンジ値の設定は可視光カメラ側での設定ではなくソフトウェア側での設定となる。このため、調整後の映像を録画するには可視光カメラから出力した映像を録画するのではなく、一度エッジサーバーに取り込んで調整した映像を出力して録画するようにしている。

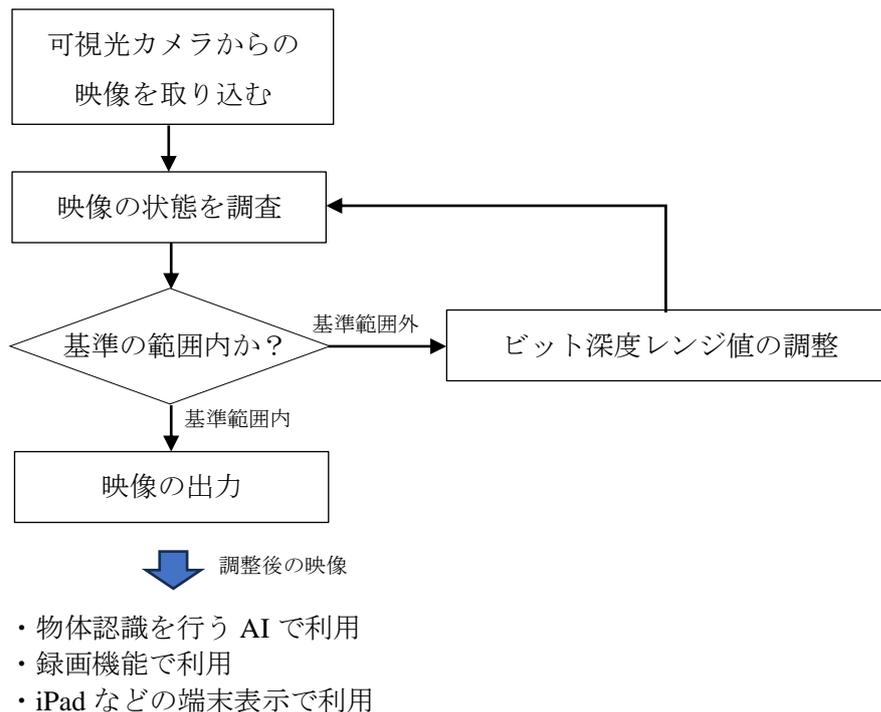


図 78 : 映像調整機能のフロー

#### 4.1.1.4 サンプル画像の収集実績

サンプル画像は2023年4月から6月の3ヶ月間で収集し、収集したデータの形式は動画ファイル（mp4ファイル）として記録した。なお、収集した動画ファイルの中から視界制限のある映像のみを抜き出す作業は人による手作業で実施した。

##### - 収集目標

AI学習のため視界制限下の学習データを5万点収集する。実運用可能な精度である90%を目標としてAIに学習させるためのデータセットに用いるサンプル画像約5万点分を、実際の船舶に搭載したカメラ及び陸上より収集する。

##### - 収集方法

評価・実証LABに設置したinfoceanus commandの録画機能を利用し、昼間における視界制限下の学習データを収集した。また、阪九フェリー株式会社の船舶「いずみ」に搭載したinfoceanus commandの録画機能を利用し、夜間における視界制限下の学習データを収集した。また、後から映像内に映る船舶の距離（1,000m付近）を判断できるようにAISのデータも同時に記録した。物体認識の目標として1,000m以上の物体を認識させるため、学習データとなる画像はできるだけ1,000m付近の物体を選べるようにした。

##### - 収集実績

- ① 収集した動画ファイルからAI学習に利用できる視界制限下の映像を選別した。
- ② AI学習させるための前処理（アノテーション作業）を行うため、動画を静止画（jpegファイル）に変換した。前処理に利用できる画像数は3万9千枚となった。
- ③ 3万9千枚の画像データからAI学習用のデータ（5万7千点）を収集した。

サンプル画像の収集目標である5万点の学習データに対し、5万7千点（AIによる計算）の学習データを収集できたことから、サンプル画像の収集目標を達成することができた。収集したサンプル画像の一部を図79に示す。

※ AIによる計算とは、船舶やブイなどの今までに学習したデータを利用し、AIによって今回学習できるデータ数を自動計算させたものとなる。

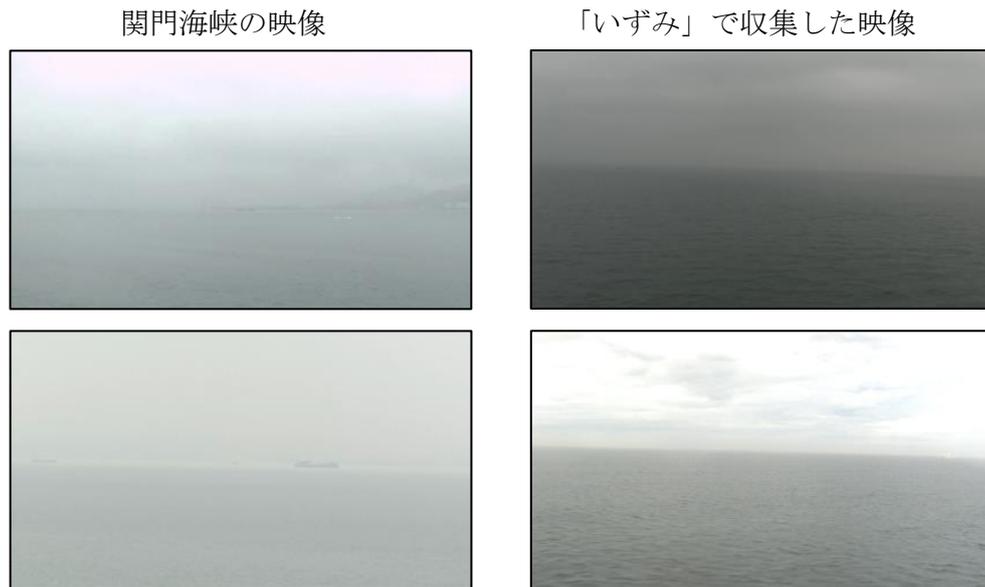


図 79：関門海峡および「いずみ」の航路で収集した霧の画像

#### 4.1.2 サンプル画像の前処理（雨天・霧）

4.1.1 項で収集したサンプル画像の学習データ 5 万 7 千点のうち、5 万 8 千 9 百 16 点のアノテーション作業を実施した。実績としておよそ 2 千点増えているのは、AI で計算したアノテーション数に取りこぼしがあったため、手作業により追加で約 2 千点のアノテーション作業を実施したことによるものとなる。アノテーション作業は画像に写っている物体への枠付け（マーキング）と、その物体のラベル付け（表 14 に示す 7 種類のクラス分け）を行った。2022 年度の事業ではこのクラス分けは 8 種類であったが 2023 年度の事業では 7 種類としている。これは Fishing\_Boat クラスと Small\_Vessel クラスを 1 つの Boat クラスに統合している内容だが、Small\_Vessel というカテゴリの表記は遠くの大きな船舶が小さく映っていても小さな船 (Small\_Vessel) となり混乱を引き起こす可能性があるため、小さな船舶は Boat として統一し分かりやすくした。また、学習データ量の少ない 2 つのクラス (Fishing\_Boat と Small\_Vessel) を 1 つにまとめて信頼性スコアを少しでも高くする目的もある。

表 14：アノテーション作業のクラス定義

クラス ID	クラス名	説明
0	Vessel	他のクラスに定義している旅客船、漁船、小型船を除く船舶
1	Fishing_Buoy	海上に浮かぶ漁業用のブイ
2	Navigation_Buoy	海上交通のための航海ブイ
3	Passenger_Vessel	旅客船
4	Boat	漁船、ボート、カヌー、ジェットスキーなどで利用される小型船
5	Human	人
6	Fishiers_Facility	漁業用の施設（養殖用の筏や網などの施設）

#### 4.1.2.1 サンプル画像の前処理の実績

収集したサンプル画像は動画データであるため、前処理を実施するにあたり動画データを静止画データ（jpeg フォーマット）に変換してアノテーション作業を実施した。アノテーションしたデータ数は5万8千9百16点で、その内訳は表 15 の通りとなる。

表 15：アノテーション作業の実績数

クラス ID	クラス名	データ数
0	Vessel	47,379
1	Fishing_Buoy	0
2	Navigation_Buoy	7,971
3	Passenger_Vessel	756
4	Boat	2,810
5	Human	0
6	Fishiers_Facility	0

