



Title	クロマグロ養殖生産管理効率化のためのモニタリング技術開発に関する基礎的研究
Author(s)	阿部, 悟
Citation	北海道大学. 博士(水産科学) 甲第14754号
Issue Date	2022-03-24
DOI	10.14943/doctoral.k14754
Doc URL	http://hdl.handle.net/2115/91073
Type	theses (doctoral)
File Information	Satoru_Abe.pdf



[Instructions for use](#)

クロマグロ養殖生産管理効率化のための
モニタリング技術開発に関する基礎的研究

(Fundamental Study on The Development of Monitoring Technology to Improve
the Efficiency of Bluefin Tuna Aquaculture Production Management)

北海道大学大学院水産科学院

海洋生物資源科学専攻

Graduate School of Fisheries Sciences

Division of Marine Bioresource and

Environmental Science

阿 部 悟

Satoru Abe

2022 年

目次

緒言	1
第1章 自動計数手法の基礎技術開発	5
1.1 背景処理手法	5
1.1.1 フレーム間差分法	5
1.2 ラベリング	6
1.3 KC法	6
1.4 解析結果の評価	8
1.5 屋内実験	9
1.5.1 屋内撮影機材	9
1.5.2 屋内撮影手順	10
1.5.3 屋内実験の解析結果および考察	10
1.6 屋外実験	11
1.6.1 撮影手法及び撮影機材	11
1.6.2 屋外実験の解析結果および考察	11
第2章 深層学習を応用した個体領域抽出手法の検討	26
2.1 セマンティックセグメンテーション	26
2.1.1 SegNet	26
2.1.2 SegNetの構築・解析環境	27
2.2 SegNetの構築	27
2.3 評価方法	28
2.4 評価結果及び考察	29
2.5 SegNetの検出性能に対する学習画像枚数の影響評価	30
2.6 SegNetの導入後のシステム性能の評価	31
2.7 新たなセマンティックセグメンテーション手法の導入の検討	31
2.8 DeepLab v3+によるラベリング性能の評価	33
2.9 DeepLab v3+の導入後のシステム性能の評価	33
第3章 運動解析部の再検討および撮影環境の影響評価	64
3.1 運動解析部におけるデータ入力方法の再検討	64
3.1.1 現行のデータ入力方法とその課題	64
3.1.2 現行のシステムと改良後のシステムの性能比較	64
3.2 撮影環境パラメータが計数システムに与える影響の評価	65
3.2.1 計測方法及び計測機材	65
3.2.2 評価方法	66
3.2.3 評価結果及び考察	66

第4章 養殖クロマグロの行動状態評価	77
4.1 個体の移動ベクトルを解析するための評価指標	77
4.2 評価指標を用いた養殖クロマグロの行動評価	78
4.2.1 台風接近時と平常時の比較	78
4.2.2 非給餌時と給餌時の比較	78
第5章 総合考察	88
5.1 自動計数手法の基礎技術開発	88
5.2 深層学習を応用した個体領域抽出手法の検討	89
5.3 運動解析部の再検討および撮影環境の影響評価	90
5.4 養殖クロマグロの行動状態評価	91
5.5 今後の課題及び展望	92
謝辞	94
参考文献	95

緒言

平成 28 年度水産白書によれば，一人当たりの魚介類の消費量は世界的に増加の一途を辿っており，特にアジア地域では新興国を中心にその傾向が顕著である。アジア地域では今後人口の増加が約 40 年にわたり続くと見込まれており，今後も人口増加に伴い水産物に対する需要も高まり続けると予想される。水産物に対する需要の高まりを満たすために，漁業・養殖業生産量もまた増加を続けているが，世界の漁船漁業生産量は 1980 年代後半をピークに概ね横ばいに推移しており，増加量の大半を養殖業に依存していて，2013 年には養殖業生産量が漁船漁業生産量を上回るようになった。今後とも高まり続ける水産物に対する需要を満たすためには，養殖生産による供給を安定して持続的に行う必要がある。中でも，国内における高級魚の代表格であるクロマグロは世界でも特に需要のある魚種の一つである。その高価な市場価値故に，近年，資源量の急激な減少が報告されており，中西部太平洋まぐろ類条約や TAC 制度によるクロマグロに対する世界的な漁獲規制強化に向けた機運が高まっている (Kitagawa, 2008; Masuma, 2008; Food and Agriculture Organization of the United Nations (FAO), 2018)。一方で，このようなクロマグロ資源の管理強化を背景に，閉鎖系でのクロマグロ養殖生産に関する研究が各国で盛んに行われている。特に日本では Sawada et al. (2005) による太平洋クロマグロ (*Thunnus orientalis*) の完全養殖の成功を契機に生産量が拡大を続けている (升間, 2019)。しかし，養殖生産による持続的な安定供給実現のためには多くの課題が存在する。特に養殖クロマグロの洋上生簀では，育成中の養魚に対して，体長や尾数，健康状態，適切な給餌量・タイミングなど養殖管理上のバロメーターが重要となるが，これらを正確に把握することは困難である。また，特に国内では一般的に漁業・養殖業従事者の高齢化加速が指摘されている。このような問題に対応するためには養殖業のスマート化が急務であり，魚のバイオマスや現存数のモニタリングが重要である (Li et al., 2019)。

従来のクロマグロのモニタリング手法は，主に VICASS や AQ1AM100 のような水中ステレオビデオカメラシステムが商業的に使用されてきた (Shortis, 2019)。しかし，これらの手法は主に手動操作によって魚を認識し，精度を担保しているため，尾数計数に膨大な時間と人件費を要する。尾数の自動計数手法としては，ソナー画像や音響カメラを用いる手法 (Jing et al., 2017; Martignac et al., 2015; Liu et al., 2018) やマルチ送受波ソナーとピンガーを用いた手法 (Hamano et al., 2018)，水路や河川に電極を設置し，電気抵抗の変化の有無から推定する手法 (Thorley et al., 2005; Gonda et al., 2014)，水中カメラで撮影した映像を解析する手法 (Terayama et al., 2016) など様々な技術を利用した実験

的手法が提唱されている。これらのうち、電気抵抗の変化を利用した手法はサケの遡上を計数する用途で古くから欧米で用いられてきた手法であり、河川や水路のように魚の遊泳方向が一定な環境下では効果が期待できるが、生簀内の養魚の遊泳方向は時空間的に同一方向であるとは限らないため、導入は困難であると考えられる。音響手法や画像解析手法については、音響データや画像データの解析技術の進歩によって、様々な魚の認識手法が提案されている。Melvin (2016) は自然環境下でのクロマグロの集団遊泳行動をモニタリングするためにマルチビームソナーを利用した。Boudhane et al. (2017) は音響データと映像データとを組み合わせることによって、対象魚の認識追跡性能とロバスト性の向上を試みた。Rosen et al. (2013) は、商業漁業における漁獲選択制の向上を目的として、ステレオカメラシステムを用いてトロール網開口部を通過した魚の種類と体サイズを推定する手法を開発した。養殖技術に関する研究としては、Torisawa et al. (2011) はクロマグロの三次元位置を DLT 法 (Abdel-Aziz et al., 1971) によるステレオカメラ計測を用いて可視化した。Costa et al. (2009) はステレオカメラシステムにニューラルネットワークを導入することを試みた。同様の試みとしては、Ravanbakhsh et al. (2015) や Muñoz-Benavent et al. (2018) による生簀内のクロマグロの体長測定を行うためにステレオカメラシステムを用いた自動測定手法が知られている。養魚の遊泳に関する研究としては、Abe et al. (2018) はクロマグロの稚魚のバースト遊泳を検出するためのモニタリング手法を開発し、Kadota et al. (2018) はクロマグロの稚魚が水槽に衝突する確率を評価することを目的として、魚の行動軌跡を解析することで行動予測モデルを開発した。著者らもまた、閉鎖空間内の養殖魚の計数を目的とした、個体の追跡手法の開発手法に取り組んできた (Abe et al., 2017)。古典的な画像処理と時系列的な動体解析とを組み合わせることによって、動画内の個々の魚を自動で抽出し、それぞれの移動軌跡の算出を実験室レベルで実現した。

一方で、これらの手法が依然として実験的思考にとどまっている原因としては、音響計測の場合は尾数計数への導入が試みられる音響カメラやマルチビームソナーが高価である点や、一度に解析可能な範囲や分解能に限界がある点が導入障壁となっていると考えられ、画像計測の場合は画像上で魚同士が重なってしまう場合には検出精度が低下してしまうという点が課題としてあげられる。画像上の重なりが生じた際の対処法は複数考案されているが現在も研究段階にあり、養殖生簀内で養魚を計数する用途には技術的課題が残されている (Dolado et al., 2015; Rodriguez et al., 2017)。また、クロマグロ養殖ではその生産管理のために特に生簀内尾数を恒常的かつ正確に把握する必要があるこ

とから、生簀内尾数を自動計数することが生産業者から強く求められているが、本種の養殖においては、ふ化後一ヶ月程度の幼魚が海上養殖網生簀内で養成されることが一般的なため、複雑な背景やノイズの影響、照度が大きく変化するなかで、計数のために個体の認識が必要とされるような状況が発生し、従来の画像処理手法では十分なロバスト性を担保できないことが懸念される。この課題に対して、近年は様々な機械学習手法の適用を、特に画像分析に試みる研究が多く見受けられる。さまざまな撮影環境下における水中モニタリングにおける魚の検出性能向上のため、Marini et al. (2018) は教師あり学習を使用し、Cheng et al. (2018) や Huang et al. (2018), Salman et al. (2019), Liu et al. (2019) は深層学習の適用を試みた。Li et al. (2018) は自然環境下での魚のリアルタイム追跡性能を追究するために、kernelized correlation filter (Henriques et al., 2015) の導入を試みた。漁業・養殖業への応用例としては、Yang et al. (2018) はマグロ類の IUU (illegal, unreported, and unregulated) 漁業対策として深層学習を利用した漁業監視システムを提唱し、Hu et al. (2020) は水揚げされたイカの種類と鮮度の判定に深層学習の適用を試みた。Kakehi et al. (2021) はカキの幼生を正確に識別・計数するために深層学習を利用した物体検出技術を開発した。しかし、深層学習を用いて魚を検出する場合、ほかの教師学習のように学習させる特徴量を人間が定量的に選択しているわけではないため、教師データに含まれる特徴のどの部分を手掛かりに対象を認識しているかが不明瞭である。そのため、解析結果のロバスト性を担保することが困難であると考えられる。

そこで、本研究では主に工学分野で流体の可視化に活用されている PTV (Particle Tracking Velocimetry) 解析技術に着目し、当該技術を閉鎖空間内の養殖魚のトラッキングや計数に応用できないか検討することにした。PTV 解析技術は、流体内に懸濁させた微小粒子を追跡することにより流れを可視化する技術で、Takehara et al. (1996) は PTV 解析のために流体内の多数の微粒子を自動で追跡しその移動ベクトルを推定するアルゴリズム：KC 法 (The Kalman filter and Chi-square Test) を提案した。魚を PTV 解析における微小粒子に見立てることによって個体のトラッキングや運動解析に応用可能ではないかとの作業仮説を立てて、魚群を構成する個体を追跡することによって、移動ベクトルの計数から画像上の魚の自動計数を検討するとともに、追跡時に得られる魚群構成個体の移動軌跡を解析することにより、養殖対象魚の状態評価を画像情報から取得するための基礎知見を得ることを試みた。具体的には、洋上生簀内の養殖クロマグロを対象に、生簀内の養魚の自動計数・状態評価を可能とするシステムを開発し、そのシステ

ムがロバスト性を発揮できる条件を探索することによって、クロマグロ養殖の生産管理効率化を実現するモニタリング手法を提案することを本研究の目的とする。

本研究では、まず、第 1 章において古典的な画像処理手法と KC 法を用いた個体計数手法を紹介し、実際の養殖クロマグロのデータを解析することでその性能の評価を行った。次に、第 2 章で個体情報の抽出効率向上を図るために、予め定義したクラスに対して、画像を構成する各画素がどのクラスに属しているのかを推定する技術であるセマンティックセグメンテーションを画像処理部に導入することを検討した。セマンティックセグメンテーション手法として導入が容易である SegNet (Badrinarayanan et al., 2017) と、より複雑な手法である DeepLab v3+ (Chen et al., 2018) について、それぞれの単体としての性能と個体係数手法に組み込んだ際の性能とを第 2 章で紹介した従来法と比較してそれぞれ評価した。第 3 章では、画像処理部の出力データを運動解析部に入力する際の入力方法について改良を試みることで、第 2 章で明らかになった運動解析部の課題解決を図った。また、提案手法に対する撮影環境が与える影響について検討を行い、提案手法で自動計数を試みるうえでの最適なパラメータを調査した。第 4 章では、提案手法で得られた各個体の追跡データに対して、独自に設けた指標について解析を行い、行動評価の実現性を検討した。最後に、第 5 章では総合考察として本論文をまとめるとともに、今後の課題と展望について議論した。

第1章 自動計数手法の基礎技術開発

世界的な水産物に対する需要の高まりを背景に、養殖生産による持続安定的な供給が求められているが、効率的な養殖管理手法の確立には未だ課題が多く残されている。養殖魚の管理には生簀内のモニタリングが重要であると考えられ、特に洋上生簀では従来は人の目視によって養魚が計数されてきたため多大な労力を必要とし、尾数把握の自動化は開発要求として大きなテーマの一つとなっている。そこで、本章では、養殖生簀内のモニタリングや養魚管理システムの自動化を検討するために、水中カメラ計測によって得られた映像を解析し、生簀内に存在する魚の自動計数を実現するシステムの構築を目指すものとする。魚群を構成する養魚の自動計数を実現するにあたって、流体中のトレーサー粒子をカメラで撮影することによって、各時刻における個々の粒子位置を解析し、時系列の前後で粒子の同定を試みることによって個々の移動軌跡を算出することで対象領域の流況を近似する PTV (Particle Tracking Velocimetry) 解析の追跡アルゴリズムに着目し、これを、生簀内養殖魚の個体数計数に応用することを試みた。

1.1 背景処理手法

背景差分法とは、移動物体を検出する際に、移動物体が存在しない画像を背景画像とし、検出対象の画像から背景画像を差分することで、差分画像を作成し、その後に差分画像を2値化することで移動物体を前景領域として抽出する手法である。本研究では画像処理部で個体候補領域を抽出するにあたって、まず撮影画像から水槽の壁面などの個体（生簀内養殖魚）と関係のない背景情報を取り除く必要がある。狭義の意味での背景差分法では、事前に背景画像を撮影する必要があるが、移動物体が存在しない背景画像を撮影できない場合が想定される。本節では背景領域を除去して前景領域を抽出するにあたって、背景画像を取得するために別途撮影をする手間のないような手法を検討する。具体的には、背景差分法を基盤とし、差分後に輝度値で2値化処理を行う、フレーム間差分法について検討を行う。

1.1.1 フレーム間差分法

フレーム間差分法とは差分の際に背景画像を用いずに、連続するフレーム間で差分をとることで前景領域を抽出する背景差分法である。背景の変化が少ない場合、フレーム間隔を魚の移動量に対して十分に大きく確保することで、適切に前景を抽出することができる。差分後の画像に対しては、Otsu 法あるいは大津の2値化と呼ばれる2値化処理を行う (大津 1980)。Otsu 法では、画像の輝度ヒストグラムを二つのクラス

