

画像認識による船体汚損度の判定とその時間変化の予測

○ Zixin Li †, 滝澤一樹 †, 美尾樹 †, 中原亮一 ‡

†: 株式会社三井 E&S 成長事業推進事業部 デジタル・ソリューション部

‡: 株式会社三井 E&S 成長事業推進事業部 マーケティング部

zixin-li@mes.co.jp

概要：船舶の燃費に影響を与える船体汚損度に対し画像認識を用いて定量化を行い、将来的な汚損の進展を予測する手法を提案する。水中ドローンで撮影した検査画像に対してバイオフィルムの付着箇所に着目してアノテーションを行い、汚損度のランク付けを行うセマンティック・セグメンテーションモデルの学習を行った。また、得られた各汚損度の面積割合の経時変化を予測するためにカルマンフィルタを設計し、動作を検証した。

<キーワード>船体汚損, セマンティック・セグメンテーション, 汚損度進展予測

1. はじめに

近年、地球温暖化を引き起こす温室効果ガス (GHG) の排出が社会課題となっている。船舶においては、国際海事機関 (IMO) の第 80 回海洋環境保護委員会 (MEPC80) において 2050 年までに GHG 排出量をネットゼロとする内容が GHG 削減戦略として合意された。2025 年 4 月に開催された MEPC 83 において、その具体的な中期対策に関する新たな規制が承認されている [1, 2]。また、燃料消費実績報告制度では 2019 年より燃料消費量等の運航データの収集や報告が義務化されているが、2026 年 1 月より燃料を使用する機器ごとの燃料消費量の合計が 80 報告項目に追加されることが決定されており、海運会社には船舶運航におけるより厳格な燃料消費量の管理が要求されている。

船体及びプロペラ表面に付着する生物汚損 (Bio-fouling) は、船舶の摩擦抵抗を増加させ、船舶の推進性能の低下や燃料消費効率の悪化の要因となることが知られている [3]。文献 [3] の技術レポートによると、フジツボや藻類などの水生生物まで成長するに至らなくとも、船体の約 50% が厚さ 0.5mm のバイオフィルム (微生物などが表面に付着して形成する膜状の集まり) で覆われると燃料消費効率としては 25~30% 悪化することが示されており、燃料消費量を適切に管理するためには水生生物の付着だけでなく、バイオフィルムの成長の把握も必

要不可欠である。

機械学習を利用した画像認識技術は様々な目視検査で活用されており、海洋分野においても水生生物の認識で高い成果を上げている。First らの研究では、分類器を教師あり学習することによりバイオフィルム層を簡便に検出することに成功している [4]。通常、海運会社はダイバーや水中ドローンで撮影した画像により船体汚損状況を把握している。画像認識技術によるバイオフィルムの検出やその成長予測ができれば、海運会社は船体洗浄のタイミングを含めた運航計画管理の高度化が可能になる。

本研究では、2024 年 2 月~2025 年 9 月の期間に特定の運搬船において撮影された水中での船体画像を対象として画像認識技術を適用し、船体に付着・成長したバイオフィルムの検出を試みた。また、航海ごとに算出された平均燃料消費量と画像から検出された生物汚損を比較することで、その汚損度合いと面積割合の変化を状態空間モデルを用いて時系列予測を行うことにより汚損度合いの変化の予測を行った。

2. 関連研究

2.1. 生物汚損の分類基準

船体およびプロペラ表面における生物付着の評価については、IMO から「船体付着生物の管理に

関するガイドライン」が出されたが、現時点において学术界および産業界の双方において、統一的かつ汎用的な評価手法が確立されていない [1]。各研究では、それぞれの研究目的や実験条件に応じて、独自の評価指標および分類体系が用いられている。Firstら [4] は実験パネルに形成された汚損を対象に、パネル表面を、付着生物の種類（付着性ホヤ類や刺胞動物ポリプなど）に基づいて詳細に分類している。しかしながら、この手法は付着生物の種類を重要視しており、各区分が船体の推進性能や燃費効率に及ぼす影響という観点では評価していない。船体表面の付着層の厚さおよび分布は、付着物種類などとともに推進抵抗および燃費効率に重要な寄与をすることが広く知られているが、船体表面に付着したバイオフィルムの成長に関して画像認識により識別した研究は既往の研究ではなく、画像に基づく判定基準の確立が必要である。