計 58,916

アノテーション作業を行ったサンプル画像は視界制限下での画像であるため、Fishing\_Buoy などの小さな物体や、Fishiers\_Facility などの見えづらい物体を判断することはできず、表 15 の通り収集できなかったクラスのデータ数は0となっている。しかしながら、Vessel クラスおよび Navigation\_Buoy クラスの収集数が多くあることから、視界制限下の画像を学習することによって認識率が向上する効果があるかどうかの評価はできると考えた。

以下、図 80 に Vessel クラスのアノテーション例、図 81 に Navigation\_Buoy

クラスのアノテーション例を示す。このように薄らと映る物体の画像を学習することで視界制限下での認識率を向上させることができると考えた。



図 80 : Vessel クラス



図 81 : Navigation\_Buoy クラス

#### 4.1.3 AIによる学習（雨天・霧）

本項では 4.1.2 項のアノテーション作業で作成したデータを用いて、雨天・霧における視界制限下の学習モデルを構築し、その学習モデルの学習精度の確認、および霧のビデオ映像を用いて各学習モデルの認識精度の比較検証を行なった。学習モデルは以下の 3 種類を利用した。

- ・ 既存モデル  
2022 年度の事業で作成した晴天における昼と夜の画像を学習したモデル
- ・ 視界制限下モデル  
2023 年度に収集した雨天および霧の画像のみを学習したモデル
- ・ 統合モデル  
infoceanus command の製品へ組み込むためのモデルで既存モデルと視界制限下モデルを統合した学習モデル

これら 3 種類の学習モデルを利用して、収集したサンプル画像を学習することにより全体の認識精度が向上するかを以下の流れで検証した。

##### 1. 視界制限下モデルの評価

今回サンプル画像として収集した画像を学習することで、視界制限下の環境において認識精度が向上するかを既存モデルと比較して評価する。

##### 2. 統合モデルの評価

製品へ組み込むため既存モデルと視界制限下モデルを統合した統合モデルが視界制限下の環境において認識精度が向上するかを確認する。

#### 4.1.3.1 視界制限下モデルの評価

第 1 段階として既存モデルの学習精度と視界制限下モデルの学習精度がどのくらいの違いがあるかを評価した。学習精度は、評価の指標となる mAP (mean Average Precision) の値で表し、この値は 100% に近づくほど学習モデルの精度が良いという判断となる。

表 16 に既存モデルの学習精度の評価指標を示す。既存モデルの学習データ（昼と夜の学習データ）の 75% を学習用として利用し、25% を評価用のデータとして mAP 値を算出した。

表 16 : mAP 値による既存モデルの評価指標

クラス	既存モデルの mAP 値
Vessel	90.9%
Fishing_Buoy	22.1%
Navigation_Buoy	43.8%
Passenger_Vessel	89.8%
Boat	61.2%
Human	61.3%
Fishers_Facility	26.4%
(全体)	56.5%

既存モデルの学習精度は、Fishing\_Buoy、Navigation\_Buoy、および、Fishers\_Facility のクラスの評価指標が 50%を下回っており、他のクラスに比べてあまり良くない数値となっている。これは、これらのクラスの学習データ量が少ないことが原因と思われ、物体の外形がはっきりと映らない視界制限下の環境のもとでは、これらのクラスの映像は物体認識しにくくなることが予想される。

次に視界制限下モデルの評価指標を表 17 に示す。こちらは視界制限下モデルの学習データ（雨・霧）の 75%を学習用として利用し、25%を評価用のデータとして mAP 値を算出した。学習データの量は既存モデルに比べかなり少なくなるが、収集したクラスの評価指標は全て高い値の結果が得られた。

表 17 : mAP 値による視界制限下モデルの評価指標

クラス	視界制限下モデルの mAP 値
Vessel	93.3%
Fishing_Buoy	---
Navigation_Buoy	92.5%
Passenger_Vessel	98.7%
Boat	87.0%
Human	---
Fishers_Facility	---
(全体)	92.9%

第 2 段階では、実際にこれらの学習モデルを使って霧のビデオ映像をもとに認識精度の比較検証を行った。図 82 に既存モデルで認識させた画像と視界制限下モデルで認識させた画像の比較を示す。上段が既存モデルによる認識状況、下段が視界制限下モデルによる認識状況となる。



図 82 : 学習モデルによる認識画像の比較

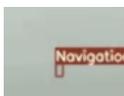
画像の左の船舶（タグボート）は可視光カメラからの距離がおよそ 2.0km の位置から 300m の位置までこちらに近づく方向で航行している。視界制限下の学習をしていない既存モデルでは船舶として判断する信頼性スコア (Average Confidence) の平均が 66% だったのに対し視界制限下モデルでは平均 82% と高く、より船舶として認識する確率が向上していることが分かった。このことにより視界制限下モデルでは、この船舶を既存モデルが認識し始める 45 秒前から認識できていた。

次に、画像右側の船舶（タンカー船）は可視光カメラからの距離がおよそ 800m から見えなくなるまでの距離 2.3km の位置を遠ざかる方向に航行している。こちらも既存モデルでは船舶として判断する信頼性スコアの平均が 74% だったのに対し、視界制限下モデルでは平均 88% と高くなっている。この船舶では既存モデルよりも視界制限下モデルの方が 3 秒長く認識し続けた。

画面中央の右側にある航海用ブイ（Navigation\_Buoy）は、可視光カメラからの距離がおよそ 1.2km に位置にあり非常に小さな画像となっている。既存モデルでは航海用ブイとして判断する信頼性スコアの平均が 27.9% だったのに対し、視界制限下モデルの平均は 54.5% と高くなっているが、物体の画像自体がかなり小さいため、タグボートやタンカー船と比べて信頼性スコアは高くない。しかしながら、この約 9 分間の霧のビデオ映像のうち、既存モデルではこの航海用ブイの検出回数は 14 回と殆ど検出できなかったのに対し、視界制限下モデルでは 4,110 回と非常に高い確率で検出できている。

表 18 に既存モデルと視界制限下モデルの認識結果の比較をまとめる。

表 18 : 既存モデルと視界制限下モデルの結果比較

対象船		項目	既存モデル	視界制限下モデル
タグボート (左の船舶)		信頼性スコア	65.7%	81.7%
		誤認識率	4.4%	0%
		連続認識率	97.2%	97.3%
タンカー船 (右の船舶)		信頼性スコア	74.1%	87.7%
		誤認識率	1.2%	0.03%
		連続認識率	99.4%	100%
航海用ブイ		信頼性スコア	27.9%	54.5%
		誤認識率	35.7%	1.7%
		連続認識率	2.3%	93.3%

視界制限下モデルは表 18 の比較表から見ても分かるように、すべての項目に対して既存モデルよりも精度が向上している。特に誤認識においては殆ど 0%に近い結果であり、また、左の船舶（タグボート）や航海用ブイのように小さな物体に対しての信頼性スコアが大きく向上している。この結果から視界制限下の画像を学習することで認識精度の向上が得られることが分かった。

- ※ 誤認識率とは物体の検出はしているが認識したクラスの種別を間違えて識別した確立を意味する。
- ※ 連続認識率とは物体の認識を開始した時間から認識を終了した時間までの間、1 秒間隔で認識し続ける確立を意味する。

infoceanus command の製品としての運用では、これら 2 つの学習モデル（既存モデルと視界制限下モデル）を天候の状況において切り分けて利用するには天候を判断するソフトウェアが別途必要となるため、2022 年度に実施した昼の学習データと夜の学習データを統合したように、今回は既存モデル（昼と夜）と視界制限下モデル（雨・霧）を組み合わせた統合モデルを作成して infoceanus command への組み込みを行うことにした。

これらの学習モデルを組み合わせることによって、各クラスの学習データの特徴が発散し認識の精度が低下してしまう懸念が考えられたが、現状の既存モデルよりも精度が向上できるか、もしくは低下してしまうかは実証試験を実施して確認することにした。

#### 4.1.3.2 統合モデルの評価

既存モデルと視界制限下モデルを組み合わせた統合モデルを作成し、その mAP 値を評価した。4.1.3.1 項では各学習モデルの学習データ数の 25%を評価用データとして mAP 値を算出したが、今回は全学習データ（昼、夜、雨・霧）の 25%を評価用データとして各々の学習モデルの mAP 値を算出した。これにより各学習モデルの学習精度を比較することができる。