に分割する場合に、それぞれのクラス分離度が最大となるような閾値 t を自動決定する。全体の画素の輝度値の平均と分散を m_t, σ_t^2 、それぞれのクラスの平均を m_1, m_2 、分散を σ_1^2, σ_2^2 、それぞれのクラスに属する画素数を ω_1, ω_2 とすると、クラス内分散 σ_w^2 とクラス間分散 σ_b^2 を次式で表すことができる。

$$\sigma_w^2 = \frac{\omega_1 \sigma_1^2 + \omega_2 \sigma_2^2}{\omega_1 + \omega_2} \quad (1.1)$$

$$\sigma_b^2 = \frac{\omega_1(m_1 - m_t)^2 + \omega_2(m_2 - m_t)^2}{\omega_1 + \omega_2} = \frac{\omega_1 \omega_2 (m_1 - m_2)^2}{(\omega_1 + \omega_2)^2} \quad (1.2)$$

また、全分散 σ_t^2 はクラス内分散 σ_w^2 とクラス間分散 σ_b^2 を用いて次式で表すことができる。

$$\sigma_t^2 = \sigma_w^2 + \sigma_b^2 \quad (1.3)$$

(1.3)式から、閾値 t に関係なくは一定となるため、クラス分離度 $\eta(t)$ が次式で定義でき、クラス分離度 $\eta(t)$ を最大とするためにはクラス間分散 σ_b^2 が最大となればよいことがわかる。

$$\eta(t) = \frac{\sigma_b^2}{\sigma_w^2} = \frac{\sigma_b^2}{\sigma_t^2 - \sigma_b^2} \quad (1.4)$$

画像ごとに異なる閾値を自動決定することができるため、照度が時間変化していくような場合でも適切に2値化が行うことが期待できる。

1.2 ラベリング

フレーム間差分法によって得られた2値画像に対してラベリングを行うことで個体候補領域を抽出する。ラベリングとは、ラスタスキャンを行って連結領域それぞれにラベルを付けていくことで連結領域を抽出する手法である。この時、画像上の微小ノイズを取り除くために、任意に閾値を設け、閾値以上の面積を有する領域のみを抽出し、その領域を個体候補領域とする。個体候補領域それぞれに対して領域の面積重心を計算し、その重心座標を個体候補位置座標として出力する。

1.3 KC法

前節で出力した個体候補位置座標を基に運動解析部でフレーム間での個体の移動ベクトルを算出する。移動ベクトルを算出するにあたって、KC法 (Kalman filter and the Chi-square test) を用いてフレーム間での同一個体の同定を行う (竹原ら 1996)。KC法は、線形カルマンフィルターと χ^2 検定とを利用した PTV 解析のために開発された自

動粒子追跡アルゴリズムで、現時刻で観測された個体の画像上での位置情報を基に次時刻の個体の位置情報を線形カルマンフィルターによって予測し、次時刻で実際に観測された個体の位置情報と予測した個体位置情報とが同一である確率を χ^2 検定によって評価することによって同一個体の対応付けを行うことを可能とする。

一般的に線形カルマンフィルターによる状態空間表現は、次式によって表すことができる。

$$h(t+1) = F(t+1;t)h(t) + \xi(t) \quad (1.5)$$

$$m(t+1) = H(t)h(t) + \zeta(t) \quad (1.6)$$

ここで、(1.5)式が状態方程式、(1.6)式が観測方程式を表す。 $h(t)$ は時刻 t における状態量ベクトルで、本研究においてはカルマンフィルターによる予測位置を表す。 $m(t)$ は時刻 t における観測量ベクトルで、本研究においては時刻 t の画像における個体候補位置座標を表す。 $F(t+1;t)$ は状態遷移行列、 $H(t)$ は観測行列、 $\xi(t)$ 、 $\zeta(t)$ はそれぞれ誤差ベクトルを表している。カルマンフィルターでは状態量ベクトルの最小二乗推定値を観測量ベクトル $m(t)$ に基づいて逐次推定し、次時刻 $t+1$ における状態量の最適推定値 $\hat{h}(t+1;t)$ を予測することができる。

最適推定値 $\hat{h}(t+1;t)$ を計算するにあたって、まずカルマンゲイン $K(t)$ を計算する。

$$K(t) = \frac{P(t;t-1)H^T(t)}{H(t)P(t;t-1)H^T(t) + R(t)} \quad (1.7)$$

この時、 $P(t;t-1)$ は時刻 t における事前誤差共分散行列、 $R(t)$ は観測方程式での誤差の分散行列である。次に、カルマンゲインを用いて時刻 t における状態推定値 $\hat{h}(t;t)$ を次式で計算する。

$$\hat{h}(t;t) = \hat{h}(t;t-1) + K(t)[m(t) - H(t)\hat{h}(t;t-1)] \quad (1.8)$$

状態推定値 $\hat{h}(t;t)$ と状態遷移行列 $F(t+1;t)$ を用いることで、次式から最適推定値 $\hat{h}(t+1;t)$ を算出する。

$$\hat{h}(t+1;t) = F(t+1;t)\hat{h}(t;t) \quad (1.9)$$

続いて、逐次計算を次時刻で行うために、事後共分散行列 $P(t;t)$ を次式で計算する。ここで、事後共分散行列 $P(t;t)$ は状態量の真値と推定値の差 $h(t) - \hat{h}(t;t)$ の共分散行列である。

$$P(t;t) = P(t;t-1) + K(t)H(t)P(t;t-1) \quad (1.10)$$

最後に、時刻 $t+1$ における事前共分散行列を次式で計算する。

$$P(t+1; t) = F(t)P(t; t-1)F^T(t) + Q(t) \quad (1.11)$$

ここで、 $Q(t)$ は状態方程式での誤差の分散行列である。

これ以降は式(1.7)～(1.11)を繰り返すことによって、次ステップの状態量ベクトルを予測する。

次に、カルマンフィルタによって予測された粒子位置と実測された粒子位置を基に、同一粒子の対応付けを行うために、 χ^2 検定による粒子の対応確率の客観的評価を行う。時刻 $t+1$ における観測値 $\{x(t+1), y(t+1)\}$ の存在確率はカルマンフィルタによって推定された最適推定値 $\hat{x}(t+1; t), \hat{y}(t+1; t)$ の周囲に正規分布していると考えられるため、次式が成り立つ。

$$\chi_x = \frac{x(t+1) - \hat{x}(t+1; t)}{\sigma_x} \quad (1.12)$$

$$\chi_y = \frac{y(t+1) - \hat{y}(t+1; t)}{\sigma_y} \quad (1.13)$$

χ_x, χ_y はそれぞれ平均値 0、標準偏差 1 の規準化正規分布に従うため、その 2 乗値は自由度 1 の χ^2 分布に従う。 χ^2 分布は再生性を有するため、次式は自由度 2 の χ^2 分布に従う。

$$\chi_t^2 = \chi_x^2 + \chi_y^2 = \frac{[x(t+1) - \hat{x}(t+1; t)]^2}{\sigma_x^2} + \frac{[y(t+1) - \hat{y}(t+1; t)]^2}{\sigma_y^2} \quad (1.14)$$

この時、(1.14)式で用いる標準偏差は対応する事後共分散行列の値を近似的に用いることができる。

1.4 解析結果の評価

1.1 ～ 1.3 で行った解析をまとめた模式図を Fig. 1-1 に示した。ここでは、フレーム間差分法を用いた場合を従来法と呼称して評価を行なう。解析に使用した環境は、画像処理・描画には MATLAB R2017b を、KC 法のアルゴリズムには Visual C++ 2017 をそれぞれ使用した。解析に用いた画像は、撮影した動画を 10 FPS で分割することに

よって作成し、作成した画像のうち 10 秒間に相当する 100 枚の画像を解析に用いた。

解析結果を評価するにあたって、検出結果の正確性の指標である適合率 P と、検出結果の網羅性の指標である再現率 R との調和平均である F 値を用いた。この時、適合率 P と再現率 R 、 F 値は次式で定義される。

$$P = \frac{\text{正解していた個体数}}{\text{検出できた個体数}} \quad (1.15)$$

$$R = \frac{\text{正解していた個体数}}{\text{画像内の全個体数}} \quad (1.16)$$

$$F = \frac{2RP}{R + P} \quad (1.17)$$

定義上、適合率 P と再現率 R は 0 以上 1 以下の値を取るため、 F 値もまた 0 以上 1 以下の値を取り、一般に F 値の値が高いほど検出性能が優れていることを意味する。

1.5 屋内実験

前節までで構築した従来法を用いて閉鎖空間内を遊泳する魚群の個体数が計数可能かを検証するために、水槽実験を屋内で実施した。

1.5.1 屋内撮影機材

実験魚には市販のヒメダカ (*Oryzias latipes*) 250 尾を利用した。n=10 尾で抽出した実験魚の平均体長は 2.99 cm、標準偏差は 0.159 cm であった。実験水槽には 640 mm×460 mm 容積 100 L のパンライト水槽を用いた。水槽外の環境に由来する影響を最小限にするために、Fig. 1-2 右の写真に示したように水槽壁面及び開口部をガラスウールでコーティングした。また、撮影機材には Kodak 社製 PIXPRO SP360 に防水用アタッチメントを使用した。このカメラの特徴として、魚眼レンズを採用しているため 360 度の視野を確保することができ、撮影時に死角が少ない点が挙げられる。一方、得られる画像は大きく歪んでしまうが、本論文では個体サイズの画像計測は行わないため、歪みの影響を無視して解析を行った。魚眼レンズの特性で画像上の被写体はカメラの仕様については Table 1-1 に示した。

1.5.2 屋内撮影手順

パンライト水槽にヒメダカを放流し、水槽中央部の水底に水面に向けてカメラを設置し、水槽開口部をガラスウールで覆い、1440×1440 px、30 FPS で約2時間にわたって撮影を行った。この時、実験魚への影響を考慮して撮影開始後30分以上経過した動画を解析対象とし、対象魚の動体検出を容易にするために2 FPS のサンプリングレートで静止画を出力し、解析を行った。

1.5.3 屋内実験の解析結果および考察

撮影した動画から、Fig. 1-3 のような静止画を出力した。この画像を解析画像として、背景処理を施したもののラベリング結果と KC 法による出力結果を描画したものの一例を Fig. 1-4 に、検出性能の評価結果を Table 1-2. にそれぞれ示した。Fig. 1-4 では、画像処理部で抽出された個体領域を緑色の矩形で囲んで示し、運動解析部で計算された個々の移動ベクトルは青い矢印で示した。以後、個体領域を示す矩形をバウンディングボックスと呼称する。ここで、表にまとめられている数値は画像100枚の解析結果を平均したものを示している。また、構築した撮影系では水槽底部に一部死角が生じたため、水槽底部付近を遊泳するヒメダカを画角に収めることができなかつたため、撮影画像ごとに撮影できたヒメダカの数にばらつきが生じた。

Table 1-2 について、抽出した個体候補領域について着目すると、抽出できた個体候補領域の数が多いほど推定個体数が多く、 F 値の値が高いことから、KC 法で移動軌跡を算出する際には個体候補領域を多く見積った場合に検出性能が向上すること、また同時に実際の尾数以上に過大に個体候補を見積もった場合であっても、KC 法によって移動個体を適切に抽出できることが確認できた。

F 値と再現率について優れた結果を示す一方で、適合率 P の値が最も低い点について考える。再現率 R は実測尾数に対する正しく抽出できていたヒメダカの数割合を表しているため、再現率 R が最も高いということは抽出できたヒメダカの数最も多かったことを意味する。適合率 P は推定個体数に対する正しく抽出できていたヒメダカの数割合を表しているため、適合率 P が最も低いということは検出結果の正答率が最も低いことを意味する。このことから、従来法は正答率を検出数で補っている手法であると言える。また、再現率 R と比較して適合率 P の値は手法間での優劣差が小さいため、 F 値が高い値になったと言える。水面に生じる波などの動的背景については、動的背景による背景変化がフレーム間で比較すると軽微であるため、検出結果への影響が少なく済んだものと考えられる。

室内実験においてはいずれの評価指標についても値が 0.9 以上であることから、KC 法を移動個体の追跡に利用できることが期待でき、尾数カウントシステムの基盤アルゴリズムとして有望であると言える。一方で、背景変化がより乏しいような環境に関しては必ずしも従来法を適用することが最適ではないこと、同様に動的背景の影響が大きいような環境に対しては、提案手法による画像処理のみでは不十分である可能性が示唆された。これらを踏まえて次節では、提案手法の実環境への可用性について主眼に置いて議論を行う。

1.6 屋外実験

前節で構築した従来法を基に、実際の養殖場で使用されている養殖生簀内の養殖魚を対象として屋外実験を行い、実環境における個体抽出・計数の評価を行った。

1.6.1 撮影手法及び撮影機材

撮影は近畿大学水産研究所奄美実験場のクロマグロ養殖生簀で 2018 年から 2021 年の間に計 9 回実施した。対象とした生簀は①直径 30 m×深さ 23 m (2018-2019) と②直径 20 m×深さ 15 m (2020-2021) の 2 種類で、Fig. 1-5 と Fig. 1-6 に①の生簀の外観と概略図を示した。撮影機材は GoPro HERO6 Black に INON 社製コンバージョンレンズ UFL-G140 SD を取り付けることで撮影視野の拡張を試み (Fig. 1-7)、Fig. 1-6 に示すように生簀底部中央にカメラの視軸が鉛直上向きになるよう設置し、4000×3000 px, 30 FPS で動画を撮影した。

1.6.2 屋外実験の解析結果および考察

撮影した動画から、サンプリングレート 6 FPS で Fig. 1-8 のような静止画を出力した。この画像を解析画像として、背景処理を施したもののラベリング結果と KC 法による出力結果を描画したものの一例を Fig. 1-9 に、検出性能の評価結果を Table 1-3 にそれぞれ示した。ここでは画像処理部の抽出結果を緑のバウンディングボックスで、運動解析部の計算結果を緑の矢印ベクトルでそれぞれ示した。ここで、表にまとめられている数値は画像 10 枚の解析結果を平均したものを示している。

Fig. 1-9 の描画結果から、画像中の個体の大半に対してバウンディングボックスがプロットできていないことから、解析画像に対する画像処理部でのラベリングが適切に実施されていないことが確認できる。また、画像ごとのラベリングのロバスト性を確認するために Fig. 1-9 の次のフレームの解析結果を確認すると (Fig. 1-10)、連続フレーム間で抽出に成功している領域の数が不安定であることが読み取れる。

Table 1-3 から、 F 値と再現率 R が屋内実験の結果と比較して半分以下に低下していることが確認できる。再現率 R が低いことと Fig. 1-9, Fig. 1-10 の結果から、養殖生簀内のクロマグロを抽出するにあたって、従来法のフレーム間差分による領域抽出が適していないことが読み取れる。原因としては、照度や濁度など、屋内撮影では考慮されていなかった撮影環境の影響を受けている点、屋内実験と比較して解析対象空間が大きいことから、対象魚の画像上の見え方が大きく変動しうる点などが考えられる。一方で適合率 P の値が 0.9 以上であることから、画像処理部の抽出結果に対する運動解析部での追跡性能は当初の期待通り発揮できていると考えられる。