2.2. セグメンテーション手法

近年、Transformer が視覚分野に広く応用されるようになるに伴い、高解像度画像の効率的な処理が重要な課題となっている。Swin Transformer は、Windows および Shifted-Windows 仕組みを提案し、従来の全体に対して行っていた Self-attention 計算を指定されたウィンドウサイズ内でのみ実行することで、計算量を大幅に削減し、効率的な計算を実現した [6]。その結果、高解像度画像におけるセグメンテーションなどのタスクにおいて優れた性能を示している。Mask2Former は Transformer を用いたセグメンテーション手法をさらに発展させたモデルであり、過去の研究において細かい罫の

色合いの違いまで検出できており、バイオフィルムの厚みによる色合いの違いを区別する能力を有していると考えられる [7, 8]。

3. 汚損度の定義手法

図 1 は一定速度で航行する船舶における単位時間あたりの燃料消費量の時間変化を示したものである。5月1日から7月23日までの期間において航海あたりの平均燃料消費量は緩やかな増大傾向を示す。一方、7月23日以降から9月2日にかけては平均燃料消費量が顕著に増大した。この変化の前後の汚損状況を確認すると、7月23日以前では船体及びプロペラ表面に薄黄緑色のバイオフィルムしか存在せず、次の時点からプロペラ上に高密度で茶褐色状のバイオフィルムが大量に現れたことがわかった。この結果から微細藻類の色合いや被覆度合いが異なる場合には、燃料消費量の増加速度が異なることが確認される。バイオフィルムが成長することにより表面粗度や被覆面積が増加し、推進抵抗の増加により燃料消費効率が悪化したことが推測される。

本研究では、汚損度と推進性能を定量的に紐づけるために、汚損状態の定義づけを行った。目視でバイオフィルムの付着が観測されなかったものを degree-0、目視で観測できる薄黄緑色のバイオフィルムを degree-1、茶褐色のバイオフィルムを degree-2 と分類した。図 2 に示した通りに、このように分類すると、概ね degree-1 では下地の状態がある程度目視で観測でき、degree-2 ではほぼ下地が見えなくなっているのが特徴的である。表 1 には本研究における汚損度の定義と文献 [4] における定義との比較を示す。前述の通りに、文献 [4]

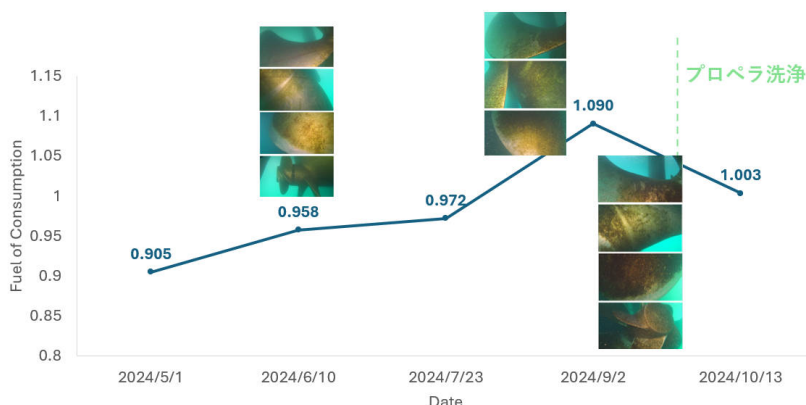
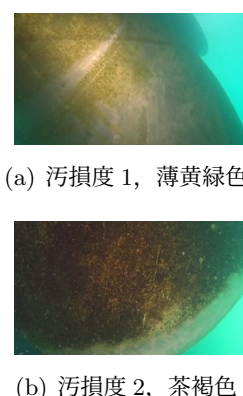