各学習モデルにおける学習精度の比較結果を表 19 に示す。今回の試験用データには夜の試験データも含まれているため、視界制限下モデルの評価指標がかなり低くなった。確認したいのは統合モデル評価指標だが、全てのクラスの評価指標は既存モデルに比べて高くなっているため、視界制限下の学習データを組み込むことにより認識精度の向上が望める結果となった。

表 19：mAP 値による各学習モデルの評価指標

クラス	既存モデル	視界制限下モデル	統合モデル
Vessel	82.3%	46.7%	93.1%
Fishing_Buoy	15.9%	0%	28.9%
Navigation_Buoy	39.9%	40.4%	73.8%
Passenger_Vessel	82.4%	13.0%	95.3%
Boat	56.9%	8.4%	77.1%
Human	56.7%	0%	69.7%
Fishers_Facility	36.4%	0%	45.7%
(全体)	52.9%	15.5%	69.1%

では実際に、既存モデルと視界制限下モデルの比較で利用した視界制限下のビデオ映像をもとに統合モデルでの認識精度を検証した。その結果を表 20 に示す。視界制限下の環境では、統合モデルは視界制限下モデルよりも認識精度が若干落ちてしまったが、既存モデルよりも認識精度は高くなる結果が得られた。タンカー船の連続認識率の値が既存モデルよりも低くなっているが、統合モデルでの認識時間は既存モデルの認識時間よりも長く、より遠くの船舶を認識できている。また、誤認識も少なくなっていることから、認識の精度は高くなっていると言える。

表 20 : 各学習モデルでの認識精度の比較

対象船	項目	既存モデル	視界制限下モデル	統合モデル
タグボート	信頼性スコア	65.7%	81.7%	80.4%
	誤認識率	4.4%	0%	1.2%
	連続認識率	96.6%	97.7%	97.3%
タンカー船	信頼性スコア	74.1%	87.7%	88.2%
	誤認識率	1.2%	0.03%	0.2%
	連続認識率	99.9%	100%	97.7%
航海用ブイ	信頼性スコア	27.9%	54.5%	50.1%
	誤認識率	35.7%	1.7%	0.8%
	連続認識率	2.3%	93.3%	87.6%

タグボートの認識距離は 2km から 300m、タンカー船の認識距離は 800m から 2.3km、これらの船舶の連続認識率が 97.3%と 97.7%の結果であったことから、目標である視界制限下における 1,000m 以上での物体認識、および 1,000m 以内での認識率 90%以上を達成することができた。

ちなみに、1.2km 先の航海用ブイの連続認識率は 87.6%の結果であったが、認識の開始から終了までの時間の中、船舶と航海用ブイが重なって約 15 秒間航海用ブイが見えなくなった時間が含まれている。この時間を省いて計算しなおすと、統合モデルにおける航海用ブイの連続認識率は 90.4%と 90%を超える結果となった。

#### 4.1.4 学習結果の実証（雨天・霧）

##### 4.1.4.1 評価・実証 LAB での実証結果

AI 学習した統合モデルを infoceanus command に組み込み、評価・実証 LAB で実証試験を実施した。図 83 に既存モデルで認識させた画像と統合モデルで認識させた画像の比較を示す。下段が既存モデルによる認識状況、上段が統合モデルによる認識状況となる。

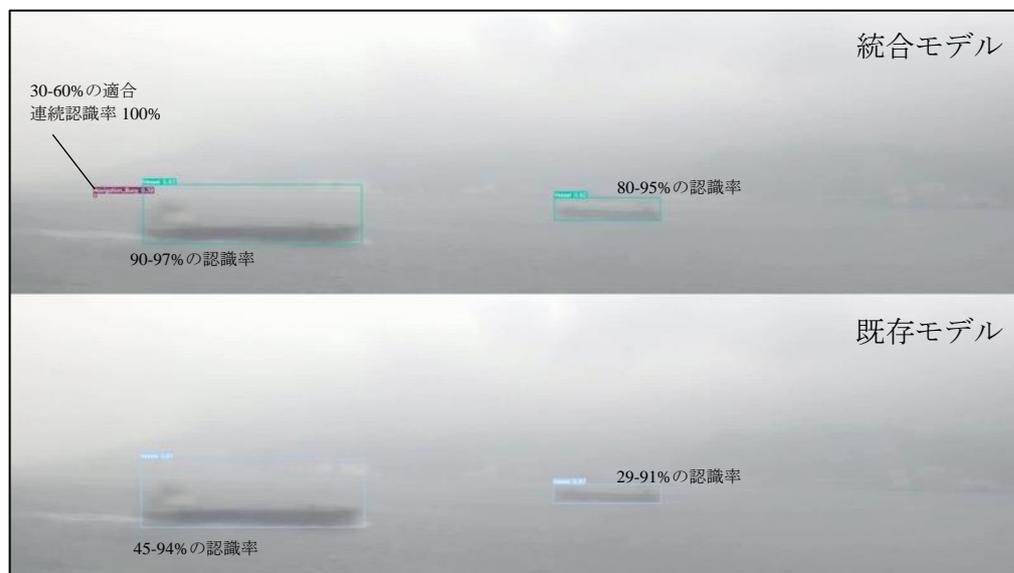


図 83：船舶および航海用ブイの認識率の比較

画像の左手前の船舶はカメラからの距離がおよそ 400m から 300m の位置を右向きに航行している。視界制限下の画像を学習していない既存モデルでは船舶として認識する信頼性スコアの値がおよそ 45%から 94%の間で大きくふらつきがあった。しかし、統合モデルでは常に 90%以上で安定した認識ができている。また、画像中央奥側の船舶はカメラからの距離がおよそ 600m から 800m の位置を左向きに航行している。こちらも既存モデルでは船舶としての信頼性スコアがおよそ 29%から 91%の間でふらつきがあったが、統合モデルでは 80%から 95%と高い認識結果が得られた。この結果の比較を表 21 に示す。

表 21：既存モデルと統合モデルの認識率の比較

対象船	項目	既存モデル	統合モデル
左手前の船舶 距離 400m～300m	信頼性スコア（範囲）	45～94%	90～97%
	信頼性スコア（平均）	84%	94%
	連続認識率	100%	100%
画像中央奥の船舶 距離 600m～800m	信頼性スコア（範囲）	29～91%	80～95%
	信頼性スコア（平均）	85%	92%
	連続認識率	100%	100%

航海用ブイ (Navigation\_Buoy) の認識状況の比較を表 22 に示す。画面左側にある航海用ブイは、可視光カメラからの距離がおよそ 1.2km に位置にあり非常に小さな画像となっている。既存モデルではこの航海用ブイの認識は 4 分 40 秒の映像のうち 1 回のみを検出だったが、統合モデルでは 2,738 回 (4 分 32 秒) の検出結果だった。信頼性スコアが 25%から 53%と若干低い値ではあるものの、この映像に対して航海用ブイを 1 秒間隔で連続に認識する確率は 97% と非常に良い結果となった。

表 22 : 航海用ブイの認識率の比較

対象物	項目	既存モデル	統合モデル
航海用ブイ 距離 1.2km	信頼性スコア (範囲)	28%	25~53%
	信頼性スコア (平均)	28%	39%
	連続認識率	0.4%	97%

前頁の船舶は比較的大きな物体であり、距離も 1km 未満であることから連続検出率は既存モデルも統合モデルも共に 100%で比較することができなかったため、次に図 84 の画面右側に現れる小型船 (Boat) について比較してみる。この小型船はおよそ 1km から 1.4km の距離を左向きに航行しており、その認識結果の比較を表 23 に示す。距離も遠く且つ、小さな物体であることから信頼性スコアの値も低くなっている状況だが、信頼性スコアの値が既存モデルでは平均 35%、統合モデルでは平均 56%と認識率が向上している結果が得られた。連続認識率についても 45%から 63%と物体を認識し続ける確率も向上している。



図 84 : 小型船の認識率の比較

表 23：小型船の認識率の比較

対象物	項目	既存モデル	統合モデル
小型船 距離 1km～1.4km	信頼性スコア（範囲）	25～58%	25～76%
	信頼性スコア（平均）	35%	56%
	連続認識率	45%	63%

図 85 に小型船を識別した時の状況、表 24 に識別結果の比較を示す。既存モデルでは小型船の認識クラスが時折 Boat から Vessel に変わり、認識した場所によって変化している結果となったが、統合モデルでは認識クラスは常に Boat となり、船舶を識別する精度も向上していることが確認できた。