以上から、従来法では画像処理部がシステム全体のボトルネックとなっており、性能向上に向けて領域抽出手法の再検討が必要であると考えられた。

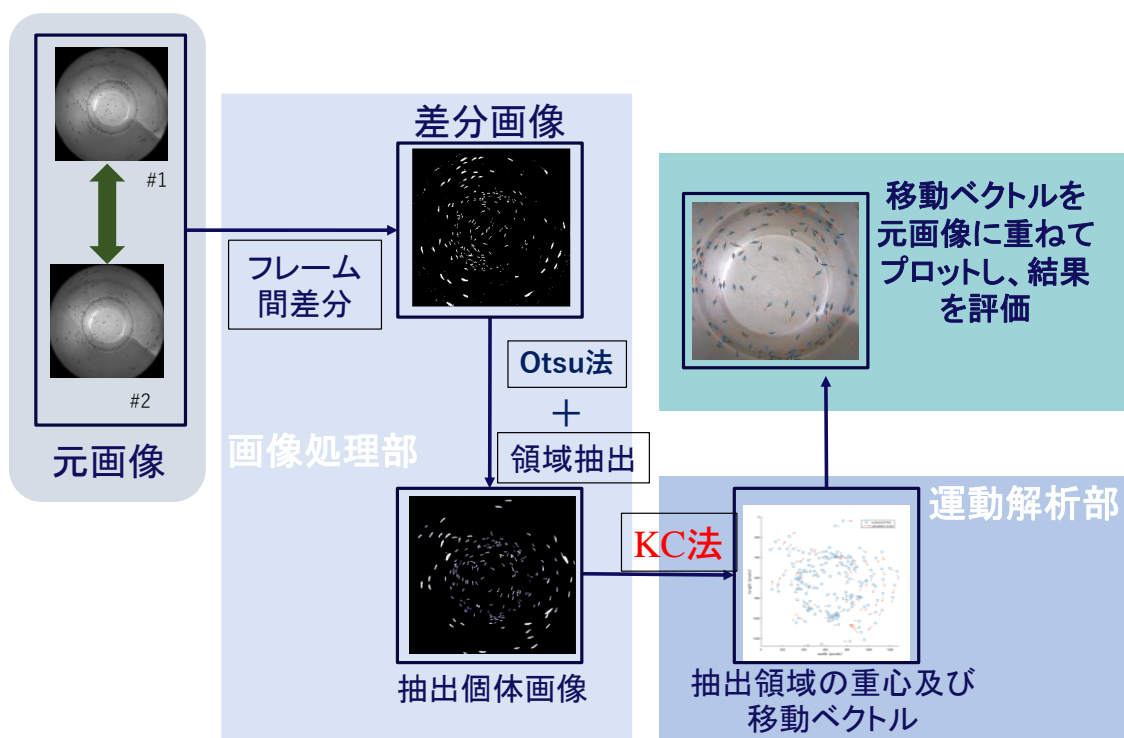


Fig. 1-1. フレーム間差分を利用した自動計数システムの解析フロー



Fig. 1-2. 左 : PIXPRO SP360, 右 : 実験で使用したパンライト水槽




Fig. 1-3. 屋内実験の解析画像の一例




Fig. 1-4. 画像処理部によるラベリングと運動解析部によるベクトルの描画結果の一例



Fig. 1-5. 実験で用いた養殖生簀




Fig. 1-6. (a) Schematic of the aquaculture net cage with the GoPro attached. (b) Schematic of GoPro installed at the bottom of the net cage with its visual axis facing directly upward.



Fig. 1-7 撮影に用いた GoPro HERO6 Black 及びコンバージョンレンズ UFL-G140 SD



Fig. 1-8. 屋外実験の解析画像の一例




Fig. 1-9. 画像処理部によるラベリングと運動解析部によるベクトルの描画結果の一例




Fig. 1-10. Fig. 1-9 の次のフレームに対する画像処理部によるラベリングと運動解析部によるベクトルの描画結果の一例

Table 1-1. PIXPRO SP360の仕様

イメージセンサー	タイプ	1/2.33型(CMOS)
	有効画素数	1636万画素
	総画素数	1752万画素
レンズ	焦点距離	0.805mm
	35mmフィルム換算	8.25mm
	解放F値	F2.8
	レンズ構成	7群9枚
	光学ズーム	無し（固定焦点），214度
	撮影範囲	50cm ~ ∞
撮影解像度		1440 × 1440 pixels

Table 1-2. 屋内実験に対する検出性能

抽出した個体候補領域	212
推定個体数	179
再現率R	0.948
適合率P	0.977
F値	0.962
実測尾数	185

Table 1-3. 屋外実験に対する検出性能

抽出した個体候補領域	48
推定個体数	38
再現率R	0.334
適合率P	0.906
F値	0.447
実測尾数	103

第2章 深層学習を応用した個体領域抽出手法の検討

流体の可視化技術である PTV 解析による魚の追跡・計数の応用可能性を検討した第1章では、撮影環境をコントロール可能な屋内水槽においては計数可能である一方、実際の養殖生簀内の計数実現に対しては従来法の画像処理部の抽出性能向上が必要であることが確認された。そこで第2章では、第1章で構築した画像処理部のロバスト性を向上させるべく、深層学習を応用したセマンティックセグメンテーションの導入を検討した。

2.1 セマンティックセグメンテーション

セマンティックセグメンテーションとは、事前に定義したオブジェクトクラス別に画素レベルで画像を塗り分けるセグメンテーション手法である。深層学習の台頭による技術革新は、手書き文字認識から医療診断まで、幅広い分野に貢献している (Jaderberg et al., 2016; Esteva et al., 2017; Panwar et al., 2020)。特にセマンティックセグメンテーションに対する深層学習手法の適用は前述の分野や自動運転支援技術をはじめとする先進技術の開発に大きく寄与している (Liu et al., 2020; Jadon et al., 2020)。

2.1.1 SegNet

SegNet とは深層学習を利用することで、任意に定義したラベル毎に画像を画素単位での分割・分類を実現可能とする技術である。Tang et al. (2020) は実際に SegNet を用いて空中ドローンで撮影した映像から湿地植生情報の抽出を試みた。SegNet では、教師画像として RGB 画像と、検出対象クラス毎に事前に塗り分けたラベリング画像のペアを利用する。SegNet の基本構造を Fig. 2-1 に示す。SegNet は Encoder - Decoder のペアから構成されており、RGB 画像の入力に対して Encoder で局所特徴量の抽出と特徴量のダウンサンプリングを繰り返すことで低解像度特徴マップを作成し、Decoder でアップサンプリングすることでクラス毎に塗り分けられた出力画像が得られる。ここでの Decoder の役割は、低解像度の Encoder 特徴マップを、画素レベルでの分類に必要な完全な入力解像度特徴マップにマッピングすることである。具体的にはまず、Decoder と対応する Encoder の max-pooling step で計算された pooling index を利用して非線形アップサンプリングを行うことにより、アップサンプリングを学習する必要がなくなる。出力された低密度アップサンプリングマップに対して、学習可能なフィルタを用いて畳み込み、密な特徴マップを生成する。学習に際しては、事前定義したラベリング画像と出

力画像を比較し、画素単位での誤差をフィードバックし、誤差が最小となるように学習が進む。SegNetでは、EncoderとDecoderのペアを複層に積み上げることで抽出される低解像度特徴マップをより低解像度に凝縮させることが可能である。Fig. 2-2に具体的な2ペア及び3ペアのSegNetのネットワーク構造を示す。Encoder - Decoderのペアを積み上げる際、Fig. 2-2のように入れ子式に新しいEncoder - Decoderが内挿される。

2.1.2 SegNetの構築・解析環境

構築及び解析環境として、2台のPCを併用した(Table 2-1)。一般的に深層学習ではGPU上で計算を行うほうがCPU上で計算を行う場合と比較して高速であるが、GPU上で計算を行う場合、計算メモリにGPUメモリ以外使用できない。すべての教師データがGPUメモリ上に格納可能な場合のみGPU上で計算を行うことができるため、教師データに用いる画像サイズを計算環境に応じて調整する必要がある。そのためSegNetの学習をGPU上で行うために低解像度の画像を教師データとして用い、学習済みのSegNetを高解像度のバリデーション画像を用いて検証する際にはCPU上でSegNetの計算を行った。また、SegNetの構築にはMATLAB R2019aを使用し、MATLAB上でのGPUによる計算を有効化させるために、NVIDIA社が提供しているGPU向け統合開発環境CUDAを導入した。

2.2 SegNetの構築

撮影した映像から任意の区間を設定し、サンプリング画像それぞれを 10×10 に等分割し、計560枚の教師画像のデータセットを作成した。データセットは一枚の分割画像に一尾以上のクロマグロ個体が含まれているような個体画像と、マグロが一切含まれていない背景画像の比率が7:3になるようにそれぞれ選択し、MATLABでラベル付けを行うことで教師画像のペアを作成した(Fig. 2-3)。学習に用いた計算条件をTable 2-2に示した。また、Fig. 2-4に深層学習の基礎的構造であるパーセプトロンを用いて深層学習の学習アルゴリズムを示す。パーセプトロンは動物のニューロン構造を模したものであり、図に示した重み w_n 更新することで、損失関数の値が小さくなるように調整する手法を最適化アルゴリズムと呼ぶ。今回採用したRMSprop(Tieleman et al., 2012)は、最適化するにあたって、直近の学習によって得られたパラメータ勾配の二乗和のみを利用して計算を行う手法である。

深層学習では教師画像1枚毎にパラメータを更新していくと要求される計算コストが跳ね上がるため、少数のサンプルごとにグループを作成し、1グループ毎に更新を行

う。このグループをミニバッチと呼び、ミニバッチサイズとは1つのミニバッチに内包される教師画像枚数を表す。全てのミニバッチが学習されるまでのサイクルを **epoch** と呼び、ミニバッチ間のばらつきを標準化するために1 **epoch** 毎に教師画像をランダムにシャッフルしてからミニバッチを作成する。

1 - 8 ペア構造の **SegNet** をそれぞれ **Net1 - Net8** と定義し、前述の計算条件で学習を行い、**SegNet** を構築した。ペア構造が大きくなるほど計算終了までに時間を要し、**PC_B** を用いて最大で13時間、1000 **epoch** 程要したため、各ペア構造での **epoch** 数を1000 **epoch** で統一した。

2.3 評価方法

異なるペア構造ネットワークの結果を検証するために、バリデーションデータとして教師画像とは別に439枚のデータセットを用意した。バリデーションデータを評価する指標としては **Accuracy**, **Intersection over Union (IoU)**, **Boundary F1 (BF)** スコアの3つを使用した。**Accuracy** は正しく分類されたピクセルの数(手動でラベル付けした画像で定義)の、クラス内のピクセルの総数に対する比率である。したがって、クロマグロを対象とする個体の画素の **Accuracy** と背景画素の **Accuracy** は次のように表すことができる。

$$Accuracy_{tuna} = \frac{cdtp}{atpi} \quad (2.1)$$

$$Accuracy_{background} = \frac{cdbp}{abpi} \quad (2.2)$$

ここで、 $cdtp$ は正しく検出された個体の画素の総数、 $cdbp$ は正しく検出された背景画素の総数、 $atpi$ はバリデーションデータとして用意された画像中の全個体の画素の総数、 $abpi$ は画像中の全背景画素の総数である。

$Accuracy_{mean}$ と $Accuracy_{global}$ は次式で求められる。

$$Accuracy_{mean} = \frac{(Accuracy_{tuna}) + (Accuracy_{background})}{2} \quad (2.3)$$

$$Accuracy_{global} = \frac{cdtp + cdbp}{atpi + abpi} \quad (2.4)$$

IoU は、残存画素の総数に対する正しく分類された画素数の比率として定義される。したがって、 IoU_{tuna} と $IoU_{background}$ は以下のように決定される。

$$IoU_{tuna} = \frac{cdtp}{atpi + adtp - cdtp} \quad (2.5)$$

$$IoU_{background} = \frac{cdbp}{abpi + adbp - cdbp} \quad (2.6)$$

ここで、 $adtp$ は個体の実検出画素数、 $adbp$ は背景の実検出画素数である。

IoU_{mean} は、 IoU_{tuna} と $IoU_{background}$ の平均を表す。 $IoU_{weighted}$ は、 IoU_{tuna} と $IoU_{background}$ の加重平均を表し、各クラスの画素数の比率に応じて重みが算出される。 IoU_{mean} と $IoU_{weighted}$ は、以下のように決定される。

$$IoU_{mean} = \frac{(IoU_{tuna}) + (IoU_{background})}{2} \quad (2.7)$$

$$IoU_{weighted} = \frac{(IoU_{tuna}) \times adtp + (IoU_{background}) \times adbp}{adtp + adbp} \quad (2.8)$$

BF 輪郭マッチングスコアは、予測された物体領域の境界が用意されたバリデーションデータ上の物体の境界とどれだけ近いかを測定する、つまり予測された物体の形状と事前定義された物体の形状の類似度を評価する指標である。これは、予測された境界上の点がバリデーションデータの境界と一致するかどうかを決定するために使用される距離誤差許容値を持つ、精度と再現値の調和平均 (F1-measure) として、以下のように定義される。

$$BF_{tuna} = \frac{2 \times precision_{tuna} \times recall_{tuna}}{precision_{tuna} + recall_{tuna}} \quad (2.9)$$

$$BF_{background} = \frac{2 \times precision_{background} \times recall_{background}}{precision_{background} + recall_{background}} \quad (2.10)$$

ここで、 BF_{tuna} と $BF_{background}$ はそれぞれ個体領域および背景領域の BF 輪郭マッチングスコアを表す。

BF スコアは、IoU よりも人間の定性評価との相関が高い傾向にある。 $BF_{mean_accuracy}$ は、 BF_{tuna} と $BF_{background}$ の平均値を表し、以下のように表すことができる。

$$BF_{mean_accuracy} = \frac{2 \times precision_{tuna+background} \times recall_{tuna+background}}{precision_{tuna+background} + recall_{tuna+background}} \quad (2.11)$$

定義上、すべての指標値は 0 以上 1 以下の値を取り、値が高いほど検出性能が優れていることを意味する。

2.4 評価結果及び考察

各ペア構造の SegNet によるラベリング結果とその評価結果を Fig. 2-5, 6, 7 に示す。Fig. 2-5, 6, 7 から、Net 5 までの SegNet ではペア構造が深くなるほどラベリングが最適化されて行

っていることが確認できる。また、なお、IoU、BFスコアにおいて、SegNetのペア数に関わらず、backgroundのスコアがtunaと比較して有意であることが確認できる。これは、教師画像において、backgroundに属する画素数の方がtunaに属する画素数と比較して多いためであると考えられる。このため、よりbackgroundに属する画素の検出に特化したネットワークが形成されたと考えられる。さらに、Net1 - Net4のbackground、mean、そしてglobal accuracyのスコアは、Net5 - Net8のそれと比較して小さい値を示した。この知見を検証するため、教師データに使用しなかった1フレームをランダムにサンプリングし、学習済みのNet1-8を用いた検出結果を比較したところ、Fig. 2-8が得られた。Fig. 2-8に示す結果から、Net1-4はフレーム内のほとんどの画素をtunaと誤認していることがわかる。その結果、Net1 - Net4の $Accuracy_{tuna}$ の値は、Net1 - Net4がtunaの画素だけでなくbackgroundの画素もtunaと識別したため、Net5 - Net8の値よりも大きな値を示したことがわかる。一方、Net1 - Net4ではbackgroundのほとんどが認識されなかったため、先に述べたように $Accuracy_{background}$ の値はNet5 - Net8の値より小さい値を示した。これらの結果から、今回の場合、Net5及びNet6が優れた検出性能を発揮していることがわかる。また、Fig. 2-5, 6, 7の結果から、以降の検証については IoU_{mean} 及び $BF_{mean_accuracy}$ を評価基準として採択した。