図 1 単位時間当たりの燃料消費量 (FOC) の経時変化



(a) 汚損度 1, 薄黄緑色
(b) 汚損度 2, 茶褐色

図 2 色合い

表 1 ラベルの定義

本文の定義	文献 [4] の定義との比較	詳細説明
degree-0	Class1(クリーン) に相当	Bio-fouling なし
degree-1	Class2(微細藻類) に相当	スライム状のバイオフィルムが軽度につ着, 主に薄黄緑色, 下地状態を目視で確認できる
degree-2	Class2(微細藻類) に相当	スライム状のバイオフィルムが密集につ着し, 主に茶褐色や濃緑色, 下地状態が遮断され, 確認困難または不可能
coating-0	言及なし	すべて塗装が完全に剥がれ, 地肌が露出している部分
coating-1		2層目の塗装が剥がれ, 1層目の塗装が露出
coating-2		3層目の塗装が剥がれ, 2層目の塗装が露出
coating-3		塗装状態が良好で剥がれなし

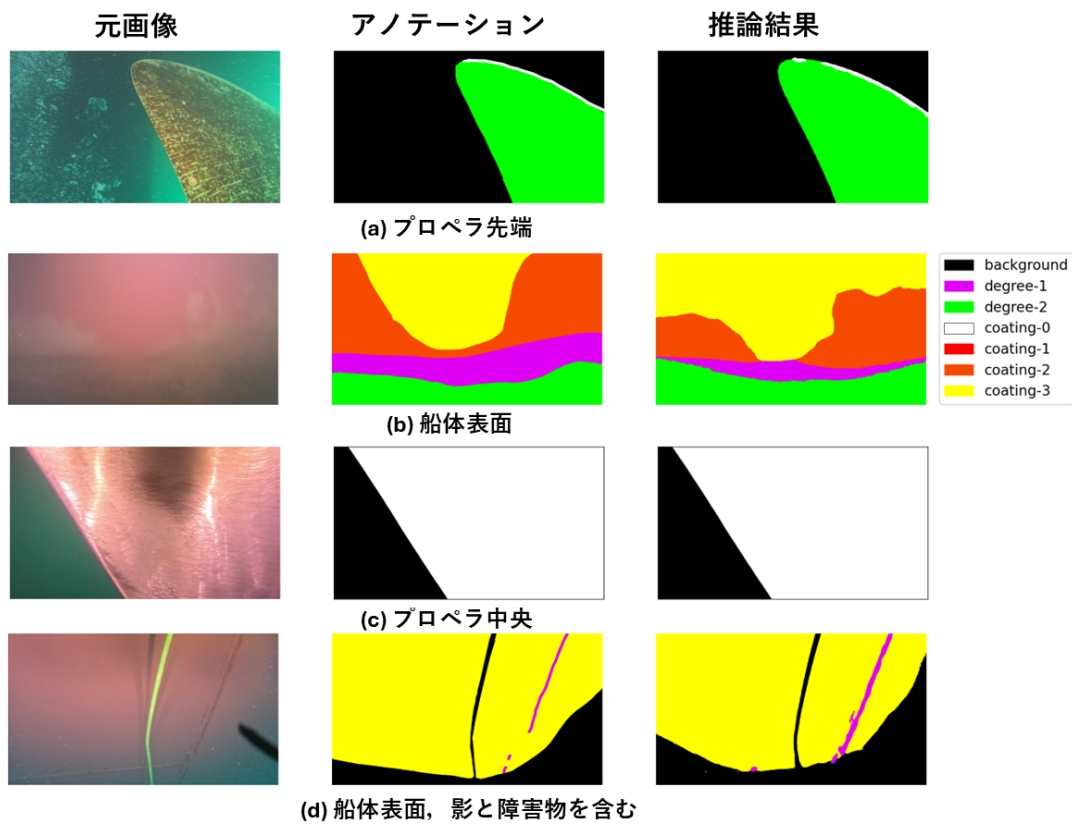


図 3 人手によるアノテーション画像 (2 列目) と検出モデルの推論結果 (3 列目)