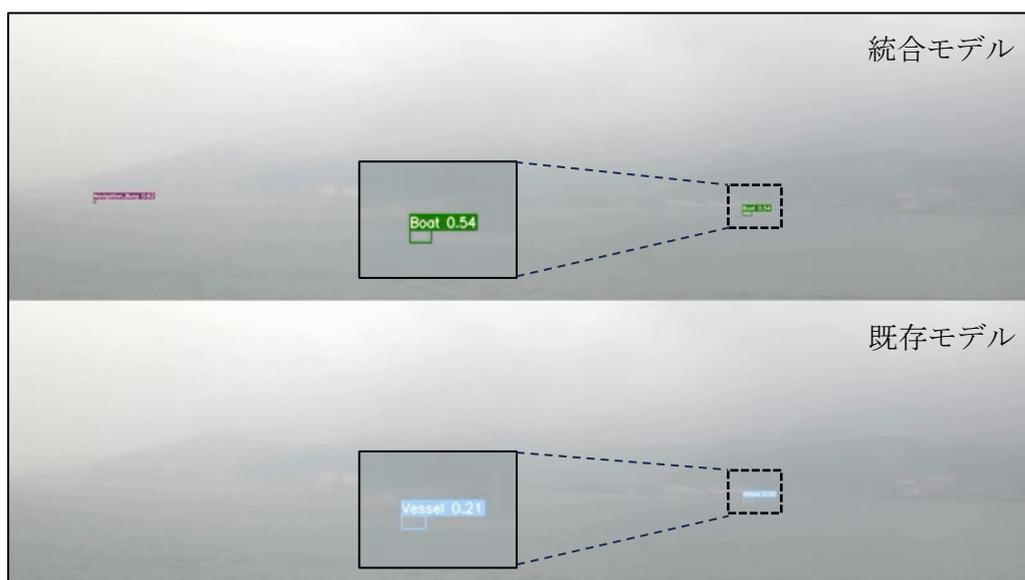


図 85：学習データの認識効果

表 24：小型船を識別した種類と数の比較

対象物	識別したクラス	既存モデル	統合モデル
小型船 距離 1km～1.4km	小型船 (Boat)	300 回	691 回
	船舶 (Vessel)	60 回	0 回

識別回数： 360 回 691 回

#### 4.1.4.2 霧除去アルゴリズムの検証

AI の学習による視界制限下の物体認識精度向上以外に、視界制限のある画像をより鮮明に映し出すための霧除去アルゴリズムを 2022 年度の事業において検討した。3.1.6 項に記載した「視界制限下の検討と検証（雨天・霧）」の検証結果として霧除去アルゴリズム CLAHE を選定した。CLAHE は他の霧除去アルゴリズムよりも霧を除去する効果が若干落ちてしまうが、このアルゴリズムの処理速度性能から infoceanus command へ組み込むアルゴリズムとして最も適しているものと決定した。この霧除去アルゴリズムは既に infoceanus command へ組み込んでいるため、次に、この霧除去アルゴリズムの効果がどの程度あるかを比較検証した。

この比較検証において利用した AI 学習モデルは「統合モデル」を利用した。この学習モデルは既に霧の学習データを組み込んだものであるが、霧除去アルゴリズムを利用することで更にどの程度認識効果が向上するかを確認した。

図 86 に霧除去を行っていない画像、図 87 に霧除去を行った画像を示す。ここでは比較的大きな物体である船舶を対象に比較した。



図 86：霧除去をしていない船舶の画像



図 87：霧除去を行った船舶の画像

船舶の比較結果を表 25 に示す。対象物が大きく霧除去前の画像でも連続認識率 100%の画像であったため、霧除去による効果はあまり見られなかった。画像中央奥の船舶の信頼性スコアが 2%向上していることから、小さな物体において効果が見られる可能性がある。

表 25：霧除去における船舶を認識した際の性能比較

対象船	項目	霧除去なし	霧除去あり
左手前の船舶 距離 400m～300m	信頼性スコア（平均）	94%	94%
	連続認識率	100%	100%
画像中央奥の船舶 距離 600m～800m	信頼性スコア（平均）	92%	94%
	連続認識率	100%	100%

次に小さな対象物である小型船について比較した。図 88 に霧除去をしていない画像、図 89 に霧除去をした画像を示す。小型船を拡大した画像を付けてはいるが、見た目では薄らとしており物体の輪郭がはっきりしていない。

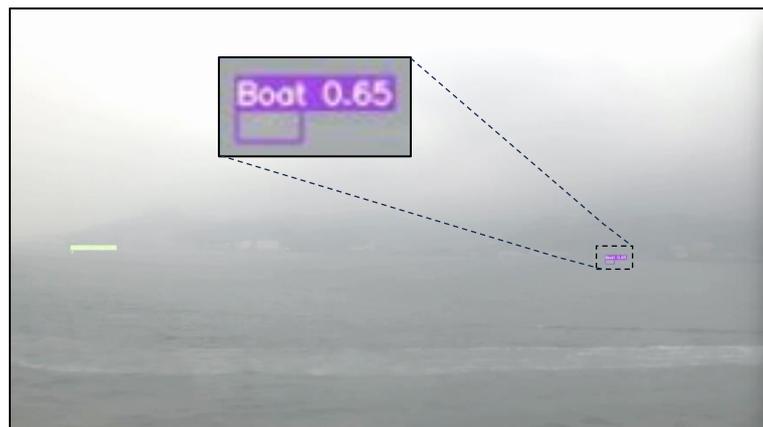


図 88：霧除去をしていない小型船の画像



図 89：霧除去を行った小型船の画像

小型船の比較結果を表 26 に示す。信頼性スコアと連続認識率は共に性能は向上したが、その効果は目立って大きいものではなかった。この結果の詳細としては、小型船を検出した時間が 2 分 11 秒から 2 分 19 秒と霧除去を行ったものが 8 秒長く検出できたこと、および検出回数が 691 回から 741 回と 50 回増えた内容となっている。

表 26：霧除去における小型船を認識した際の性能比較

対象船	項目	霧除去なし	霧除去あり
小型船 距離 1km～1.4km	信頼性スコア (平均)	56%	61%
	連続認識率	63%	66%

この霧除去の機能はオプションとして infoceanus command に搭載しており、霧除去を行うかどうかの判断は利用するユーザーにて選べるようにしている。

#### 4.1.4.3 「いずみ」での実証結果

4.1.4.1 項の評価・実証 LAB での実証試験では可視光カメラは陸上からの定点撮影となるため、移動する船舶「いずみ」に搭載した可視光カメラでの実証試験を別途実施した。この実証試験では航行中の船舶で行うため、対象となる船舶が遠距離に存在し、遠距離での認識精度を確認することができる。また、「いずみ」の通常運行は夜間を航行してしまうため、この実証試験では、図 90（※1:出典）に示すように「いずみ」がドック工事を終了してから新門司港へ帰港する昼間の移動ルート（広島県の呉港から福岡県の新門司港）で実証試験を実施した。

試験開始日時： 2024 年 1 月 24 日 09:45

試験終了日時： 2024 年 1 月 24 日 19:30



図 90 : 「いずみ」での実証試験ルート（※1）

実証試験を行なった対象船舶および航海用ブイを表 27 に示す。

表 27 : 実証試験で検証した船舶のリスト

船名	種別	大きさ
INTRA BHUM	Container	全長 144m / 全幅 23m
FORTUNE SAILING	General Cargo	全長 76m / 全幅 12m
EISEKI	Tanker	全長 70m / 全幅 12m
ASIATIC REUNION	Container	全長 143m / 全幅 23m
周防灘航路第 3 号灯浮標	航海用ブイ	不明
COSCO KIKU	Container	全長 138m / 全幅 22m
FERRY DOUGO	Passenger	全長 191m / 全幅 27m

① 実証試験結果 1

船名	INTRA BHUM
船種	Container
大きさ	全長 144m / 全幅 23m
計測時間	12:50:00 ~ 12:54:27 (4分 27秒)
航路	左舷側をいずみと同一進行方向に進む船舶
天候	曇り、視野良好
可視光カメラ	左舷の可視光カメラ
認識距離	最長 2,383m / 最短 1,195m
信頼性スコア	95% ~ 98% (平均 96%)
連続認識率	100%