2.5 SegNetの検出性能に対する学習画像枚数の影響評価

Net5及びNet6について、教師データを増加させた場合の傾向の変化を確認するために、バリデーションデータに用いた画像と新たに作成したデータを追加することで教師データの枚数を2000枚まで増加させて同様の評価を行った。この時、epoch毎に教師データの2割をランダムに抽出し、学習に使用せずにバリデーションデータとして用いた。この時の学習条件をTable 2-3に示した。学習が収束するまでに最大で200epoch程要したため、各ペア構造でのepoch数を200epochで統一した。またこの時、最適化アルゴリズムにはRMSpropの発展形であるAdam (Kingma et al., 2015)を採用した。評価結果をTable 2-4に示した。また、比較を行うために前節のNet5及びNet6について評価結果を改めてTable 2-5に示した。結果から、教師データの増加に伴う変化として、①Net5とNet6の優劣が逆転し、特にNet6については性能の低下が確認されたこと、②Net5については $BF_{mean_accuracy}$ の値の増大が確認できた一方で、 IoU_{mean} についてはNet5とNet6の双方で値の減少が確認されたことの2点が挙げられる。教師データの増加に伴い傾向が変化した要因としては、増加前に用いたバリデーションデータと教師データの両方で背景情報などの傾向が異なることに起因する過学習が発生したためと考えられる。

以上の結果から、 IoU_{mean} 及び $BF_{mean_accuracy}$ の両指標において Net 5 の値が安定していると判断し、教師画像を 5000 枚まで増やした場合について追加で同様の評価を行い、その結果を Table 2-6 に示した。バリデーションデータについては教師データ 2000 枚の際と同様に、epoch 毎に教師データの 2 割をランダムに抽出して用いた。Table 2-6 から、 IoU_{mean} 及び $BF_{mean_accuracy}$ の両指標において値の増大が確認できた。

2.6 SegNet の導入後のシステム性能の評価

前節の結果を踏まえて、画像処理部に SegNet を用いた際のシステム全体の性能を評価するために、教師データ 5000 枚を学習させた Net5 の SegNet と第 1 章で紹介した従来法との比較を行い、その結果を Fig. 2-9 及び Table 2-7 に示した。Fig. 2-9 では運動解析部の KC 法による計算結果を赤の矢印ベクトルで描画し、Table 2-7 に示した数値は Table 1-3 で用いたものと同じデータ・評価指標から算出した。

Fig. 2-9 の描画結果から、SegNet を導入することによって画像中央周辺の個体について追跡性能が従来法と比較して向上していることが確認できる。フレーム毎のラベリングのロバスト性についても SegNet を導入したことによって向上したものと考えられる。

Table 2-7 から、いずれの評価指標についても SegNet を導入することによって性能が向上したことが確認できた。特に適合率 P についても性能の向上が認められることから、従来法と比較して KC 法による解析に適した領域抽出が実現されたと考えられる。一方で、再現率 R の値は性能の向上が認められたものの、尾数を計数するには不十分なレベルであると考えられる。

2.7 新たなセマンティックセグメンテーション手法の導入の検討

画像処理部の更なる性能向上に向けて、SegNet より高性能なセマンティックセグメンテーション手法として DeepLab v3+ の導入を試みた。DeepLab v3+ は常に一定のダウンサンプリング・アップサンプリングを行う Encoder - Decoder ネットワークとは異なり、Fig. 2-10 に示すように異なる解像度で特徴マップをサンプリングする ASPP (Atrous Spatial Pyramid Pooling (Cheng et al., 2017)) と呼ばれるアーキテクチャと、Encoder - Decoder ネットワークとを組み合わせることで、高密度の特徴マップを高速に抽出することを可能とする手法である。抽出可能な特徴量に対しては比較的高速である一方、単純な Encoder - Decoder モジュールの組み合わせである SegNet と比較して内部構造が大規模かつ複雑化しているため、計算コストの大幅な増大する。具体的には、教師データ

5000 枚を 200 epoch まで学習させるために要する時間は, Net5 の SegNet で 1500 分程度要したのに対して, DeepLab v3+では 8000 分以上必要となった。

2.8 DeepLab v3+によるラベリング性能の評価

DeepLab v3+の性能を評価するために、教師データ枚数と epoch 数を変化させて比較対象実験を行い、その結果を Table 2-8 に示した。また、Fig. 2-11 に Net5 の SegNet と DeepLab v3+のラベリング結果の比較を示した。Table 2-6 と比較を行うと、 IoU_{mean} 及び $BF_{mean_accuracy}$ のいずれの指標についても性能の向上が確認され、特に IoU_{mean} については最大で 0.880 と 0.9 に迫る高い値を示すことが確認できた。また、epoch 数を増加させることによって性能が向上することが確認できた。しかし、徒に epoch 数を増大させた場合、教師データの傾向に特化したネットワークが形成されてしまい、汎化性能が著しく低下する過学習という現象が報告されていることから、epoch 数の増加については慎重に検討する必要があると考えられる。また、Fig. 2-11 のラベリング結果から、(b) 図中の赤丸で囲まれた個体のように、SegNet では検出できていなかった個体に対して DeepLab v3+で新たに検出が可能となった事例が確認できた。以上の結果から、画像処理部に対して DeepLab v3+の導入を検討した。

2.9 DeepLab v3+の導入後のシステム性能の評価

2.6 と同様に、画像処理部に DeepLab v3+を導入した場合のシステム全体の性能の評価を行い、その結果を Fig. 2-12 及び Table 2-9 に示した。Fig. 2-12 では Fig. 2-9 と同様に運動解析部の KC 法による計算結果を赤の矢印ベクトルで描画した。Table 2-9 に示した数値については、システムで推定された個体数に対して、画像上で肉眼で存在が確認できる個体数の比率を示した。Table 2-9 から、DeepLab v3+を画像処理部に導入した場合が最もシステム性能が高く、検出率は 77.1%に達した。一方で、Table 2-8 に示された各評価指標の値に対して、システム性能が決して高い水準ではないことから、画像処理部の改良によって運動解析部の追跡性能がシステム全体のボトルネックとなっている可能性が示唆された結果となった。従って、尾数計数システムの性能向上に向けて、運動解析部に着目した検討が必要であると結論付けた。

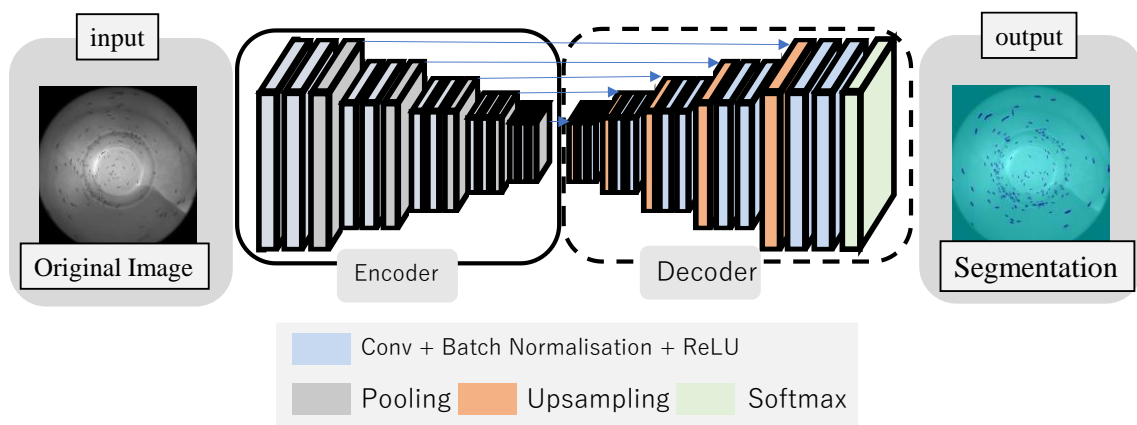


Fig. 2-1. SegNet の基本構造 : Encoder – Decoder モジュール。

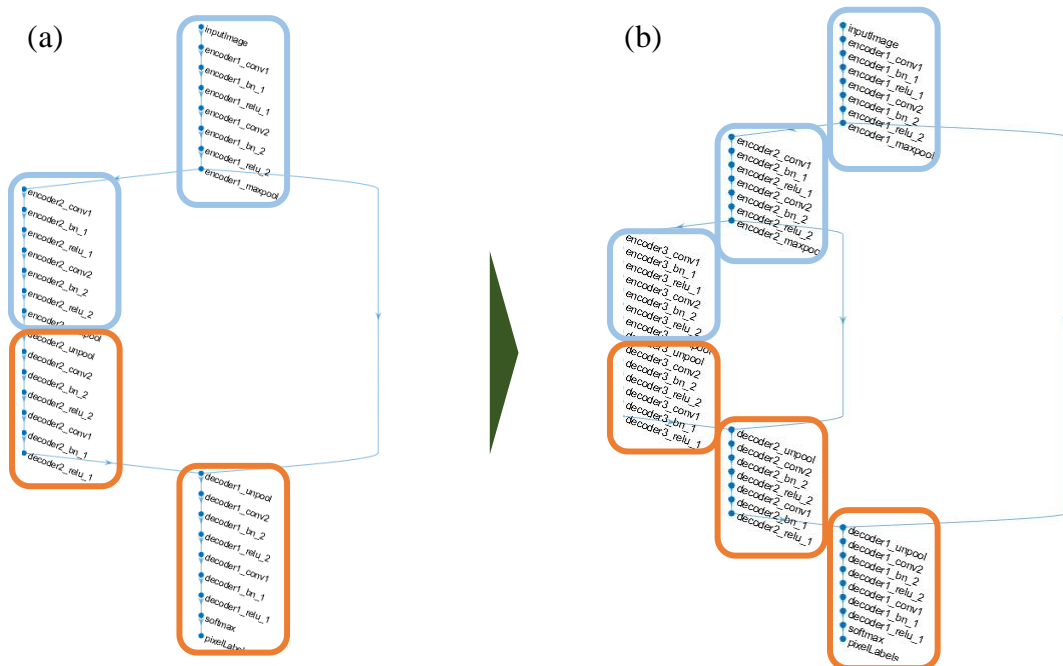


Fig. 2-2. 複数の Encoder – Decoder のペアを有する SegNet の構造 : (a) 2 ペア構造と (b) 3 ペア構造。

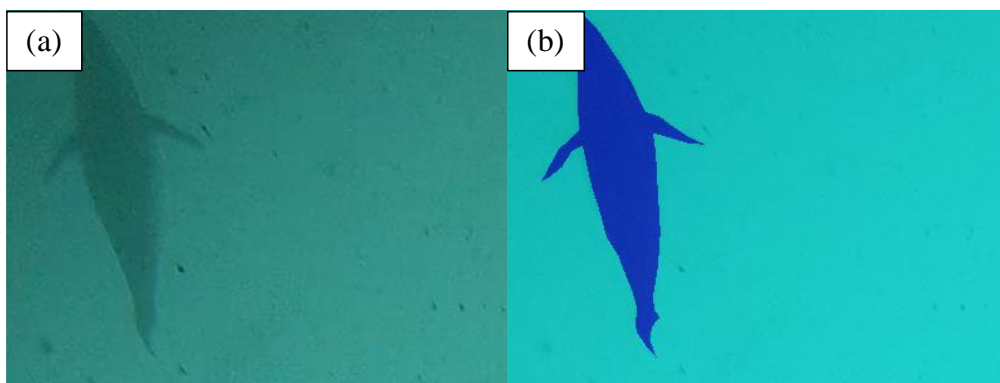


Fig. 2-3. 学習で用いた教師画像のペアの一例。(a)サンプリング画像から切り出したオリジナル画像, (b)(a)の画像をクラス別に塗り分けた画像。

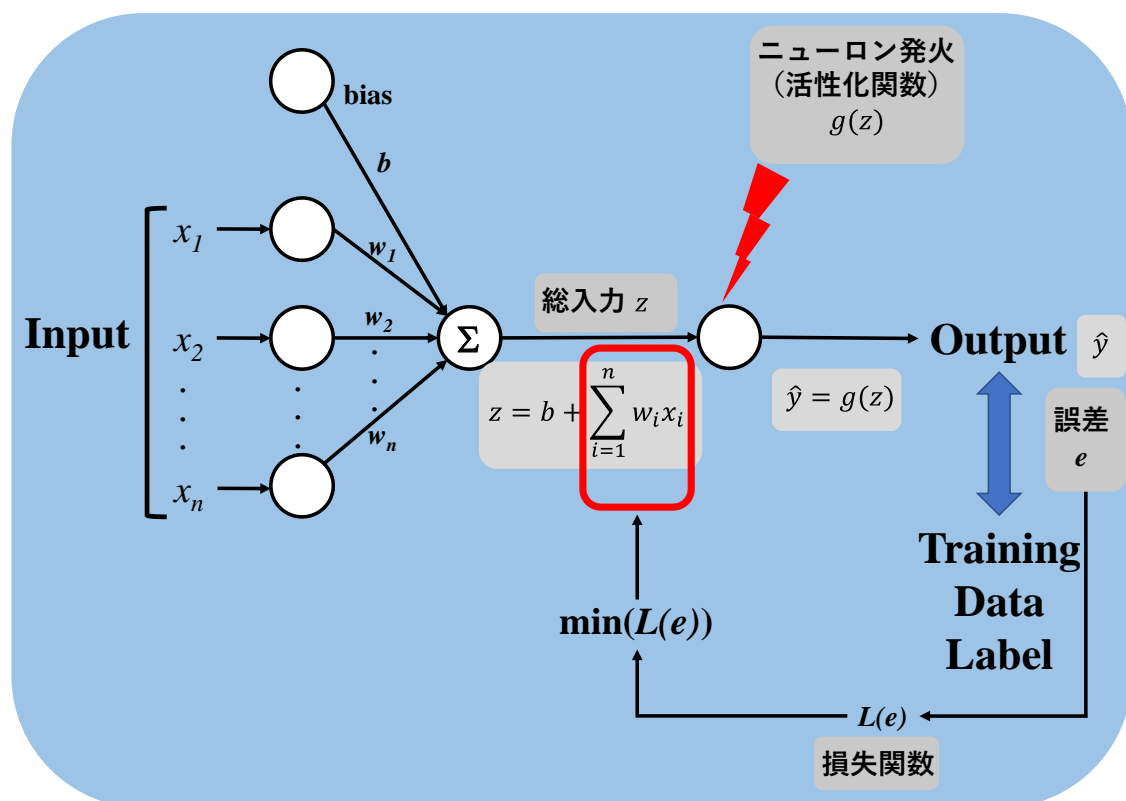


Fig. 2-4. パーセプトロンの学習アルゴリズム

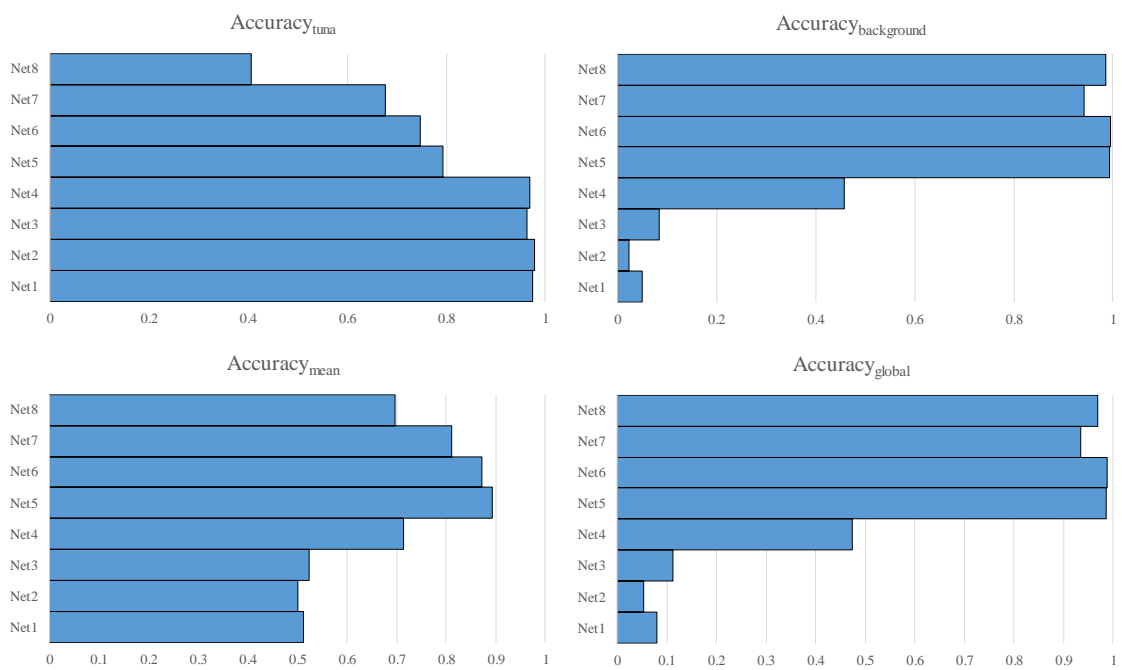


Fig. 2-5. Comparison of the accuracy indicator of the validation data for each number of layers in SegNet.