において「クリーン」に次ぐ最も軽微な汚損段階として定義されている「微細藻類バイオフィルム」は、厚さ 1mm 未満とされており、本研究における degree-1 および degree-2 の範囲を包含する概念に相当する。本研究の定義は生物種に依存しないため、藻類の定義に拘らず藻類以外の微小なスライム状生物であっても、その外観的特徴が該当する場合には、degree-1 または degree-2 として分類される。

また、防汚塗装の保護作用により、洗浄後の滑らかな船体表面には、フジツボのような一定以上

の体積を有する生物は容易につ着しない。そのため、本研究では塗装の剥離状況も分類し、識別対象に含めることで、後述の予測作業における分析要素として取り入れた。対象とした船舶の船体には 3 種類の色合いを持つ防汚塗料が積層されており、表面層により色合いが異なる。それらを coating-0~coating-3 で分類した。プロペラは塗装されていないため、生物が付着していない領域はすべて coating-0 として分類した。

4. Mask2Former による船体汚損の識別

本研究は計算速度の向上によるリアルタイム性よりも精度向上を追求した。Swin Transformer の強力なマルチスケール特徴抽出能力と、Mask2Former[7] の高効率かつ汎用的なセグメンテーション機構を組み合わせることにより、高精度かつロバストな手法として、外観検査への応用が期待できる。モデルは ImageNet で事前学習された Swin Transformer(Large) をバックボーンとし、Mask2Former をセグメンテーションフレームワークとしてファインチューニングを行った。学習データは水中カメラで撮影された映像から、プロペラを 415 枚、船体を 1832 枚の画像サンプルを切り出し、前節の定義に基づいてアノテーションを行った。水中における光量の制限により汚損度合いや塗装状態の判別が困難となる影領域や、撮影設備などの異物が画像中に写り込んでいる場合、それらはアノテーション範囲外とした。データセットは、7 割を学習用、2 割を検証用、1 割をテスト用としてランダムに分割した。

学習においては、検証データで平均 IoU が最大となったエポックの重みを採用した。表 2 はテストセットで検出精度の評価を行った結果を示す。プロペラの検出精度が 70% 以上であり、船体表面に関しても coating-0 と degree-2 以外が 70% 以上であるため、良好な識別結果が得られている。coating-0 と coating-1 に関しては船体表面は基本的に 3 層の塗料によって覆われており、塗料が完全に剥離している事例は極めて稀であり、データ量が不足している。一方で、degree-2 については、完全に露出しているプロペラとは異なり、塗料によって船体表面には付着物が付きにくく、分散して付着する傾向がある。このような付着形態に対しては、人手による細かいアノテーションが困難であるため、アノテーション方法の改善は今後の課題になる。

図 3(a)(b) より、モデルの推論結果と人手によるアノテーションには大きな差異が見られないことが分かる。また、図 3(b) からは、白色に近い二層目の塗装 (coating-2) と赤色の三層目の塗装 (coating-3) の境目について、モデルの推定結果の方がアノテーションよりも正確であることが分かる。図 3(c) は撮影者が意図せずに照明モードを赤色光に切り替

表 2 テストセットにおける検出精度 (IoU)

Class	Propeller	Hull
background	92.48	73.37
degree-1	71.93	73.13
degree-2	80.95	54.26
coating-0	83.25	37.18
coating-1	—	NA
coating-2	—	75.07
coating-3	—	84.6

えた事例であるが、モデルはプロペラ部分を正確に検出し、正しいクラス (coating-0) として識別しており、モデルのロバスト性が示された。図 3(d) は水質が比較的濁っている日に撮影された画像であり、画面内には多くのマリンスノーが確認される。しかしながら、これらのマリンスノーはモデルの判断に影響を与えずに正確な結果が得られていることがわかる。船体表面の状態が判別しづらい画像下部の領域やケーブルなども、適切に識別対象から除外されている。