図 91 : 対象物の画像

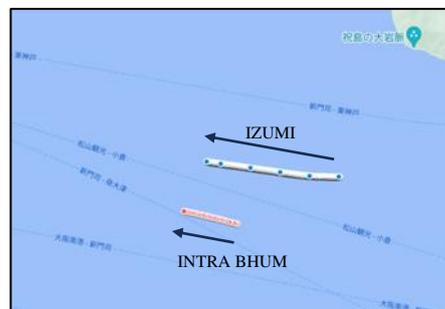


図 92 : 認識時の航路 (※1)

図 91 は対象物の画像、図 92 (※1:出典) は対象船を認識した時の航路となる。「いずみ」は対象船を右側から追い越す航路となり、2,383mの距離から1,195mの距離まで近づく形となる。図 93 に最長距離2,383mでの認識画像を示す。この時点で既に信頼性スコアは96%と良い認識率となっている。



図 93 : 最長距離での認識画像

図 94 に最短距離 1,195m での認識画像を示す。この時の天候は曇りであったが視界が非常に良いこともあり、船舶の形がはっきりとしていることから信頼性スコアおよび連続認識率共に良い結果が得られた。



図 94 : 最短距離での認識画像

② 実証試験結果 2

船名	FORTUNE SAILING
船種	General Cargo
大きさ	全長 76m / 全幅 12m
計測時間	12:52:10 ~ 12:59:59 (7分49秒)
航路	前方をいずみと同一進行方向に進む船舶
天候	曇り、視野良好
可視光カメラ	中央の可視光カメラ
認識距離	最長 5,425m / 最短 2,185m
信頼性スコア	25% ~ 91% (平均 65%)
連続認識率	82%



図 95 : 対象物の画像

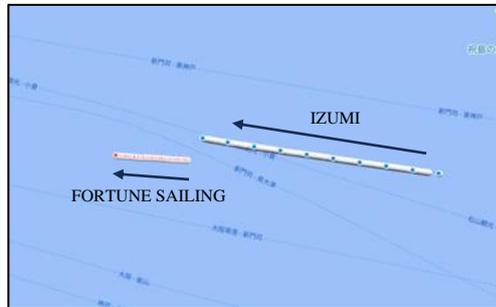


図 96 : 認識時の航路 (※1)

図 95 は対象物の画像、図 96 (※1:出典) は対象船を認識した時の航路となる。「いずみ」の前方を同一方向に進む対象船に近づく航路となり、本試験では 5,425m の距離から 2,185m の距離まで近づく形となる。対象船の大きさが小さいこと、また認識距離が遠いこともあり、図 97 に示す最長距離での認識画像では船舶を認識した大きさは 5 ピクセル × 5 ピクセルと非常に小さく信頼性スコアも 26%と低い値となっている。



図 97 : 最長距離での認識画像

距離 4km 付近に近づくまでは、対象物のピクセル数が非常に小さく、図 98 に示すように認識クラスが時折 Navigation\_Buoy に変わり、10%の確率で誤認識している。この誤認識時のピクセル数の最大は 8 ピクセル×9 ピクセルで 10 ピクセルよりも小さな認識の際に多く発生していることがわかった。



図 98 : 誤認識の画像

距離 4km 以下では連続認識率は 100%となり、誤認識もなくなっている。ピクセル数も幅もしくは高さのピクセルのどちらかが 10 ピクセル以上となっていた。図 99 は最短距離 2, 185m での認識画像でこの時のピクセル数は 32 ピクセル×14 ピクセルと大きく、信頼性スコアも 90%と高い値となっている。

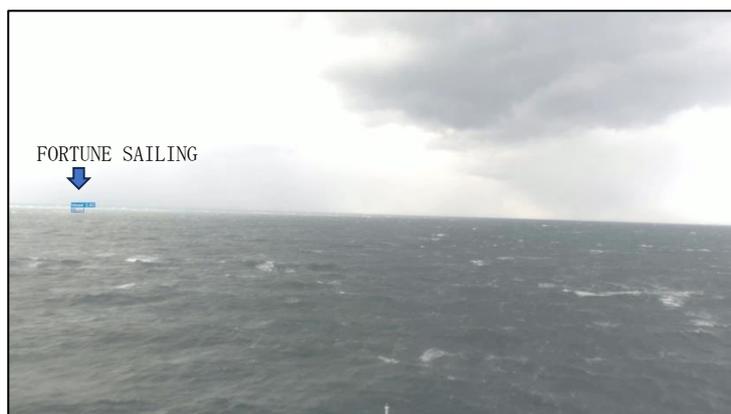


図 99 : 最短距離での認識画像

③ 実証試験結果 3

船名	EISEKI
船種	Tanker
大きさ	全長 70m / 全幅 12m
計測時間	12:51:26 ~ 12:59:59 (8分 33秒)
航路	前方をいずみと同一進行方向に進む船舶
天候	曇り、視野良好
可視光カメラ	中央の可視光カメラ
認識距離	最長 6,539m / 最短 3,931m
信頼性スコア	25% ~ 77% (平均 38%)
連続認識率	28%

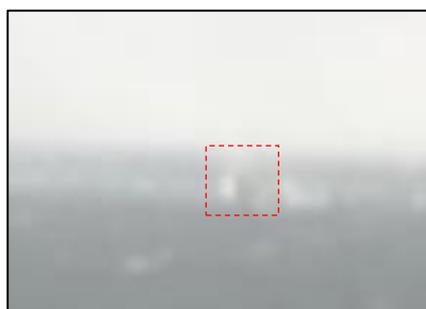


図 100 : 対象物の画像

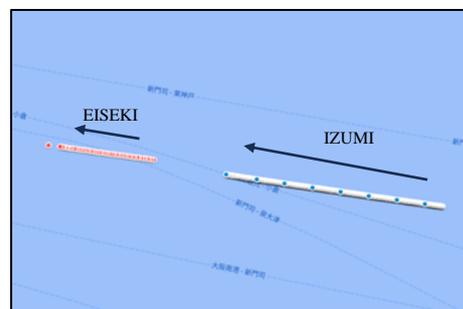


図 101 : 認識時の航路 (※1)

図 100 は対象物の画像、図 101 (※1:出典) は対象船を認識した時の航路となる。「いずみ」の前方を同一方向に進む対象船に真後ろから近づく航路となり、本試験では 6,539m の距離から 3,931m の距離まで近づく形となる。認識距離が遠いこともあり図 102 に示すように 6,000m 以上の距離では対象船がかなり小さく船舶としての形が捉えられないため、認識クラスが Vessel ではなく、Navigation\_Buoy と誤認識する事象が多々発生し、その確率は 634 回の検出数の内 131 回の誤検出で 21% の確率だった。



図 102 : 誤認識時の画像

この誤認識時の画像のピクセルサイズの最大は 8 ピクセル×15 ピクセルと、高さが 10 ピクセルを超えたサイズとなっているが幅が 8 ピクセルと小さいため、縦長の物体と認識され Navigation\_Buoy と認識されているものと思われる。本試験では、対象船を後ろから捉えているため、横長の物体の映像となっていないことも影響しているものと考えられる。縦長として認識されたものが全て Navigation\_Buoy となる訳ではないが Vessel として認識されないケースの場合、この縦長の特徴のものは Navigation\_Buoy として認識される傾向が強い。ちなみに、Navigation\_Buoy と誤認識されたものは、全て幅のピクセル数よりも縦のピクセル数の方が大きな数値となっている。

誤認識の確率が多い結果の実証試験となったが、図 103 に最長距離 6,539m での認識画像を示すように、全長 70m の中型船を距離 6km 以上で検出できる精度は良い結果であると言える。

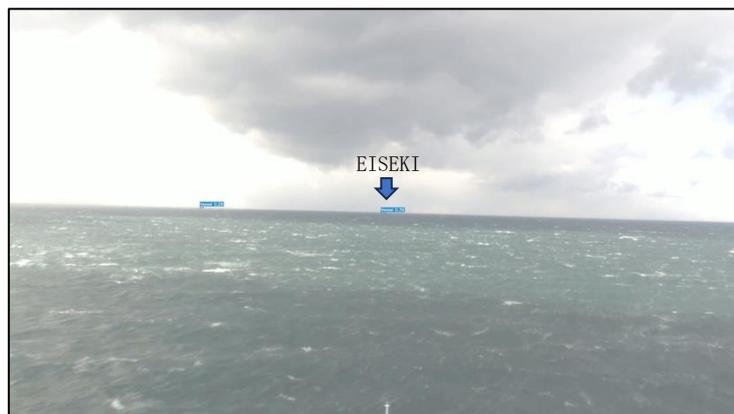


図 103 : 最長距離での認識画像

④ 実証試験結果 4

船名	ASIATIC REUNION
船種	Container
大きさ	全長 143m / 全幅 23m
計測時間	13:42:57 ~ 13:50:00 (7分3秒)
航路	右舷前方よりいずみの方向に近づく船舶
天候	曇り、時々霽
可視光カメラ	右舷の可視光カメラ
認識距離	最長 10,865m / 最短 8,325m
信頼性スコア	25% ~ 87% (平均 64%)
連続認識率	82%