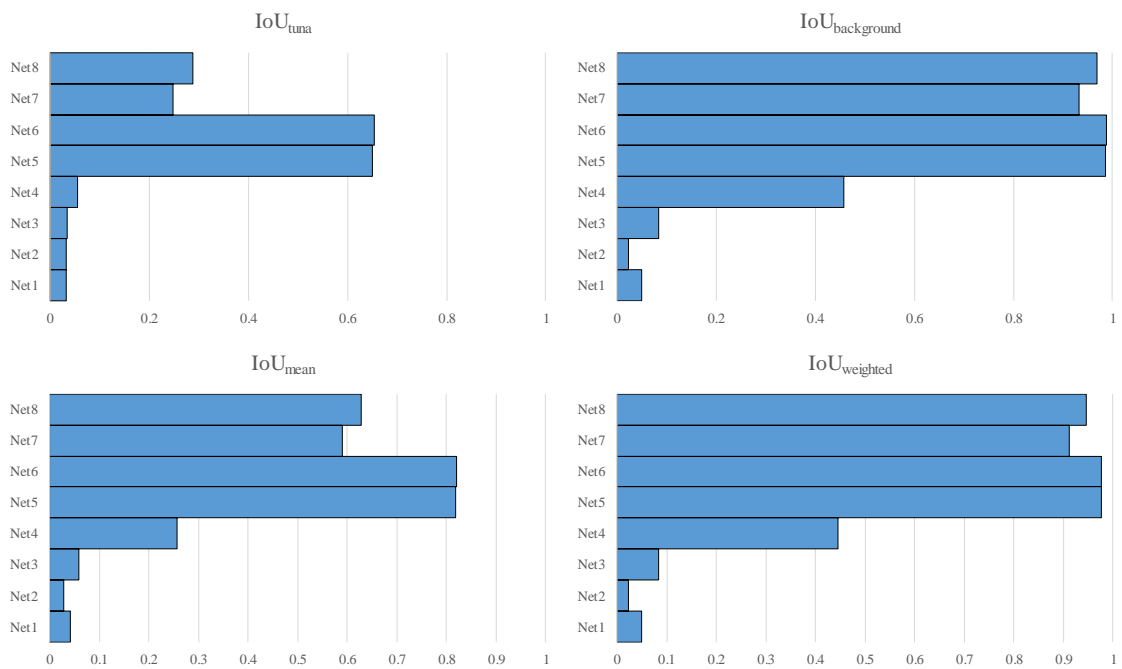


Fig. 2-6. Comparison of IoU indicator of the validation data for each number of layers in SegNet.

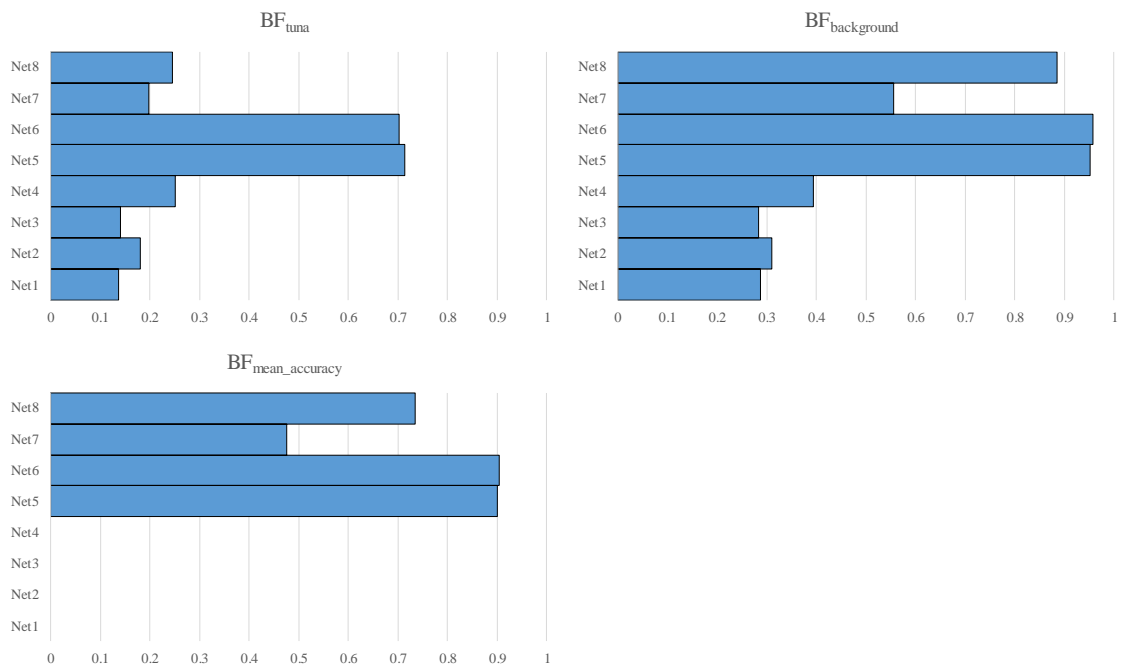


Fig. 2-7. Comparison of BF score of the validation data for each number of layers in SegNet.



Fig. 2-8. Comparison of the detection performance of SegNet network structures for the same image: (a) Net 1, (b) Net 2, (c) Net 3, (d) Net 4, (e) Net 5, (f) Net 6, (g) Net 7, and (h) Net 8.



Fig. 2-8. Comparison of the detection performance of SegNet network structures for the same image: (a) Net 1, (b) Net 2, (c) Net 3, (d) Net 4, (e) Net 5, (f) Net 6, (g) Net 7, and (h) Net 8.




Fig. 2-8. Comparison of the detection performance of SegNet network structures for the same image: (a) Net 1, (b) Net 2, (c) Net 3, (d) Net 4, (e) Net 5, (f) Net 6, (g) Net 7, and (h) Net 8.




Fig. 2-8. Comparison of the detection performance of SegNet network structures for the same image: (a) Net 1, (b) Net 2, (c) Net 3, (d) Net 4, (e) Net 5, (f) Net 6, (g) Net 7, and (h) Net 8.



Fig. 2-8. Comparison of the detection performance of SegNet network structures for the same image: (a) Net 1, (b) Net 2, (c) Net 3, (d) Net 4, (e) Net 5, (f) Net 6, (g) Net 7, and (h) Net 8.




Fig. 2-8. Comparison of the detection performance of SegNet network structures for the same image: (a) Net 1, (b) Net 2, (c) Net 3, (d) Net 4, (e) Net 5, (f) Net 6, (g) Net 7, and (h) Net 8.




Fig. 2-8. Comparison of the detection performance of SegNet network structures for the same image: (a) Net 1, (b) Net 2, (c) Net 3, (d) Net 4, (e) Net 5, (f) Net 6, (g) Net 7, and (h) Net 8.



Fig. 2-8. Comparison of the detection performance of SegNet network structures for the same image: (a) Net 1, (b) Net 2, (c) Net 3, (d) Net 4, (e) Net 5, (f) Net 6, (g) Net 7, and (h) Net 8.




Fig. 2-9. KC 法による描画結果の一例：(a) 画像処理部にフレーム間差分を用いた場合（従来法），(b) 画像処理部に SegNet を用いた場合




Fig. 2-9. KC 法による描画結果の一例：(a) 画像処理部にフレーム間差分を用いた場合（従来法），(b) 画像処理部に SegNet を用いた場合

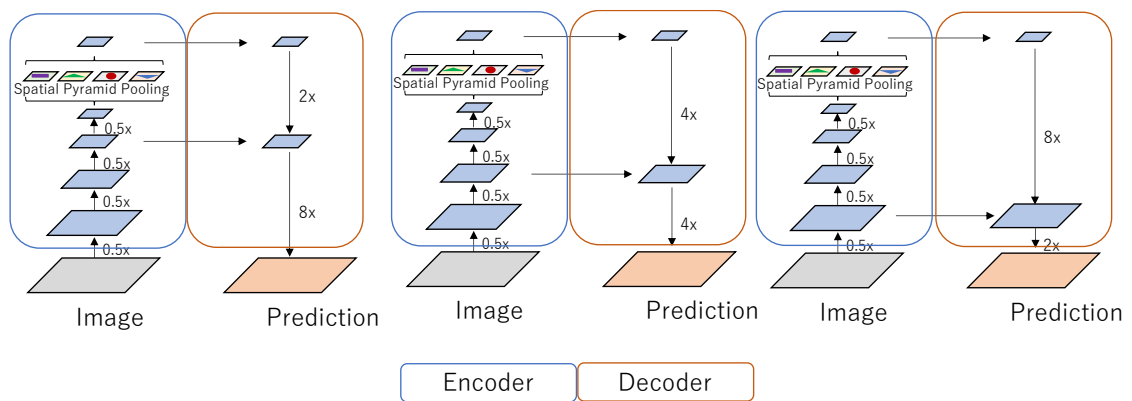


Fig. 2-10. DeepLab v3+の基本構造：異なる解像度で特徴マップをサンプリングするASPP（Atrous Spatial Pyramid Pooling）と呼ばれるアーキテクチャと、Encoder - Decoder ネットワークとを組み合わせることで、高密度の特徴マップを高速に抽出することを可能とする。



Fig. 2-11. SegNet と DeepLab v3+のラベリング性能の比較 : (a) 教師データ 5000 枚, Net5 の SegNet によるラベリング結果, (b) 教師データ 5500 枚の DeepLab v3+によるラベリング結果




Fig. 2-11. SegNet と DeepLab v3+のラベリング性能の比較 : (a) 教師データ 5000 枚, Net5 の SegNet によるラベリング結果, (b) 教師データ 5500 枚の DeepLab v3+によるラベリング結果




Fig. 2-12. KC法による描画結果の一例：画像処理部にDeepLab v3+を用いた場合。

Table 2-1. 解析環境

	PC_A	PC_B
CPU	Xeon E5 2687W 8 core 16 thread × 2	Core i7 8700K 6 core 12 thread
memory	DDR3 128GB	DDR4 32GB
GPU	NVIDIA GeForce GTX 1080 8GB	NVIDIA GeForce GTX 1080 Ti 11GB
software	MATRAB R2019a + CUDA 9.2	

Table 2-2. 教師データ 560 枚に対する SegNet の学習条件

training image size	number of training image	Optimaization	number of epoch	mini-batch size
400 × 300 pixels	560	RMSprop	1000 epoch	14

Table 2-3. 教師データ 2000 枚に対する SegNet の学習条件

training image size	number of training image	Optimaization	number of epoch	mini-batch size
400 × 300 pixels	2000	Adam	200 epoch	14

Table 2-4. 教師データ 2000 枚での各ペア構造の SegNet の性能比較

	IOU_{mean}	$BF_{mean_accuracy}$
Net5	0.7929	0.9100
Net6	0.7143	0.8099

Table 2-5. 教師データ 560 枚での各ペア構造の SegNet の性能比較

	IOU_{mean}	$BF_{mean_accuracy}$
Net5	0.8179	0.9011
Net6	0.8203	0.9031

Table 2-6. 教師データを増加させた場合についての Net5 の性能の比較

教師データ数	IOU_{mean}	$BF_{mean_accuracy}$
2000	0.7929	0.9100
5000	0.8155	0.9429

Table 2-7. 画像処理部にフレーム間差分を用いた場合（従来法）と画像処理部に SegNet を用いた場合について，検出性能の比較

	フレーム間差分	SegNet
抽出した個体候補領域	48	66
推定個体数	38	54
再現率R	0.334	0.501
適合率P	0.906	0.959
F値	0.447	0.657
実測尾数	103	

Table 2-8. 教師データ数と epoch 数を変化させた場合についての DeepLab v3+の性能評価

教師データ数	epoch数	IOU_{mean}	$BF_{mean_accuracy}$
3850	50	0.846	0.950
3850	100	0.868	0.969
5500	100	0.865	0.967
5500	200	0.880	0.978

Table 2-9. 画像処理部に導入した手法別のシステム性能の比較

	フレーム間差分	SegNet	DeepLab v3+
(a) 画像中に肉眼で観察された個体数		103	
(b) システムで自動検出された個体数	38	54	80
b/a (%)	36.9	52.4	77.7

第3章 運動解析部の再検討および撮影環境の影響評価

前章までの結果から、画像処理部の性能向上に伴い、運動解析部の追跡性能が尾数計数システム全体の性能のボトルネックになっている可能性が示唆された。第1章の屋内実験の結果から、運動解析部に適切なデータを入力することで画像中のほぼ全数の個体を計数することが可能であることが確認できているため、本章では最初に、画像処理部の出力を運動解析部に入力する際の処理の妥当性について検討を行う。入力処理の妥当性について検討した後に、構築した尾数計数システムの運用上の特性を把握する目的で、撮影時の照度や濁度などの環境パラメータの変化がシステム性能に与える影響について検討を行う。

3.1 運動解析部におけるデータ入力方法の再検討

3.1.1 現行のデータ入力方法とその課題

1.2 で説明した通り、本システムでは画像処理部で抽出した領域情報について面積重心座標の計算を行い、算出された重心位置座標を画像上の各個体候補を代表する位置座標として扱い、位置座標情報を運動解析部に対して入力し、KC法でフレーム間での個体の移動ベクトルの算出を行ってきた。第1章で実施したような水槽実験の場合、水槽サイズが小さいためカメラから被写体までの距離が近く、撮影画像上に投影される個体の画素数や形状にばらつきは少なく、個体を重心位置座標に置き換えて移動ベクトルを算出した場合に実際の画像上の個体の移動軌跡との間に大きな差異は発生し難いと考えられる。一方で、養殖生簀内の個体を対象とする場合、カメラから個体までの距離は遠く、個体の遊泳深度や生簀内の3次元的な位置に応じて撮影画像上に投影される個体の画素数や形状は大きく変化することが予想される。

そこで、入力方法の改善策として、画像処理部から出力される領域情報を座標情報の集合にとらえ、領域座標を運動解析部に入力することで各個体領域を領域構成画素単位で移動ベクトルを算出する方法を考案した。しかし、領域構成画素すべてを運動解析部に入力した場合、移動ベクトルの算出に膨大な計算コストを要することが確認されたため、各抽出領域に対して領域面積に応じて収縮処理を行うことで計算コストの軽減を試みた。

