

陸上養殖のためのウニの行動解析システムの構築

Building a Behavior Analysis System for Sea Urchins in Aquaculture Systems

研究学生：松井 竣哉

指導教員：江崎 修央

1. はじめに

近年、全国各地の沿岸で藻場が著しく減少する磯焼けが深刻化している。磯焼けは海水温の上昇によるさまざまな影響が原因とされている。ウニは、藻類を餌とするため食害が目立つようになってきた^[1]。ここで、ウニは高級食材として人気があるが、磯焼けの藻場で育ったウニは身が痩せており、価値が低い。そのため、地域の漁業者は採取しない。そのため、伊勢志摩地域では、海女がウニを海中で割って駆除している。一方で、駆除されたウニを捕獲し、陸上養殖で身を太らせて販売する取り組みも始まっている。しかし、ウニ養殖の手法は確立されておらず、経験に頼った判断や手作業が多いため、品質の向上や安定化には限界がある。これは、ウニの行動生態が十分に解明されていないためと考えられる。

そこで本研究では、ウニの個体移動追跡と餌検出を行い、気象・海象データと組み合わせウニの行動生態を科学的に解析する。これにより、ウニ養殖においてデータに基づいた給餌手法を確立し、磯焼け解消に貢献するとともに、身入りの少ないウニに新たな価値を与え、地域の新たな食材として提供できることを目指す。

2. システム概要

本システムの概要図を図1に示す。養殖生簀に設置した観測機から、昼間は可視光、夜間は赤外線画像を撮影し、水温やDO（溶存酸素）量を取得する。収集した画像を基に、ウニの個体移動追跡と餌の検出を行うモデルを作成する。さらに、これらの結果とセンサーデータ、月齢を組み合わせウニの摂餌行動との関係を可視化する。得られた結果は給餌判定に活用し、WEBアプリケーション（ダッシュボード）で養殖者に提示する。

この分析により、勘や経験に頼らず、データに基づいた給餌・育成が可能になる。



図1 システム概要図

3. ウニの個体移動追跡

3.1 個体移動追跡の構築

ウニの移動量が餌の食いつきに与える影響を実験するため、ウニの個体移動追跡を実現する。

まず、ウニ検出 AI を機械学習で作成し、ウニの検出を行う。ウニ検出 AI の構築手順を図2に示す。撮影画像に物体検出技術を適用し、ウニを検出した。モデル構築には MobileNet SSD v2 使用し、ウニにタグを付けて学習させ、画像内のウニを検出する。次に、検出したウニに対して MOT (Multiple Object Tracking) のライブラリ「motpy」を用い、個体識別と追跡を行った。これにより、ウニの移動量を数値的に可視化することができる。

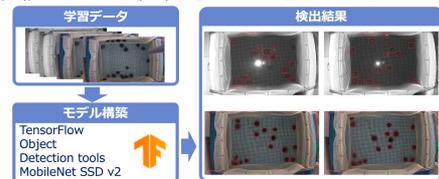


図2 ウニ検出 AI の構築の流れ

3.2 個体移動追跡の精度検証

ウニ検出 AI は、可視光と赤外線の2つのモデルを作成した。学習には、可視光1130匹・赤外線950匹分のタグ付けを行い、それぞれに15種類の水増しをランダムに適用し学習サンプルとした。検証には、可視光400匹・赤外線354匹分を使用した。検証結果を表1に示す。どちらのモデルも適合率と再現率が高く、養殖カゴの画像からウニを検出できることが確認できた。

個体移動追跡では、可視光・赤外線それぞれ180枚の連続した画像を使用して検証を行った。今回は MOT で広く使われる指標である MOTA (Multiple Object Tracking Accuracy) を採用した。表1のとおり、可視光では94.5[%]となり、赤外線では71.9[%]となった。赤外線の MOT が低くなった理由は、ウニ検出 AI の再現率が可視光に比べて低かったためと考えられる。

表1 ウニ検出 AI と個体移動追跡の精度結果 [%]

	ウニ検出 AI		個体移動追跡
	適合率	再現率	MOTA
可視光	98.9	97.0	94.5
赤外線	97.9	81.0	71.9

4. 餌の検出

4.1 餌検出 AI の構築

ウニの摂餌行動を把握するためには、誤検出を少なくし、餌の有無・餌量と餌の減少傾向を正確に算出する必要がある。そこで本研究では、計算負荷が少なく中間処理が明確な画像処理手法と入力画像の明るさや環境の変化に適応しやすい機械学習手法を用いて精度を比較する。