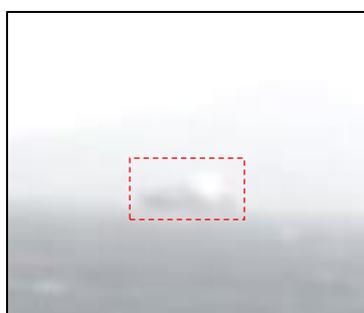


図 104 : 対象物の画像

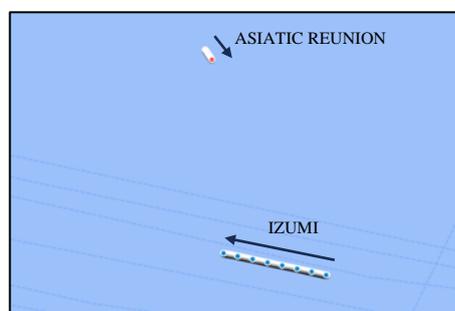


図 105 : 認識時の航路 (※1)

図 104 は対象物の画像、図 105 (※1:出典) は対象船を認識した時の航路となる。図 106 は最長 10,865m での認識画像となるが、海上に雲がかかっているような状況で時折、霽による視界不良が発生した。対象船は 10km 以上離れた位置に存在していたが Vessel として認識することができ、連続認識率もおよそ 9km の地点からは 97% と非常に高かった。

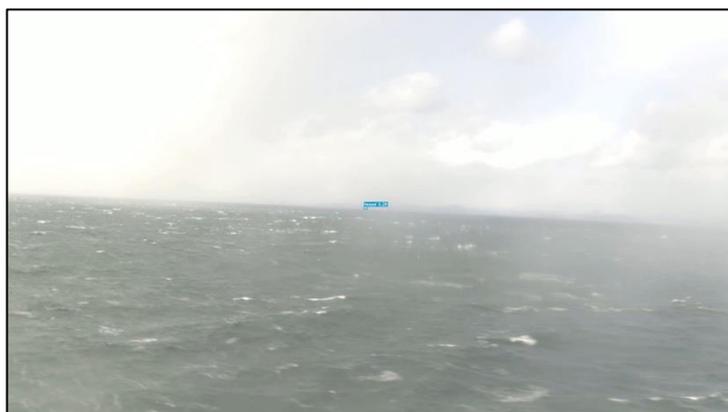


図 106 : 最長距離での認識画像

図 107 は距離 8.7km 地点の画像となるが本対象船は船灯を照らしており船舶の形が区別しやすかったことが高認識の影響になっているものと思われる。



図 107 : 8.7km 地点の認識画像

本実証試験は距離が非常に遠いものであったが誤認識もなく、全て Vessel として認識できた結果となった。

⑤ 実証試験結果 5

船名	周防灘航路第3号灯浮標
船種	航海用ブイ
大きさ	不明
計測時間	13:53:54 ~ 13:55:29 (1分35秒)
座標	33.8061728607041N, 131.493391507657E
天候	曇り
可視光カメラ	左舷の可視光カメラ
認識距離	最長 749m / 最短 488m
信頼性スコア	25% ~ 81% (平均 58%)
連続認識率	71%



図 108 : 対象物の画像



図 109 : 認識時の航路 (※1)

図 108 は航海用ブイを認識した時の画像、図 109 (※1:出典) は航海用ブイを認識した時の航路となる。図 110 は最長 749m での認識画像で航海用ブイまでの距離は近距離となるが、この日は靄も発生しており対象物の形が非常にわかりにくくなっている。およそ 1 分半の映像における連続認識率が近距離ながら 71%と低くなっているが、前半の 30 秒間の連続認識率が 27%、後半 1 分間の連続認識率が 91%という割合になっている。



図 110 : 最長距離での認識画像

前半の連続認識率が27%と低くなっている原因を調査した結果、時折1秒、長くて3秒ほど認識できなくなっている箇所が多々あった。画像を調査したところ認識できなかった時は航海用ブイが波の影響で沈み込んでいる時であった。この日は若干波が高かったため、このような現象が発生した。図111の画像は認識できた画像、図112は認識できなかった画像となる。波は必ず上下するため浮かび上がった時に認識が可能となるため、物体を認識するシステムの運用上の問題はないと考えるが、航海用ブイなどの小さな物体の連続認識率を上げるには、全体が見えない時の画像についても学習する必要がある。ただし、不完全な形を学習すると誤認識が増えるリスクも発生するため、それを考慮して学習するかどうかの検討が必要である。



図 111 : 認識可



図 112 : 認識不可

⑥ 実証試験結果 6

船名	COSCO KIKU
船種	Container
大きさ	全長 138m / 全幅 22m
計測時間	14:01:16 ~ 14:03:00 (1分44秒)
航路	前方から左舷方向にすれ違う船舶
天候	雪
可視光カメラ	中央の可視光カメラ
認識距離	最長 4,548m / 最短 2,444m
信頼性スコア	25% ~ 93% (平均 73%)
連続認識率	88%

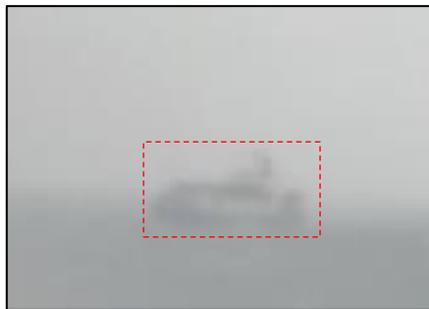


図 113 : 対象物の画像

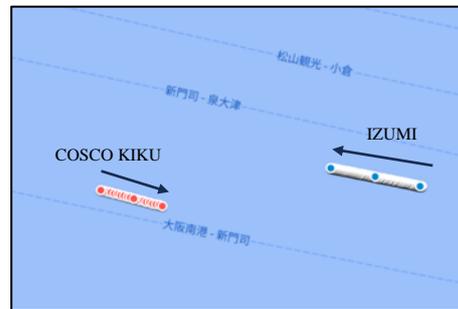


図 114 : 認識時の航路 (※1)

図 113 は対象物の画像、図 114 (※1:出典) は対象船を認識した時の航路となる。この時間帯は一瞬天候が雪となり中央の可視光カメラのハウジングに雪が付着して図 115 のように視界をさえぎる状態となった。対象船が雪の付着したところで見えなくなったおよそ 14 秒間を除くと、連続認識率は 100%と良い結果だった。視界不良の要因として雪の付着だけでなく雨による水滴の付着の問題も考えられるため、可視光カメラのハウジングには撥水シートなどでレンズチューブを保護するハード的な対策も今後必要となる。



図 115 : 可視光カメラに雪が付着した画像

⑦ 実証試験結果 7

船名	FERRY DOUGO
船種	Passenger
大きさ	全長 191m / 全幅 27m
計測時間	19:17:22 ~ 19:20:04 (2分42秒)
航路	前方を横切る船舶
天候	夜、小雨
可視光カメラ	中央の可視光カメラ
認識距離	最長 3,926m / 最短 3,676m
信頼性スコア	25% ~ 88% (平均 60%)
連続認識率	98%

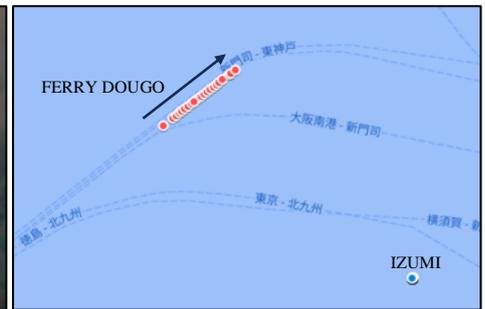


図 116 : 対象物の画像

図 117 : 認識時の航路 (※1)