3.1.2 現行のシステムと改良後のシステムの性能比較

現行のシステムと改良後のシステムの性能の比較を行うために、養殖生簀内で撮影した画像に対してランダムに区間を設定し、それぞれの手法で尾数の推定を行い、その結

果をヒストグラムにまとめて Fig. 3-1 に示した。図中の太い縦線で示したラインがそれぞれのヒストグラムの推定個体数の算術平均値のラインを示し、平均値のラインを中心に内側から順に 99%信頼区間、95%信頼区間、68%信頼区間のラインを示した。対象区間内の画像中に肉眼で確認できた個体数はおよそ 140 尾前後であったのに対して、現行のシステムで 48 尾、改良後で 89 尾が検出に成功した。性能が向上した要因としては、各領域の構成画素単位で追跡を行うことで、KC 法において線形カルマンフィルタで予測した次時刻の推定位置情報と観測値の同一性を χ^2 検定で評価する際に、候補となりうる観測値が常に十分に確保できることから、追跡に成功する確率が上昇するためと考えられる。また、現行のシステムと比較して改良後のシステムでは領域面積の大小にかかわらず常に一定以上の領域座標を運動解析部に入力可能であることから、画像内で個体と背景のコントラストが明瞭でないために画像処理部での領域抽出性能が安定しないような状況下でもロバスト性を確保することができたためであると考えられる。以上の結果を踏まえて、尾数計数システムの基盤を構築できたと判断し、以降は改良後のシステムについて運用評価を行う。

3.2 撮影環境パラメータが計数システムに与える影響の評価

本節では前節で構築した尾数計数システムについて、運用可能な撮影条件の検討を行い、システムの実用性の評価を行う。構築したシステムは水中撮影による画像取得が前提となっているため、撮影画像の状態が計数性能に大きく影響を与えると考えられる。撮影系は 1.6.1 で触れたとおり生簀底部にカメラを上向きに設置して構築されているため、カメラに到達する照度の影響を強く受ける。そこで、撮影に影響を与えると考えられる環境パラメータを計測し、影響の評価を行った。

3.2.1 計測方法及び計測機材

影響評価のために照度と濁度の計測を近畿大学水産研究所奄美実験場のクロマグロ養殖生簀で、2019 年の 6 月、9 月、2020 年 2 月、2021 年 3 月の撮影時に評価試験を実施した。対象とした生簀は①直径 30 m×深さ 23 m (2019) と②直径 20 m×深さ 15 m (2020-2021) の 2 種類で、このうち②の生簀内の養魚の尾数は 140 - 160 尾であった。計測機材には照度計 Onset 社 UA-002-64 (Fig. 3-2. (a)) と濁度計 KRK 社製 TR-55 (Fig. 3-2. (b)) を採用し、撮影は GoPro HERO6 Black に INON 社製コンバージョンレンズ UFL-G140 SD を取り付けて実施した。計測方法は、照度計はカメラと同じ場所に上向きに設置し、カメラ・照度計設置時に生簀表層の採水を行い、TR-55 で濁度を測定した。照度計の測定頻度は 10 秒ごとに設定し、濁度測定用のサンプリングは 7 回実施し、各採水

で得られたサンプルに対して5回濁度を測定し、その平均値をそれぞれのサンプリング時の生簀底面濁度と設定した。

3.2.2 評価方法

撮影した画像を尾数計数システムで解析し、解析結果に対して以下で定義する3種類の指標で評価を実施した。

$$q1 = \frac{\text{DeepLab v3+で正しく検出できた個体数}}{\text{肉眼で画像内に存在が確認できた個体数}} \quad (3.1)$$

$$q2 = \frac{\text{KC法で正しく検出できた個体数}}{\text{KC法で推定された個体数}} \quad (3.2)$$

$$Q = \frac{\text{提案手法で正しく検出できた個体数}}{\text{肉眼で画像内に存在が確認できた個体数}} \quad (3.3)$$

それぞれの指標は、 $q1$ がDeepLab v3+について領域抽出性能の網羅性を評価するための指標、 $q2$ が画像処理部で抽出された領域について、個体以外の背景部分を誤検出している場合に関して誤検出の影響を軽減させるKC法によるノイズリダクション性能を評価するための指標、 Q が尾数計数システム全体に対する計数性能を評価するための指標として設定した。

3.2.3 評価結果及び考察

濁度の各測定結果から、ホルマジン濁度 0.66 FTU を閾値と設定し、以上と未滿とで各指標について評価を実施した。濁度 0.66 FTU 未滿における $q1$ と生簀底面の照度との関係を解析した結果を Fig. 3-3 に示した。この時、プロット結果に対して生簀内にいる養殖魚全個体数に対して、本研究で提案した DeepLab v3+によるラベリングで個体を検出できるとする確率モデルを二項分布とし、個体数を計数する事象が成立する確率を撮影時のカメラ近傍の照度の関数としてロジスティック回帰を行った。link 関数を logit とした場合、検出確率 p_{q1} は次式で表すことができる。

$$p_{q1} = \frac{1}{1 + e^{-z}} \quad (3.4)$$

(3.4)式の z は線形予測子を表す。 z の値を以下の2種類に変化させ、それぞれの回帰結果を図中に描画した。

$$z = \beta_0 + \beta_1 x \quad (3.5)$$

$$z = \beta_0 + \beta_1 x + \beta_2 x^2 \quad (3.6)$$

(3.5)式では線形予測子 z 内の説明変数 x が一次となっていることから、説明変数(照度)の増減によって1または0に収束していくカーブを描くことになる。一方、(3.6)式では x の二次形式となっていることから、特定の照度 x に対して p_{q1} がピークを持つ形となる。照度に対する DeepLab v3+による個体のラベリング能力は照度が大きすぎる場合では、水面からの光の入射が強すぎることにより、個体周りの光の回折により背景と個体とのコントラストがはっきりしなくなり白くぼやける、いわゆるハレーションが発生し、照度環境として悪化することになる。また、暗すぎる場合では当然のことだが光がカメラに届かなくなるため個体識別ができなくなる。そのため、(3.6)式で示したように、特定の照度にピークを持つ二次形式の線形予測子となっていることが妥当と予想できる。Fig.3-3には(3.5)および(3.6)式でそれぞれロジスティック回帰させた一般化線型モデルを図示した。AICを算出すると(3.5)式適用の場合は110.83、(3.6)式では110.88と、(3.6)式の方が僅かに大きくなったが、図に示されているように、(3.5)式を適用した回帰モデルでは、照度の低下とともに $q1$ で表した検出率が上昇しており、現象をうまく表現できていないと考えられた。一方(3.6)式を適用した回帰モデルでは、照度が955 lxで検出率 $q1$ はピークを迎え、DeepLab v3+による個体のラベリングではこの付近での照度で撮影すると検出能力が高いことが示唆された。このときの線形予測子の各係数パラメータは次式で表された。

$$\beta_0 = 1.10, \quad \beta_1 = 5.11 \times 10^{-4}, \quad \beta_2 = -2.68 \times 10^{-7} \quad (3.7)$$

照度955 lx付近の撮影は奄美大島において、2月下旬晴天時の午前9時頃の深度20 mで撮影した環境に近いものとなる。

濁度0.66 FTU以上における $q1$ 、生簀底面の照度との関係を解析した結果を Fig. 3-4に示した。(3.5)式、(3.6)式をそれぞれ線形予測子として適用した場合、両者とも0 lxから3000 lxまでほぼ単調減少に近い回帰曲線となり、二次形式で表現された(3.6)式も極大値をとることができないデータセットであったことがわかる。このことから、濁度が大きくなる0.66 FTU以上の水質環境では、撮影画像から個体にラベリングを行うことはもはや適切ではない撮影条件であることが推察され、少なくとも濁度が0.66 FTUを下回る環境で生簀内クロマグロを撮影することが必要とされる。こうした濁度が高い状況は夏期の6月、9月に確認された。

Fig.3-5は前述の $q2$ とノイズ領域の数との関係をプロットしたものである。ここで、ノイズ領域の数とは DeepLab v3+により養殖魚個体以外でラベリングされた領域数を表しており、この数値が高まることは、例えば養殖魚個体以外に水中懸濁物等が画像に

多く映し出されていることを表している。図からわかるように、ノイズ領域の数が増加しても、 $q2$ の値はほぼ一定の値を示していることから、ラベリングによる領域抽出の際にノイズを検出してもその数の多寡にかかわらず、KC法によるノイズリダクションがうまく機能していることが推察される。このことにより、DeepLab v3+による個体抽出機能に KC 法を組み合わせることによってシステムの個体検出能力のロバスト性が高まっていると考えられた。

Fig.3-6 は尾数計数システム全体の計数性能を評価するための指標 Q に対して撮影時の生簀底面照度がどのように影響するか調べるために示した図で、濁度が 0.66 FTU 未満の時のものである。 $q1$ 対生簀底面照度との関係をロジスティック回帰させた方法と同様に、線形予測子を二次形式で表した。その結果、線形予測子の各係数パラメータは、

$$\beta_0 = 0.024, \quad \beta_1 = 1.17 \times 10^{-3}, \quad \beta_2 = -4.10 \times 10^{-7} \quad (3.8)$$

となり、AIC は 114.5 であったのに対し、線形予測子を一次形式で表した場合は 116.9 となり、極大値をとる二次形式表現で Q を表した方が相対的に適当であった。また、生簀内底面照度は 1425 lx 付近で検出率はピークを迎え、その値 Q は 0.75 であった。この照度は奄美大島実海域において深度 15 m で 2 月下旬晴天時の午前 10 時から 10 時半の時刻で取得された映像データに当たる。Fig.3-7 は Q 対生簀底面照度の関係を撮影時濁度が 0.66 FTU 以上の時のプロット図である。図のように、回帰曲線は Fig.3-6 同様、線形予測子を二次形式で示したものだが、1000 lx 以下でのばらつきが大きいプロットとなり、もはや特定の照度でピークを持つことはなかった。このことから、本提案手法で個体数検出を行う場合は、濁度が小さい清澄な水質条件である冬期の撮影が好条件であり、濁度が大きくなる 6 月から 9 月の夏期は検出精度が低下する可能性が示唆され、特に夏期では濁度が 0.66 FTU を下回るような水質環境で撮影することが望まれる。また、濁度が小さい条件では 1400 lx から 1500 lx の範囲で検出性能がピークを迎えると考えられ、ほぼシステムで取得された個体数検出数に 1.33 の係数を掛けることによって、直径 20 m のクロマグロ養殖生簀における養成尾数が推定できるものと推察された。




Fig. 3-1. 運動解析部への入力方法の改良の前後でのシステム性能比較 : (a) 改良前, (b) 改良後。




Fig. 3-1. 運動解析部への入力方法の改良の前後でのシステム性能比較：(a) 改良前, (b) 改良後。



Fig. 3-2. 環境パラメータ測定に用いた計測機材：(a) 照度計 UA-002-64，(b) 濁度計 TR-55。

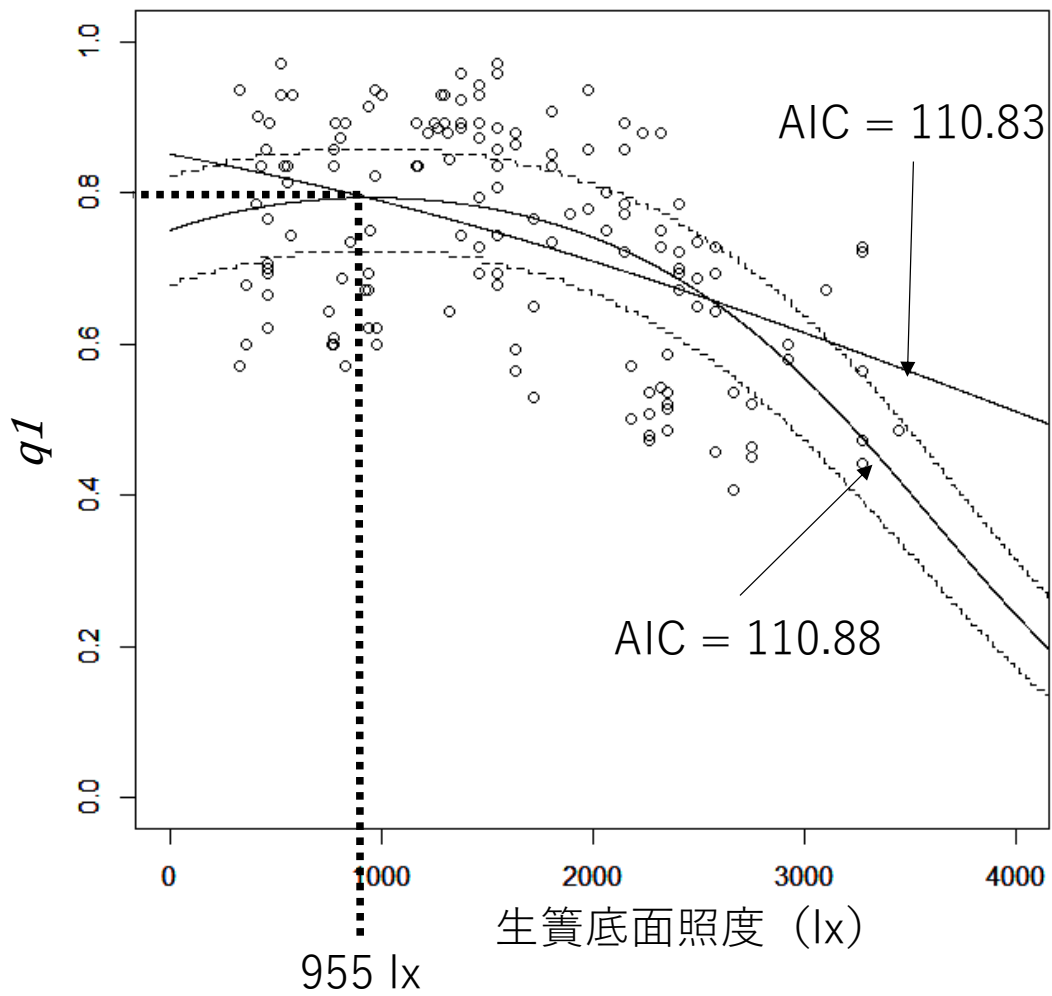


Fig. 3-3. 濁度 0.66 FTU 未満における $q1$ のプロット結果。細い点線はロジスティック回帰曲線の 95%信頼区間を表している。




Fig. 3-4. 濁度 0.66 FTU 以上における $q1$ のプロット結果。下に凸となっている曲線は線形予測子を二次形式で表現した場合。




Fig. 3-5. ノイズ領域の数に対する $q2$ の値の変化。




Fig. 3-6. 濁度 0.66 FTU 未満における Q のプロット結果。細い点線はロジスティック回帰曲線の 95%信頼区間を表している。




Fig. 3-7. 濁度 0.66 FTU 以上における Q のプロット結果。

第4章 養殖クロマグロの行動状態評価

前章で構築した尾数計数システムでは、計数結果のロバスト性を担保するために KC 法による運動解析を行っているため、尾数を計数する際に副次的に連続的な各個体の 2 次元平面画像上での移動ベクトル情報を得ることができる。連続的な個体の追跡結果を重ねてプロットしたものを Fig. 4-1 に示す。この図では給餌時と非給餌時のそれぞれについて連続 1 秒間 30 フレーム分の追跡結果を重ねてプロットしており、両者でベクトルのプロットに違いが生じているのが確認できる。プロットの違いは個体の遊泳深度や遊泳速度の変化に起因するものと考えられる。したがって、移動ベクトルは個体の 3 次元的な行動を 2 次元平面に投影しているという点に着目し、このベクトルを解析することで摂餌行動などの個体の行動状態を表現できるのではないかと、という仮説を立てた。本章ではこの仮説を検証するために、給餌時など個体の行動に変化が生じる状況下の撮影データに対して独自に設定した評価指標を解析し、その妥当性について検討を行った。