5. 汚損度の時系列予測モデル

5.1. 状態空間モデルの設計

船体を撮影した画像からバイオフィルムの成長を予測する際に、画像認識による汚損度の判定結果が実際のバイオフィルムの状態を完全に再現するのは困難であるため、ある程度観測値に含まれるノイズを考慮したロバストなモデルを設計する必要がある。また、本論文で対象としている中型の運搬船は年に数回程度の頻度でしか点検・洗浄を行わないため、観測される汚損度データはスパースである。このような条件下では予測モデルによる状態値と実際の観測による状態値の補正を分離して扱うことができる状態空間モデルが適していると考え、本研究では、状態空間モデルの中でも制約付き線形カルマンフィルタにより各汚損度クラスの割合の変化の予測を行った。カルマンフィルタは一般的にはロボットなどの運動動作における物理量の予測などに用いられるが、社会学などの分野では非物理量の時系列予測などにも幅広く用いられている。予測に用いた状態遷移方程式を

式 1～式 7 に示し、制約条件を式 8, 9 に示す。

$$[\text{deg-0}]_{t+1} = [\text{deg-0}]_t - v_{01,t}\Delta t \quad (1)$$

$$[\text{deg-1}]_{t+1} = [\text{deg-1}]_t + v_{01,t}\Delta t - v_{12,t}\Delta t \quad (2)$$

$$[\text{deg-2}]_{t+1} = [\text{deg-2}]_t + v_{12,t}\Delta t - v_{23,t}\Delta t \quad (3)$$

$$[\text{deg-3}]_{t+1} = [\text{deg-3}]_t + v_{23,t}\Delta t \quad (4)$$

$$v_{01,t+1} = \alpha_{00}[\text{deg-0}]_t + \alpha_{01}[\text{deg-1}]_t + \alpha_{02}[\text{deg-2}]_t - \alpha_{03}[\text{deg-0}]_t(1 - [\text{coat-0}]_t) + \beta_0 2^{(T-T_0)/T_1} \quad (5)$$

$$v_{12,t+1} = \alpha_{11}[\text{deg-1}]_t + \alpha_{12}[\text{deg-2}]_t + \alpha_{13}[\text{deg-3}]_t + \beta_1 2^{(T-T_0)/T_2} \quad (6)$$

$$v_{23,t+1} = \alpha_{23}[\text{deg-2}]_t + \beta_2 2^{(T-T_0)/T_3} \quad (7)$$

$$[\text{deg-0}]_t + [\text{deg-1}]_t + [\text{deg-2}]_t + [\text{deg-3}]_t = 1 \quad (8)$$

$$0 \leq [\text{deg-}i]_t \quad (i = 0, \dots, 3) \leq 1 \quad (9)$$

ここで、状態変数 $[\text{deg-0}]_t$, $[\text{deg-1}]_t$, $[\text{deg-2}]_t$, $[\text{deg-3}]_t$ は、それぞれ時刻 t における各汚損度クラスの割合を示しており、状態変数 v_{01} , v_{12} , v_{23} はそれぞれ状態 degree-0 \rightarrow degree-1, 状態 degree-1 \rightarrow degree-2, 状態 degree-2 \rightarrow degree-3 の遷移に対する面積割合の変化の速度を示している。速度係数 α_{**} ・温度係数 β_* ・基準温度 T_* はハイパーパラメータである。 $[\text{coat-0}]_t$ は coating-0 クラスの割合を示している。汚損が進展した場合には船体表面のコーティングは見えなくなるので、coating-0 の割合の分母は degree-0 の面積となっている。

バイオフィルムの成長を状態量として取り込む上で、環境の変化による影響も考慮する必要がある。Uzun らの報告によれば、バイオフィルムの成長は、海面温度、塩分濃度、pH、流速、光量、栄養素、帯水時間、表面のマイクロテクスチャ、表面電位、濡れ性、表面粗度、防汚塗料の性能などにより変化することが示されている [5]。図 4 は 2025 年 3 月から 2025 年 9 月までの期間における対象船の寄港海域における表面海水温度を示したものである。図の横軸は対象船の積算停泊日数を示している。対象としている運搬船は航路として北半球と南半球の往復を繰り返しているため、表面海水温が 9-30 °C の範囲で大きく変化しており、バイオフィルムの成長に強く影響することが考えられる。モデルでは 5-7 式の最終項により、遷移速度の増加