図 116 は対象物の画像、図 117 (※1:出典) は対象船を認識した時の航路となる。「いずみ」は北九州空港沖に停泊しており、対象船は左舷側から右舷側へ前を横切る航路となる。対象船までの距離は 3.5km 以上あり、小雨によりレンズに水滴が若干付着している状況ではあったが、対象物が大きいため連続認識率は高かった。ただし、認識クラスは Vessel と Passenger\_Vessel の 2 種類を判断している。その割合は Vessel が 81%、Passenger\_Vessel が 19%であり、殆どが Vessel としての認識であった。信頼性スコアの平均をしてみると Vessel が 63%、Passenger\_Vessel が 48%であることから、やはり Vessel としての認識率の方が高い。この旅客船を Passenger\_Vessel として正確に認識させるには、Passenger\_Vessel の学習量を増やす必要がある。

図 118 は FERRY DOUGO を Vessel として認識した時の画像だが、本船の客室部および船首部に灯りが多く、船首甲板部が暗くなっている。このため、明るい箇所が 2 つに分断され、本船は 2 隻の Vessel として認識されている。この現象については、夜間における画像調整により光の反射を抑え船の形をよりよく映し出す必要があると考えるが、画像全体を調整すると他の船にも影響が出るため、FERRY など光の多い船舶の箇

所のみ調整できるような仕組みが今後必要になると考える。



図 118 : 認識した時の画像

#### 4.1.4.4 実証試験のまとめ

現状の昼と夜の学習モデル（既存モデル）に今回学習した視界制限下の学習モデルを組み合わせた統合モデルで実証試験を行なった結果をまとめる。

評価・実証 LAB において霧の状態での実証試験を実施した結果、今回収集した視界制限下の学習データを利用することにより物体認識の精度が向上する結果を得ることができた。およそ 3km より近い距離での検証結果となるが以下の効果が得られたことを確認した。

- 物体を認識するための信頼性スコアが高くなった。特に小さな対象物に対しての効果が大きかった。
- 既存モデルよりも遠くの距離の物体を認識できるようになった。
- 連続した 1 つの物体認識において信頼性スコアの振らつきが少なくなった。
- 誤認識が少なくなった。
- 視界制限のある環境によって認識できなかった物体が認識できるようになった。

この結果から視界制限下の画像を学習することは認識精度の向上に有効であると判断できる。また、本実証試験において 2023 年度の目標である霧および降雨による視界制限下での物体認識距離 1,000m に対し、2.3km の実証結果が得られたこと、視界制限下における 1,000m 以下での物体認識率 90%以上に対し、97.7%の結果が得られたことで、2023 年度の目標は全て達成することができた。

次に遠くの物体を認識する精度については、船舶「いずみ」が航行する海上で実証試験を実施した。その結果を以下の表 28 にまとめる。

表 28 「いずみ」での実証試験結果のまとめ

天候状態	視界状態	対象物(全長)	対象物までの距離	連続認識率	備考
曇り	○	コンテナ船(144m)	2.4km~1.2km	100%	
曇り	○	貨物船(76m)	5.4km~2.2km	82%	4.2km以下で連続認識率は100%
曇り	○	タンカー船(70m)	6.5km~3.9km	28%	6km以上で誤認識が多く発生
霧	△	コンテナ船(143m)	10km~8.3km	82%	9km以下で連続認識率は97%
曇り	○	航海用ブイ	750m~490m	71%	ブイの沈み込みによる未検出あり
雪	×	コンテナ船(138m)	4.5km~2.5km	88%	
夜	○	旅客船(191m)	4km~3.7km	98%	

表 28 の結果から対象物までの距離が 10km であっても認識ができています。遠くの対象物(特に小さな対象物)はその形がはっきりと映らず誤認識となっているケースもあったが物体の検知はできているため、その検知精度については良い結果であったと考える。また、今回の実証試験の結果から新たに改善が必要となる事項も見つけることができた。

- ・ 雨や雪が可視光カメラに付着し、認識できなくなるケースがある。
- ・ 波の影響により認識できないケースがある。

可視光カメラのレンズに雨や雪が付着する対策については、可視光カメラを装備しているカメラハウジングにハードウェア的な対策の検討が必要となる。

波の影響により認識できなくなるケースについては要検討となる。今回は航海用ブイのケースが実証されたが、ポートや漁業用ブイなどの小さな対象物も同様の問題が発生すると思われる。波に対象物が全て隠れてしまったものに対しては認識することはできないが、対象物が少し見える形のものはその画像を学習することで認識率を向上させることができる。ただし、学習するクラスの形の特徴が発散して誤認を誘発してしまう懸念もあることからこのケースの学習データの構築は今後の課題として対応していく。

#### 4.1.5 製品への反映

##### 4.1.5.1 製品への反映

視界制限下における学習データ（5万8千9百16点）を既存の学習モデルへ組み合わせた統合モデルを実施者の製品 infoceanus command へ組み込んだ。現在は「阪九フェリー株式会社：いずみ」に搭載している infoceanus command に反映した。また、実施者による乗船を伴うユーザーレビューを3か月に1回の割合で実施し、夜間航海時の本船乗組員様によるワッチの状況の観察とあわせユーザーコメントを入手し製品に反映した。今回作成した視界制限下の学習データには、Fishing\_Buoy、Boat、Human、Fishers\_Facility のクラスデータが存在していないため、今後はこれらの学習データも追加して行く予定である。ただし、これらの学習データは実映像から収集するのは非常に困難であるため、画像加工のソフトウェア（通常の映像から霧や雨、雪といった映像を作り出す）を用いて学習データを構築していくことを検討していく。

##### 4.1.5.2 普及版製品の構築（試作）

実施者の製品 infoceanus command は可視光カメラを3台利用し、3種類の映像を同時にエッジサーバーで物体認識を行っている。このため、エッジサーバーは高スペックのものでなくてはならない。各機材の外形も大きくなり且つ物量も増えてくるため、船舶への搭載の際には機材の設置場所の確保や配線工事、航海計器からの信号入力の取り合いなど、製品を設置するための工事が大掛かりとなってしまう。このことにより、機材費用のみならず設置のための工事費も多くかかってしまう。infoceanus command は大型船だけでなく、小型船や浚渫工事のための特殊船などからの利用要望もあり、可視光カメラの台数は少なくとも簡単に利用できるシステムを要求されることがある。また、内航船などでは、機器を設置するスペースが限られる事もあるため、infoceanus command の普及版を構築することを検討し、試作を行った。

仕様として、可視光カメラの台数は1台、エッジサーバーはLaptop型のパソコンの構成とし、特別な工事を必要とせず、ユーザーによる設置、設定、セットアップの後に利用開始できるシンプルな構成とした。カメラは操舵室内部に設置できる小型の筐体とし、市販のカメラブラケット等により固定する。また、エッジサーバーがLaptop型であることによりバッテリーが搭載されているためUPSも不要となる。（ただし、可視光カメラなどの電源を切れないようにするにはUPSは必要となるが小型のもので良い）

普及版製品のシステム構成を図 119 に示す。



図 119 : 普及版製品のシステム構成

基本構成は、図 120 の可視光カメラ、PoE スイッチ、エッジサーバーおよびインターネット接続環境が揃えば運用できる形態とした。可視光カメラの映像および物体認識の結果を表示するアプリケーションはエッジサーバーにインストールされている。図 119 内の波線で示す航海計器のデータはオプションとし、この信号をネットワークで取り込めば、アプリケーションの画面内に AIS で認識した船舶の位置や、可視光カメラが認識した物体までの距離、および衝突回避のための TCPA(Time of Closest Pointed Approach) および DCPA(Distance of Closest Pointed Approach) の値を表示することができる。

試作品の課題として、カメラの視野角が 50~60 度に限定されることが挙げられる。カメラ用レンズを広角のタイプにすることで、より広い範囲を監視することもできるが、オプションとして前述した、物体までの距離の測定が困難になる。今後の開発では広角と距離の測定を両立させる工夫が必要となる。試作を通して、事業目的に挙げた「広く普及させる事が可能な価格帯 (1 / 10 程度のコスト感)」の実現は可能であることを確認した。



図 120 : 普及版製品写真 (試作品)