4.1 個体の移動ベクトルを解析するための評価指標

移動ベクトルから個体の行動状態を評価するにあたって、時系列的に連続する 2 本のベクトルに着目し、移動ベクトルのノルム差 D 、移動ベクトルのなす角 θ 、移動ベクトルを加工して得られる渦度に似た指標 ω の 3 種類の評価指標を設定した (Fig. 4-2.)。それぞれの評価指標について、ノルム差 D はベクトルの前後での遊泳速度の変化を表す指標として採用し、 D が正の値をとるときに減速を、負の値をとるときに加速をそれぞれ表現している。角度 θ はベクトルの前後での遊泳方向の変化を表している。 ω は移動軌跡が円弧のように曲線的か否かを表現するために、渦度を導出する式に移動ベクトルを代入したものである。算出は 1 個体の時間的に連続した 2 本の移動ベクトルを用いているため空間的な変化ではなく時間的な変化をとらえていることから定義上は渦度を意味しないが、本章では移動ベクトルの渦度と呼称する。

設定した指標の妥当性を検討するために、2019 年 6 月と 9 月、2020 年 2 月 2021 年 3 月の撮影データに対して、移動ベクトルの解析を実施した。2019 年 9 月は台風接近時に撮影を行ったため、台風による波浪影響の有無を評価可能か検討する目的で 2019 年 6 月と 9 月の比較解析を実施した。2020 年 2 月と 2021 年 3 月については給餌・非給餌時の移動ベクトルに対して解析を行うことで指標の妥当性の評価を試みた。評価に使用した移動ベクトルのサンプリングレートは 2 FPS とした。評価可能性の判断材料としてはウィルコクソンの順位和検定を行った。

4.2 評価指標を用いた養殖クロマグロの行動評価

4.2.1 台風接近時と平常時の比較

台風接近時と平常時の比較結果を Fig. 4-3, 4-4, 4-5 に図示した。結果から、ノルム差 D と渦度 ω について帰無仮説が棄却できた一方で、 θ については帰無仮説を棄却できなかったことから、接近時と平常時について D と ω を用いて表現できる可能性が示唆された。 D について台風接近時・平常時ともに常に負の値を示していることから、解析対象区間において個体が加速状態にあると読み取ることができる。また、平常時と比較して接近時の値が小さいことから、台風接近時には平常時と比較して加速度合いが緩やかであると考えられる。

ω については平常時に負の値を、接近時に正の値をとることから、ベクトル場としてとらえた場合平常時と比較して接近時の方がより円弧に近い曲線的な遊泳軌跡であると解釈できる。これらの結果から、台風の接近が個体の行動状態に及ぼす影響が評価指標を用いて判断可能であることが示唆された。

4.2.2 非給餌時と給餌時の比較

非給餌時と給餌時比較結果を Fig. 4-6, 4-7, 4-8 に図示した。結果から、ノルム差 D と渦度 ω について帰無仮説が棄却できなかった一方で、 θ については帰無仮説を棄却できたことから、接近時と非接近時について θ を用いて表現できる可能性が示唆された。非給餌時と給餌時の行動の変化は魚の飽食度合いに起因すると考えられるため、この結果から、魚の飽食度合いを判断する指標として θ が利用可能であることが示唆された。




Fig. 4-1. 連続 1 秒間の個体の移動ベクトル : (a) 非給餌中の個体の移動軌跡, (b) 給餌中の個体の移動軌跡。




Fig. 4-1. 連続 1 秒間の個体の移動ベクトル : (a) 非給餌中の個体の移動軌跡, (b) 給餌中の個体の移動軌跡。

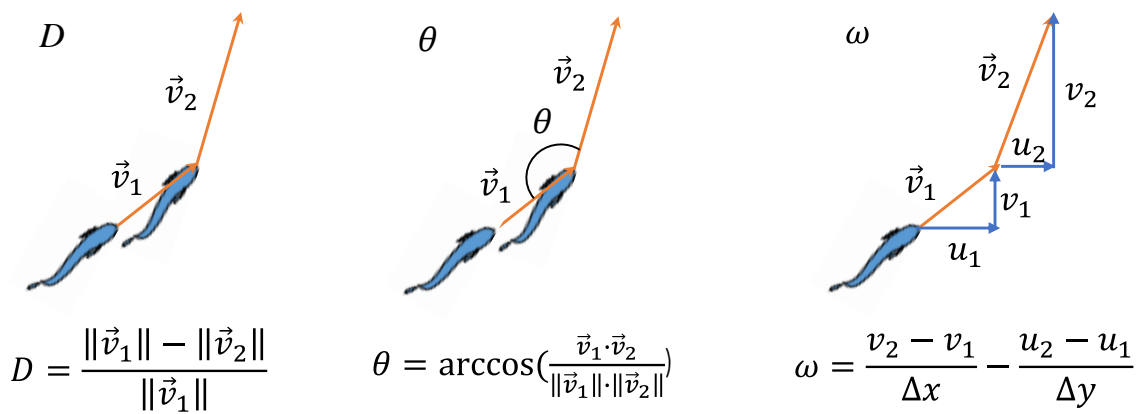


Fig. 4-2. 養殖クロマグロの行動状態の評価指標：移動ベクトルのノルム差 D ，移動ベクトルのなす角 θ ，移動ベクトルの渦度 ω 。

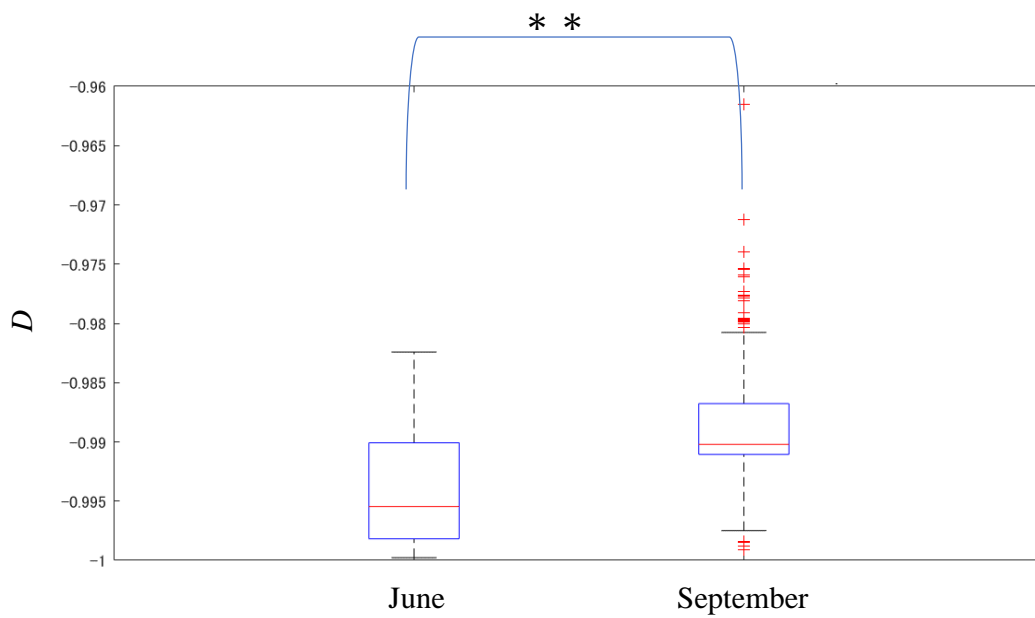


Fig. 4-3. 移動ベクトルのノルム差 D について、平常時（6月）と台風接近時（9月）の比較。Wilcoxon rank sum exact test: $p < 0.01$.




Fig. 4-4. 移動ベクトルのなす角 θ について、平常時（6月）と台風接近時（9月）の比較。Wilcoxon rank sum exact test: $p > 0.05$.




Fig. 4-5. 移動ベクトルの渦度 ω について、平常時（6月）と台風接近時（9月）の比較。Wilcoxon rank sum exact test: $p < 0.01$.




Fig. 4-6. 移動ベクトルのノルム差 D について、非給餌時と給餌時の比較。
Wilcoxon rank sum exact test: $p > 0.05$.




Fig. 4-7. 移動ベクトルのなす角 θ について、非給餌時と給餌時の比較。
Wilcoxon rank sum exact test: $p < 0.05$.




Fig. 4-8. 移動ベクトルの渦度 ω について，平非給餌時と給餌時の比較。
Wilcoxon rank sum exact test: $p > 0.05$.

第5章 総合考察

5.1 自動計数手法の基礎技術開発

第1章では、養殖生簀内のモニタリング手法の開発を目的として、養殖生簀底面から水面に向けて撮影した連続画像から個体を自動でカウントする尾数計数システムを開発するために、動体の自動認識・追跡手法を構築した。検討手法は連続するフレーム間の画像で差分領域を個体候補領域として出力する画像処理部と、時系列の前後での差分領域の同一性を評価することで動体の検出・追跡を行う運動解析部の二部構成で、構築手法を用いて画像内の個体数が推定可能か、検討を行った。まず構築手法が設計した意図通りに動作するかを確認するために、屋内環境下の円筒水槽内でヒメダカ(*Oryzias latipes*)を250尾投入し、広角魚眼カメラを底面に上向きで設置し撮影を行い、取得した画像を用いて構築手法の評価を実施した。評価結果から設計通りに尾数推定が可能であることが確認され、この時、Table 1-2の推定個体数と実測尾数の値から、計数性能としては検出率97%と算出できた。また、Table 1-2の抽出した個体候補領域と実測尾数の値から、画像処理部からは実際の個体の数に対して15%過大評価された出力結果が得られており、この結果から画像処理部で実際の個体数よりも過大評価されたノイズを含む結果を出力し、運動解析部で動体ではないものをノイズとして除去することによって計数を実現しているものと考えられた。一方で、カメラの死角に存在する個体については推定が困難であり、水槽内の全個体数に対する検出率は72%にとどまる。本実験系では計数結果のばらつきが少なかったため、運動解析部の出力結果の1.4倍が全個体数であると言い換えることができる。水槽内に投入するヒメダカの個体数を変化させて解析を行えば、算出された1.4という値がこの実験系に固有の値であるか、再現性があるかについては再検討を実施する必要があると考えられる。

この結果を受けて、次に近畿大学水産研究所奄美実験場のクロマグロ洋上養殖生簀にて同様の撮影を行ったところ、システム全体の検出率が37%、運動解析部の出力は肉眼で観察された個体数に対して52%の過小評価という結果が得られた。屋外での撮影では画像内の背景部分に対して天候や海象条件、水質、生簀網や海藻のような柔軟構造物に起因する動的背景などの外的要因が影響することから、時間的に連続したフレーム間においても背景の色情報や形状に差異が生じ、フレーム間差分による前景抽出性能が安定しないため、システム全体の性能のボトルネックとなっている可能性が示唆された。動的背景の影響軽減を目的とした研究は従来から数多く検討されてきたが(Stauffer et al., 1999; Zivkovic et al., 2006)、水中環境下でのモニタリングに適用するためには課題が多い(Liu et al., 2021)。第2章で導入したセマンティックセグメンテーションはあらかじめ学習した背景オブジェクトに対しては高い認識性能を有するが、別海域の養殖生簀など学習済みの背景情報とは異なる背景を有する環境を

対象に計数システムを適用するためには、動的背景の除去技術を画像処理部に組み込むことでロバスト性を向上させることが可能になると考えられる。動的背景除去技術の計数システムへの組み込みや水中画像への適用については今後の課題である。

本実験では、個体を粒子に見立てることで PTV 解析に用いられている KC 法による個体の同時追跡が実現可能かを確認することを目的とした。結果から、KC 法の導入によって一定以上の同時追跡性能を有することが確認でき、個体を同時追跡する運動解析部の基盤が構築されたものと考えられる。しかし、フレーム間差分による個体候補領域の抽出は動的背景の影響を強く受け、抽出性能が安定しないことから、屋外環境下で撮影した画像を解析するためには画像処理部で使用する領域抽出性能を向上させる必要があると考えられる。

5.2 深層学習を応用した個体領域抽出手法の検討

第 2 章では、第 1 章で構築した画像処理部に対して、照度変化などの撮影時の外部撮影パラメータの影響にロバストな個体領域抽出技術の適用による抽出性能の向上を目的として、深層学習を応用したセマンティックセグメンテーションの導入を試みた。深層学習を応用したセマンティックセグメンテーションでは、検出したいオブジェクトと背景オブジェクトを事前に定義し、定義したクラスラベル毎に塗り分けを行った教師画像を用意し学習を行うことで、画像を画素単位でラベル別に塗り分けることを可能とするセグメンテーション手法である。まず比較的構造が単純なセマンティックセグメンテーション手法である SegNet を構築することで領域抽出に適した教師画像の作成方法や学習条件の選択、出力結果の傾向などのセマンティックセグメンテーション手法に対する理解を深め、次に得られた知見を基により大規模で複雑な構造を持つ DeepLab v3+ を構築し、画像処理部に適用して領域抽出性能の安定化・向上を目的とした性能評価を実施した。

SegNet は Encoder – Decoder モジュールを有するセグメンテーション手法であり、Encoder で特徴抽出と分類を行い、抽出された特徴量マップと元画像の画素座標の対応関係を Decoder でマッピングする。初期のセグメンテーション手法である FCN (Long et al., 2015) では Encoder で特徴量マップを抽出する際に元画像上の画素座標との対応情報が欠落してしまうため、Decoder を採用することによりメモリ効率を高めている。一方で、特徴抽出時に情報の欠落が発生しやすいというデメリットを抱えている。画像処理部に SegNet を導入することによって、システム全体の検出率は 52%に向上し、画像処理部の出力結果は実測尾数に対して 36%の過小評価であった。フレーム間差分を採

用した場合と比較するといずれの指標も性能の向上が確認され、領域抽出性能のロバスト性の向上も確認されたが、画像処理部で出力された候補領域数は実測尾数に対して過小評価傾向を示しており、Encoder で特徴抽出を行う際の情報欠落分が影響していると考えられる。特徴量マップの情報欠落を防ぐ手法としては、特徴抽出を行う際に ASPP を行うことで、情報の極端な圧縮を行うことなく任意のスケールで特徴抽出を行うことができることが知られており、結果として Encoder を用いた場合と比較してより広範囲の特徴を抽出することが可能となる。DeepLab v3+ は特徴抽出時に ASPP を利用し、アップサンプリング時に Decoder モジュールを組み込むことで、抽出された特徴量マップと元画像の画素座標の対応関係をマッピングすることで、各オブジェクトの特徴量マップと画像上の境界情報のどちらも損なうことなく領域抽出可能なセグメンテーション手法であり、DeepLab v3+ の画像処理部への適用によって抽出性能の向上が見込まれた。

DeepLab v3+ を導入することによって、システム全体の検出率を 78% にまで向上させることに成功した。しかし、DeepLab v3+ の性能に対して検出率の水準が決して高くはないことから、運動解析部に抽出結果が入力される際に情報欠落が生じている可能性が示唆された。運動解析部に入力される情報は画像処理部で出力される情報から領域の形状や大きさなどが破棄されているため、Encoder で行っている意味情報のみを抽出する過程と本質的に違いはなく、FCN で生じた問題との類似が認められる。本論文では画像処理部での出力データに対する情報の圧縮を抑えることで問題に対処したが、Encoder – Decoder モジュールのように画像処理部での出力情報を別の形で保存することで同様に対処できる可能性があり、今後の研究展開が期待される。