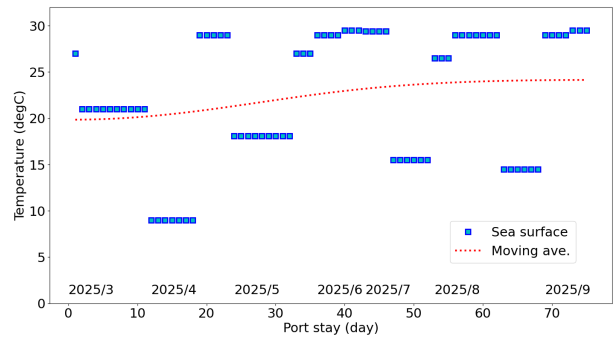



図 4 停泊期間中の温度変化

を表現している。海面温度の情報は気象庁の公開データや実際の船舶の運航時の計測データなどから正確な値が得られるため、簡略化のために外部入力としてモデルに導入した。


5.2. プロペラの汚損度予測

図 5 はプロペラ表面の汚損度の経時変化を状態空間モデルを用いて予測した結果を示す。図の横軸は総停泊日数を示しており、本モデルによる汚損度予測は動きの激しい航行中にはバイオフィルムの成長は遅く、動きの少ない港での停泊中にバイオフィルムが成長するという仮定に基づいている。初期条件はプロペラ洗浄を終えた直後の状態である汚損のない状態 (degree-0 = 1.0) とし、データのばらつきを考慮して、初期共分散行列は $0.0007I$ とした。画像解析による汚損度評価を行った結果は図中に青マーカーで示してあり、赤線は予測値、黄色の領域は誤差共分散の推定から算出した 95% 信頼区間の領域を示している。図中の 80 日目以降は予測値のみを示しており、このときの海水表面温度は 25°C で一定とした。


図から洗浄後 20 日ぐらい経過すると汚損の進行が進んでくることが予測されている。バイオフィルムの初期段階ではバクテリアなどの微生物がプロペラ表面のコンディショニングを行うため Biofouling 初期成長が遅くなる [9]。その後、汚損は急速に発展していき、およそ 80 日後にはプロペラ全体がバイオフィルムに覆われるとの予測結果が得られている。5 式はその様子を定式化したものである。右辺第 2 項は degree-1 の成長、すなわちバイオフィルムの成長に伴い degree-0 \rightarrow degree-1 の遷移が促進される。80 日後以降では支配的な成長は degree-1 から degree-2 に移り、degree-2 の汚損がプロペラ




(a) プロペラ汚損度 (degree-0)




(a) 船体汚損度 (degree-0)




(b) プロペラ汚損度 (degree-1)



(b) 船体汚損度 (degree-1)



(c) プロペラ汚損度 (degree-2)



(c) 船体汚損度 (degree-2)

図 5 プロペラ汚損度の経時変化

図 6 船体汚損度の経時変化

全体に広がっていく。予測結果では観測点において推定誤差共分散値が減少しており、観測点において推定精度の改善が確認できている。80日目以降は計測値がないため、予測を繰り返すたびに誤差が大きくなっていく結果となった。

5.3. 船体の汚損度予測

図 6 に船体汚損度の経時変化の様子を示す。船体汚損度とはプロペラ以外の部分の平均的な汚損度を意味する。図 5 と同様に横軸は洗浄後の総停泊日数を示しており、degree-0～degree-3 の面積割合の変化が示されている。プロペラ部との大きな違いとして、船体には通常防汚塗料が存在する点である。防汚塗料上では汚損の進展が遅いため、プロペラの場合と比較してグラフの傾きは緩やかになる。およそ 80 日で船体（喫水部分）の約 1 割に汚損が進展する結果となった。この状況は 5 式においても右辺第 4 項で表現している。コーティン