## 4.2 2023年度の目標達成状況

### 4.2.1 サンプルデータの収集実績（雨天・霧）

目標	実績	
5万点	収集画像数	3万9千枚
	収集データ数	5万7千点

学習用データの収集目標5万点に対し、5万7千点分の学習データを収集できたため、目標を達成することができた。

### 4.2.2 サンプルデータの前処理実績（雨天・霧）

目標	実績	
5万点	アノテーション数	5万8千9百16点

アノテーション専門業者と協力して、5万8千9百16点のアノテーション作業を実施した。

### 4.2.3 AIの学習データの構築実績（雨天・霧）

目標	実績	
5万点	学習データ数	5万8千9百16点

サンプル画像の前処理で実施したアノテーションデータを全て利用して5万8千9百16点の学習データを構築した。実証試験に関してはこの学習データと既存の学習データを統合した統合モデルを構築して実施した。

### 4.2.4 実証試験の実績（雨天・霧）

評価項目	目標	実績
霧および降雨による視界制限下での物体認識距離	1,000m以上	2.3km
視界制限下における1,000m以下での物体認識率	90%以上	97.7%

視界制限下での物体認識距離については、その時の視程の度合いにもよるが実証試験を実施した霧の状態でも最長2.3kmでの認識ができた。1,000m以下での連続認識率についても船舶で97.7%、1.2km先の航海用ブイで90.4%の結果を得ることができたため、今年度の目標は全て達成することができた。

#### 4.3 2023年度の実施内容の概要

##### 4.3.1 サンプル画像の収集（雨天・霧）

AIに学習させるためのデータセットに用いるサンプル画像を、評価・実証LABおよび、阪九フェリー株式会社の船舶「いずみ」に実施者の製品 infoceanus command を設置し、その録画機能を利用してサンプル画像を収集した。サンプル画像の収集は5万点を目標としたが、結果5万7千点のサンプル画像を収集することができた。

##### 4.3.2 サンプル画像の前処理（雨天・霧）

収集したサンプル画像をもとにAIに学習させるための前処理（アノテーション作業）を行った。収集したサンプル画像は動画データであるため、フレームに分割して静止画データへ変換したのちに前処理を実施した。前処理は専門業者へ依頼し、専門業者と実施者とでデータを確認し合いながら5万8千9百16点のAI学習データを構築した。サンプル画像の収集数より多くなっているのは、アノテーション作業時に追加でアノテーション数を増やしたことによるものとなる。

##### 4.3.3 AIによる学習（雨天・霧）

前処理にてアノテーションを行ったデータを用いて視界制限下のAI学習データを作成し、視界制限下における物体認識精度の向上が見られるか検証を行った。評価に使用したモデルは、既存モデル、視界制限下モデル、統合モデルの3種類とし、評価指標にはmAP値(mean Average Precision=100に近づくほど認識精度が高いと言える)を用いた。検証の結果、視界制限下、統合モデルのそれぞれにおいて、mAP値の向上が見られた。さらに学習モデルによる認識結果の比較を行う指標として、信頼性スコア、誤認識率、連続認識率の3つを用い評価した結果、いずれの指標も向上が見られたことから、AIによる学習の有効性を確認した。

#### 4.3.4 学習結果の実証（雨天・霧）

4.1.3 項で作成した視界制限下の学習データを評価するため、既存のモデルと視界制限下のみのモデル（視界制限下モデル）を霧のビデオ映像を元に比較評価した。視界制限下モデルの物体認識精度は既存モデルよりも高い精度であることが確認できたため、infoceanus command へ組み込むための統合モデル（既存モデルと視界制限下モデルを組み合わせたもの）を構築して実証試験を実施した。実証試験は近距離での精度確認を行うための評価・実証 LAB での実証試験と、遠距離の精度確認を行うための「いずみ」による実証試験の2回に分けて行った。実証試験の結果として、視界制限下の状態での1km先の物体認識については最長2.3km先まで認識ができ、1km以下の認識率90%の目標に関しては97.7%の認識率を得ることができ本事業の目標を達成できた。また、遠距離での実証試験においては船舶「いずみ」の航海中で実施し、新たな改善項目を見つけ出すことができた。

#### 4.3.5 製品への反映（雨天・霧）

実証試験にて検証した統合モデルを実施者の製品 infoceanus command のアップデートモジュールとして組み込みを実施した。このアップデートモジュールは、「いずみ」にて継続的に検証を続けており、今後販売する製品に対してもアップデートモジュールを適用することになる。また、本事業の目的の一つである、従来技術と比較したコストメリットを重視し、広く普及させる事が可能な価格帯（1／10程度のコスト感）を実現するために、サーバーシステムやカメラ構成を簡素化させた普及版製品の検討と試作を行ない、目的にあげたコスト感の実現が可能であることを確認するとともに、製品化に向けた今後の課題を抽出した。

## 5. 今後の予定

### 5.1 視界制限下の学習データの収集

実際の視界制限下の学習データを収集するには天候の状態に左右され、且つ、あらゆる場所での収集も非常に困難である。このため、今後は視界制限下の映像をソフトウェアで構築し、その画像を学習していくことを検討していく。この方法が有効であれば天候や場所に囚われることなく効率の良いデータの収集が行える。

### 5.2 視界不良の要因対策

今回の実証試験において、可視光カメラのハウジングに雪が付着し物体認識に影響が出る現象があった。雪だけでなく雨による水滴の付着の影響も考えられるため、カメラハウジングのレンズチューブに撥水シートなどによる付着防止対策を検討していく。

### 5.3 波による影響の対策

今回の実証試験において、航海用ブイが波によって沈んだ際、認識ができなかった結果が得られた。本件について対策は波に物体が沈んだ際の画像データを学習することが考えられるが、学習データの精度の問題もあるため、運用において問題が発生した際に検討していくこととする。

### 5.4 販売計画について

既存の製品について、雨天・視界制限下での利用が可能になったことで、2024年度よりこれらの特長を前面に出して販売を促進することが可能になった。また、既存製品の販売を強化すると同時に、本事業にて試作を行った普及版製品について2024年度中の製品化、および当初の目的であった内航船への広い普及に向けた販売開始を目指す。

## 6. まとめ

最後に本開発に関して公益財団法人日本財団からモーターボート競走共益資金による補助金を受けて実施しており、ここに記して厚く感謝申し上げます。

## 7. 出典および参考文献

出典：

- ※1 掲載した地図は Google Map 上に座標データをプロットし、その表示画像を利用させていただいております。 (<https://www.google.co.jp/maps/>)
- ※2 船舶の画像は Marine Traffic のホームページに掲載されている画像から引用させていただいております。 (<https://www.marinetraffic.com/>)

参考：

- ※3 DHP(Dark Channel Prior)  
K. He, J. Sun and X. Tang, "Single Image Haze Removal Using Dark Channel Prior," in IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 33, no. 12, pp. 2341-2353, Dec. 2011, doi: 10.1109/TPAMI.2010.168.
- ※4 ACE(Automatic Color Enhancement)  
Getreuer, Pascal. (2012). Automatic Color Enhancement (ACE) and its Fast Implementation. Image Processing On Line. 2. 266-277. 10.5201/ipol.2012.g-ace.
- ※5 CLAHE (Contrast Limited Adaptive Histogram Equalization)  
Veluchamy, Magudeeswaran & Subramani, Bharath. (2019). Image Contrast and Color Enhancement using Adaptive Gamma Correction and Histogram Equalization. Optik. 183. 10.1016/j.ijleo.2019.02.054.
- ※6 OpenCV ヒストグラム その2 : ヒストグラム平坦化  
[http://labs.eecs.tottori-u.ac.jp/sd/Member/oyamada/OpenCV/html/py\\_tutorials/py\\_imgproc/py\\_histograms/py\\_histogram\\_equalization/py\\_histogram\\_equalization.html](http://labs.eecs.tottori-u.ac.jp/sd/Member/oyamada/OpenCV/html/py_tutorials/py_imgproc/py_histograms/py_histogram_equalization/py_histogram_equalization.html)  
  
Wikipedia(Histogram equalization)  
[https://en.wikipedia.org/wiki/Histogram\\_equalization](https://en.wikipedia.org/wiki/Histogram_equalization)

「この報告書は BOAT RACE の交付金による日本財団の助成金を受けて作成しました」

(一社)日本船用工業会

〒105-0001

東京都港区虎ノ門一丁目 1 3 番 3 号 (虎ノ門東洋共同ビル)

電話 : 03-3502-2041      FAX:03-3591-2206

<https://www.jsmea.or.jp>