画像処理手法の流れを図3に示す。まず、入力画像を2値化し、ウニと餌・それ以外の領域に分類する。次に、個体移動追跡で作成したウニ検出 AI を適用し、ウニ領域を除去することで餌を検出する。

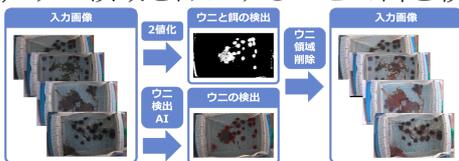


図3 画像処理手法の流れ

機械学習手法では、餌検出 AI を用いて餌を検出する。餌検出 AI の構築手順を図4に示す。入力画像に対して餌領域をセグメンテーションし、Pascal VOC 2012 で学習した Deeplab v3+ を用いて転移学習し、餌検出 AI を作成した。

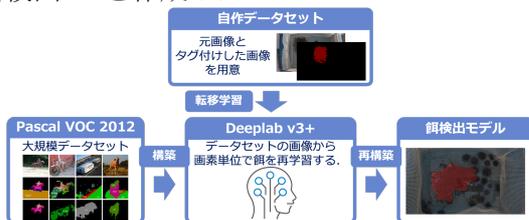


図4 餌検出 AI の構築の流れ

また、高水位では餌が不明瞭に写るため、水位の違いが識別精度に影響を与えると考えた。そのため、画像処理手法と機械学習手法で、高水位と低水位の2条件下で実験を行い、最も優れた手法を選定する。

4.2 餌検出 AI の精度評価

餌検出 AI のモデル構築では、高水位および低水位条件の可視光および赤外線画像を、それぞれ餌あり 50 枚ずつ使用した。検証には、モデル構築に使用した水位条件の可視光および赤外線画像を用い、餌ありおよび餌なしの画像をそれぞれ5枚ずつで実施した。摂餌解析では、餌量を正確に把握するため、IoU (Intersection over Union) に加え、FPR (False Positive Rate) を指標として評価を行った。

精度検証の結果を表2に示す。画像処理手法では餌の明度差により検出が困難な場合があり、IoU が低くなることがあった。一方、機械学習手法では明度差が多少あっても検出可能であり、画像処理手法より優れた結果が得られた。また低水位にす

ることで FPR が低下した。これにより、低水位の機械学習手法は誤検出が少なく、餌量を正確に算出できることが示唆された。また、餌の有無や減少傾向をより正確に把握できることが確認された。

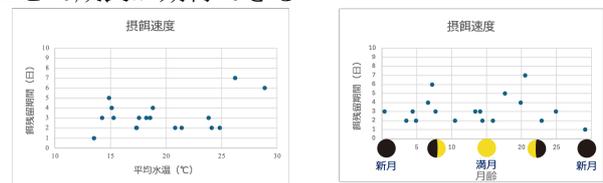
表2 餌検出手法の精度結果 [%]

		画像処理		機械学習	
		高水位	低水位	高水位	低水位
可視光	IoU	38.7	47.1	50.8	78.3
	FPR	1.7	1.8	5.6	1.5
赤外線	IoU	32.4	33.4	41.4	68.1
	FPR	14.2	1.0	7.2	0.5

5. 摂餌行動の解析

給餌を行う際に気象・海象の影響を考慮した摂餌行動に基づく給餌を実現するため、今回は水温、月齢、摂餌速度の関係を解析した。解析には 18 回分の給餌データを用いた。解析の結果を図6に示す。水温が 25°C に近づくと摂餌速度が向上し、25°C を超えると急激に低下することが確認された (図5 (a))。また、月齢が新月・満月付近で摂餌速度が上昇する傾向が示された (図5 (b))。

これらの結果から、ムラサキウニの蓄養には、水温 25°C 以下で給餌を行うことが望ましく、新月・満月付近が摂餌速度が高いため、給餌を行うことで成長が期待できる。



(a) 平均水温

(b) 月齢

図5 気象・海象による摂餌速度の変化

6. まとめと今後の課題

今回は、ウニの摂餌行動を可視化するために、個体移動追跡と餌の検出を実施し、水温・月齢による摂餌速度の解析を行った。個体移動追跡と餌の検出は高精度で構築できた。摂餌速度の分析では、水温が 25°C 以下で新月・満月付近に摂餌速度が向上することを確認した。今後は試験回数を増やして更なる検証を進めたい。

今後の課題として、実際に 25°C 以下の新月・満月付近で給餌を行い、他条件との比較での成長比較を検証していく。

参考文献

- [1] 水産庁, 『磯焼けガイドライン第3版』, https://www.jfa.maff.go.jp/j/gyoko_gyozyo/g_gideline/index.html, (2024年12月27日参照)