グされた部分の面積が多いほど、汚損の進展が抑えられることがわかる。反対に、汚損度が進展していくとコーティング表面が汚損に覆われるため、その抑制効果の影響は小さくなる。緩やかな汚損の進展の場合には誤差共分散の推定値の値も小さくなり、比較的精度よく予測結果が得られている。

6. まとめ

本研究では、船舶の燃料消費量と船体表面の生物汚損の画像を比較することで、船体の汚損度をバイオフィームの色合いに基づいて分類し、Mask2Former を用いてセマンティック・セグメンテーションを行うことで船体とプロペラの汚損度評価を行う手法を検討した。また、カルマンフィルタを用いて各クラスの汚損度の時系列予測を行うモデルを構築することで、船体やプロペラの汚損度の進展予測を行う手法を検討した。これにより、

点検時に撮影した画像から燃料消費量が予測できれば、本手法は船舶のメンテナンス計画を決める上で有益な情報となる。

今後の課題としては、アノテーション手法を見直して汚損度判定の精度を高めていくこと、洗浄前後において状態空間の不連続性に対応して予測精度を高めること、を行い、サービスの価値を高めていきたい。

参考文献

- [1] Resolution MEPC.377(80) - 2023 IMO Strategy on Reduction of GHG Emissions from Ships.
- [2] ClassNK External Affairs Department Vol. 2025-01, 2025.
- [3] Analysing the Impact of Marine Biofouling on the Energy Efficiency of Ships and the GHG Abatement Potential of Biofouling Management Measures, Published by GloFouling Partnerships and GIA for Marina Biosafety. London, 2022.
- [4] First MR, Riley SC, Islam KA, Hill V, Li J, Zimmerman RC, Drake LA, 2021. Rapid quantification of biofouling with an inexpensive, underwater camera and image analysis. *Management of Biological Invasions* 12(3): 599–617.
- [5] Dogancan Uzun, Yigit Kemal Demirel, Andrea Coraddu, Osman Turan. Time-dependent biofouling growth model for predicting the effects of biofouling on ship resistance and powering. *Ocean Engineering*, Volume 191, 2019, 106432, ISSN 0029-8018. <https://doi.org/10.1016/j.oceaneng.2019.106432>
- [6] Ze Liu, Yutong Lin, Yue Cao, Han Hu, Yixuan Wei, Zheng Zhang, Stephen Lin, Baining Guo. Swin Transformer: Hierarchical Vision Transformer using Shifted Windows. In *International Conference on Computer Vision*, 2021.
- [7] Bowen Cheng, Ishan Misra, Alexander G. Schwing, Alexander Kirillov, and Rohit Girdhar. Masked-attention Mask Transformer for Universal Image Segmentation. In *IEEE Conference on Computer Vision and Pattern Recognition*, 2022.
- [8] Zixin Li, 滝澤一樹. 画像認識による大型クレーンインフラ設備の錆検知とその腐食度評価方法の検討. *ビジョン技術の実利用ワークショップ ViEW2024*, 468-472, 2024.
- [9] L.F. Melo and T.R. Bott, *Biofouling in Water Systems*, *Experimental Thermal and Fluid Science* 14, 375-381, 1997.

Zixin Li: 株式会社三井 E&S 成長事業推進事業部 デジタル・ソリューション部 デジタル開発グループ所属. 主に画像認識に関する研究に従事。

滝澤一樹: 株式会社三井 E&S 成長事業推進事業部 デジタル・ソリューション部 デジタル開発グループ所属. 博士(工学). 2004年に三井造船株式会社(現, 株式会社三井 E&S)に入社. 主に, 研究開発業務に従事. 2017年頃より画像認識関連の開発に携わる。

美尾樹: 株式会社三井 E&S 成長事業推進事業部 デジタル・ソリューション部 デジタル開発グループ所属. 博士(理学). 2022年に株式会社三井 E&Sに入社し, 以来画像認識関連の開発業務に従事。

中原亮一: 株式会社三井 E&S 成長事業推進事業部 マーケティング部 マーケティンググループ所属. 主に新規事業開発に関わる業務に従事. 2023年頃より水中船体汚損管理に関する事業開発に携わる。