5.3 運動解析部の再検討および撮影環境の影響評価

第 2 章では画像処理部の抽出性能が向上した結果、運動解析部の性能がシステム全体のボトルネックとなっている可能性が示唆された。運動解析部に入力を行う際に画像処理部の出力結果のうち抽出された領域の面積重心位置座標以外の情報をそぎ落としてしまっているため、KC 法でフレーム間の領域の同定を行う際に手掛かりとなる情報が少なく、結果として追跡性能に悪影響を与えている可能性が考えられる。そこで画像処理部に入力する情報の圧縮を最小限にとどめることで、追跡性能の向上に成功し、これをもって画像処理部及び運動解析部を構築できたと判断した。現状では改良前も改良後も画像上の位置座標のみを入力しているが、運動解析部の更なる性能向上を求める場合、画像処理部で抽出された領域の各構成画素位置と対応する元画像の RGB 値を紐づけ、KC 法で解析を行うことで実現可能ではないかと考えられる。この場合、入力情報が増

えることで KC 法，特に χ^2 検定を実施する際の計算コスト増大が懸念されるため，最適な入力情報の圧縮方法や，KC 法内部のいずれかの計算ステップ時に圧縮情報の複合化を図ることで性能の向上が図れないかの検討を実施することが今後の課題である。

次に本論文では，構築した画像処理部及び運動解析部に対して，運用可能な撮影条件の検討と，条件下における最終的な尾数計数システムの実用性の評価を行った。クロマグロ養殖生簀の底面照度と表層濁度を計測し，表層濁度の値からホルマジン濁度 0.66 FTU を閾値に以上と未満とで設定し高く評価指標と照度をプロットし，その結果を解析した。解析結果から，本研究の尾数計数システムは濁度 0.66 FTU 以上の海域では検出性能とロバスト性が低下することが確認できた。計測期間内に奄美大島実海域で表層濁度が 0.66 FTU 以上となるのは夏季のみであったため，冬季には安定して運用可能であることが示唆された。夏季においても奄美大島実海域で濁度が 0.66 FTU 以上となるような水質環境は降雨時や台風接近時に限定されたため，陸水の流入が発生しうるような状況下での運用は避けるべきであると考えられる。濁度が 0.66 FTU 未満の水質環境下では，照度が 1400 – 1500 lx の範囲において検出性能のピークを迎えることが解析結果から読み取ることができた。この照度範囲は計測データから対象海域では冬季晴天時の午前 10 時頃の照度であると考えられる。このような適正条件下において，運動解析部の出力結果にロジスティック回帰分析結果から得られた係数 1.33 を掛けた値と直径 20 m，深さ 15 m の養殖生簀内の養成尾数とがほぼ一致することから，運動解析部の最後にこの係数 1.33 を掛ける過程を組み込むことで，該当するサイズのクロマグロ養殖生簀に対する尾数計数システムを構築できたと推察できた。運動解析部の出力結果にかける係数の値は生簀のサイズや対象の海域によって変動する可能性があると考えられるため，今後はこの係数と生簀サイズ等の情報とを対応付けるためのデータベースを作成することで，本研究の尾数計数システムの汎化性能を図ることが今後の課題である。

5.4 養殖クロマグロの行動状態評価

第 3 章で構築した尾数計数システムを運用することで，2 次元平面上に投影された連続的な各個体の移動ベクトル情報が取得できる。この移動ベクトルの状態には摂餌や周辺環境に影響される個体行動の状態情報を内包している可能性があり，ベクトルの状態変化から個体行動の状態変化を読み取れる可能性がある。ベクトルの状態変化を評価するために移動ベクトルのノルム差 D ，移動ベクトルのなす角 θ ，渦度に類似した指標 ω の 3 種類の評価指標を策定し，これらの指標を用いて養成環境の変化が表現可能であるか分析を行った。分析結果から，給餌時と非給餌時では θ の値に対して有意な違いが確

認められ、この結果から、養成魚の摂餌時における遊泳軌跡が特有のものである可能性が示唆され、指標 θ を用いることで養成魚の飽食度合いの評価に利用できる可能性が確認されたことになる。また、平常時と台風接近時とでは D と ω の値に対して有意な違いが確認できた。台風接近時のように平常時と流速条件が大きく異なるような状況下では養殖生簀が波浪動揺により翻弄され、生簀容積の減少に至ることが Suzuki et al. 2009 の解析によって明らかになっている。生簀網と養成魚が接触してしまうと個体にダメージを与える可能性がある。波浪動揺を低減させるために沈下機能が設計されているような施設の場合などには、 D や ω のような指標を評価基準とすることで、沈下捜査の必要性が判断できる可能性が示唆された。以上の結果から、いずれの指標についても養殖管理上有用である可能性が確認できた。

5.5 今後の課題及び展望

流体の可視化に用いられる PTV 解析用に構築された KC 法をチューニングすることによって、養殖生簀内の太平洋クロマグロの尾数計数システムを構築した。また、尾数推定時に算出される個体の移動ベクトルを解析することで、魚の行動状態の判別・評価が可能であることを確認した。本研究では、新たな尾数計数システムを構築し、システムの運用可能な条件の探索を行うことで、データ取得から尾数算出、そして養成魚の状態評価までを一体化した統合的な養殖管理システムの構築可能性を示した。

今後このシステムを洗練し、運用可能な条件をより明確化することができれば、本システムの運用条件を基に養殖生簀を設計し、養殖生簀・モニタリングシステム一体型の養殖形態を開発できる可能性がある。このような養殖形態を実現するためには、当該技術を実用化するための要素技術の研究開発についても推し進めていく必要がある。養成魚の状態評価については、現在評価可能性が示唆されているのは養成魚の飽食度合いや台風接近時など、限定的だが、今後本システムの運用によって養成魚の行動状態情報を集積することで、養成魚の健病性や産卵行動など、これまでは事前に察知することが困難であった事象を把握することが期待できる。また、本システムは現状光学情報に大きく依存しているため、清澄な海域でのみ運用可能であると考えられ、運用できる海域が大きく制限されてしまう。この問題に対しては、今後ソナーなどの音響計測手法を取り入れ、光学情報と音響情報とを組み合わせることによって、運用可能な海域を広げていくことが可能となるだろう。さらには、画像処理部での抽出性能は、学習済みの教師データのバリエーションに大きく依存することから、教師データを拡充していくことは要求コストが高く、別の海域への応用は現状困難である。この問題に対処するためには、

教師データ数を人工的に増加させるために敵対性ネットワーク (Goodfellow et al., 2014) を組み込む, または必要となる教師データ数を削減するために自己教師あり学習手法 (Wang et al., 2020; Jaiswal et al., 2021) を導入することで解決が期待できる。

本研究では深層学習を応用した画像処理手法と流体の可視化に用いられている KC 法を組み合わせることによって, 撮影画像内の個体候補領域を抽出し, 時系列の前後での個体候補領域の同定を行うことで個体の 2 次元平面上の移動ベクトルを算出し, その情報を基に養殖生簀内の養成魚の尾数計数と, 養成魚の行動状態を評価する統合的な養殖管理システムを提案した。このことは, 養殖管理の効率化を推進するだけでなく, 個体の行動状態の評価結果から魚類の未知の行動特性の解明を可能とするものであり, 海洋生物の物理特性を解明し, その特性を社会に役立てる水産工学研究において大きく貢献するものであると考えられる。本研究を基盤技術とする, 魚類の行動特性に対する物理的究明の発展が期待される。

謝辞

本研究の遂行と論文の作成に際して終始御指導と御鞭撻を賜った北海道大学水産科学研究院，高木 力教授に謹んで感謝の意を表します。

本論文を提出するにあたり，有益な御助言を賜った北海道大学水産科学研究院，木村 暢夫教授，藤森 康澄教授，安間 洋樹教授，ならびに近畿大学工学部竹原 幸生教授に心から感謝の意を表します。

本研究の遂行やデータ収集にあたり多大な御助力を賜った近畿大学農学部鳥澤 眞介講師，近畿大学水産研究所，升間 主計教授，また，近畿大学水産養殖種苗センター，八木 洋樹氏，中井 彰治氏，勝田 芳樹氏に心からお礼申し上げます。

本研究を進めるにあたり有益な御助言とご協力を頂いた古野電気株式会社技術研究所，西森 靖博士，浅海 茂氏，山口 武治氏に謹んで感謝の意を表します。

また，北海道大学大学院水産科学院大学院生修士 2 年武井 大樹君には現地での実験遂行に協力頂きました。また同大学院博士課程ならびに修士課程学生の皆さんには研究遂行に際してご協力を頂きました。ここにお礼申し上げます。

さらに，一般財団法人電力中央研究所 サステナブルシステム研究本部 生物・環境化学研究部門 水域生物ユニットの皆様におかれましては，一般業務と並行して学位論文の執筆を行うことにご理解・ご協力いただきましたこと，心より感謝申し上げます。

最後に本研究の一部は JSPS 科研費 JP19J11547(特別研究員奨励費)，北海道大学-古野電気株式会社共同研究費用，また JP18H02260(基盤研究(B))の助成を受けたものであることを付記し，ここに関係者各位に深甚なる謝意を表します。

参考文献

- Abdel-Aziz, Y. I., Karara, H. M., 1971. Direct linear transformation from comparator coordinates into object space coordinates in close-range photogrammetry. In: ASP Symposium on Close Range Photogrammetry. American Society of Photogrammetry Falls Church VA: 1-19.
- Abe, K., Tanaka, M., Habe, H., Taniguchi, Y., Iguchi, N., 2018. Video scene detection of burst swimming by fry of farmed-raised bluefin tuna. In: 2018 4th International Conference on Frontiers of Signal Processing (ICFSP). Poitiers, France, pp. 105–109.
- Abe, S., Takagi, T., Takehara, K., Kimura, N., Hiraishi, T., Komeyama, K., Torisawa, S., Asaumi, S., 2017. How many fish in a tank? Constructing an automated fish counting system by using PTV analysis. Selected Papers from the 31st International Congress on High-Speed Imaging and Photonics vol. 10328, 56–59.
- Abe, S., Takagi, T., Torisawa, S., Abe, K., Habe, H., Iguchi, N., Takehara, K., Masuma, S., Yagi, H., Yamaguchi, T., Asaumi, S., 2021. Development of fish spatio-temporal identifying technology using SegNet in aquaculture net cages. *Aquacultural Engineering*, 93, 102146. [10.1016/j.aquaeng.2021.102146](https://doi.org/10.1016/j.aquaeng.2021.102146)
- Badrinarayanan, V., Kendall, A., Cipolla, R., 2017. SegNet: a deep convolutional encoder- decoder architecture for image segmentation. *IEEE Trans. Pattern Anal. Mach. Intell.* 39 (12), 2481–2495.
- Boudhane, M., Nsiri, B., 2017. Fish tracking using acoustical and optical data fusion in underwater environment. In: Paper presented at the proceedings of the international conference on watermarking and image processing, Paris, France.
- Chen, L.C., Papandreou, G., Kokkinos, I., Murphy, K., Yuille, A.L., 2017. DeepLab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs. *TPAMI* 40, 834–848.
- Chen, L.C., Zhu, Y., Papandreou, G., Schroff, F., Adam, H., 2018. Encoder-decoder with atrous separable convolution for semantic image segmentation. In: Proceedings of the European conference on computer vision (ECCV), pp. 801–818.
- Cheng, X.E., Du, S.S., Li, H.Y. et al., 2018. Obtaining three-dimensional trajectory of multiple fish in water tank via video tracking. *Multimed Tools Appl* 77, 24499–24519.

Costa, C., Scardi, M., Vitalini, V., Cataudella, S., 2009. A dual camera system for counting and sizing Northern Bluefin Tuna (*Thunnus thynnus*; Linnaeus, 1758) stock, during transfer to aquaculture cages, with a semi automatic Artificial Neural Network tool. *Aquac.* 291 (3–4), 161–167.

Dolado, R., Gimeno, E., Beltran, F.S., Quera, V., Pertusa, J.F., 2015. A method for resolving occlusions when multitasking individuals in a shoal. *Behav Res Methods.* 47(4):1032-1043.

Esteva, A., Kuprel, B., Novoa, R. et al., 2017. Dermatologist-level classification of skin cancer with deep neural networks. *Nature* 542, 115–118.

Food and Agriculture Organization of the United Nations (FAO), 2018. The State of World Fisheries and Aquaculture 2018 – Meeting the Sustainable Development Goals. FAO, Rome.

Gonda, Y., Kondo, Y., Takahashi, N., Miya, K., 2014. Trials of resistivity fish counters for automatic counting of chum *Oncorhynchus keta* and masu *O. masou* salmon migrating in small rivers. *Journal of Fisheries Technology.* 7, 1, 1-16.

Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., Bengio Y., 2014. Generative adversarial nets. In *NIPS*, pp. 2672–2680.

Hamano, A., Sasakura, T., Namari, S., Sakakibara, N., Ito, S., Kodera, K., Nomura, T., Watanabe, K., Nose, M., Inai, K., Nakamura, T., Tanoue, H., 2018. Development of a new monitoring methodology for counting bluefin tuna in net pens. In: *Proceedings of 2018 OCEANS - MTS/IEEE Kobe Techno-Oceans (OTO) Conference & Exhibition.* Kobe, Japan.

Henriques, J.F., Caseiro, R., Martins, P., Batista, J., 2015. High-speed tracking with kernelized correlation filters. *IEEE Trans Pattern Anal Mach Intell* 37(3):583-596.

Hu, J., Zhou, C., Zhao, D., Zhang, L., Yang, G., Chen, W., 2020. A rapid, low-cost deep learning system to classify squid species and evaluate freshness based on digital images. *Fish. Res.* 221, 105376

Huang, R. -J., Lai, Y. -C., Tsao, C. -Y., Kuo, Y. -P., Wang, J. -H., Chang C. -C., 2018. Applying convolutional networks to underwater tracking without training. In: *2018 IEEE International Conference on Applied System Invention (ICASI)*, pp. 342-345,

Jaderberg, M., Simonyan, K., Vedaldi, A. et al., 2016. Reading Text in the Wild with Convolutional Neural Networks. *Int J Comput Vis* 116, 1–20.

Jadon, S., Leary, O., P., Pan, I., Harder, T. J., Wright, D. W., Merck, L. H. et al., 2020. A comparative study of 2D image segmentation algorithms for traumatic brain lesions using CT data from the ProTECTIII multicenter clinical trial. In: *Medical Imaging 2020: Imaging Informatics for Healthcare Research and Applications*, International Society for Optics and Photonics, SPIE, vol. 11318, pp. 195-203.

Jaiswal, A., Babu, AR., Zadeh, MZ., Banerjee, D., Makedon, F., 2021. A Survey on Contrastive Self-Supervised Learning. *Technologies*. 9(1):2.

Jing, D., Han, J., Wang, X., Wang, G., Tong, J., Shen, W., Zhang, J., 2017. A method to estimate the abundance of fish based on dual-frequency identification sonar (DIDSON) imaging. *Fish. Sci.* 83, 685–697.

Kadota, M., Torisawa, S., Takagi, T. et al. Analysis of juvenile tuna movements as correlated random walk. *Fish Sci* 77, 993–998 (2011).

Takehi, S., Sekiuchi, T., Ito, H., Ueno, S., Takeuchi, Y., Suzuki, K., Togawa, Mai., 2021. Identification and counting of Pacific oyster *Crassostrea gigas* larvae by object detection using deep learning, *Aquac. Eng.*, 95, 102197.

Kingma, D., Adam, J. Ba., 2015. A method for stochastic optimization. In *ICLR*.

Kitagawa, T., 2008. Studies on the behavioral ecology and thermal adaptation mechanisms of Pacific bluefin tuna, *Thunnus orientalis*. *Nippon. Suisan Gakkaishi* 74 (4), 580–583.

Li, D., Hao, Y., Duan, Y., 2019. Nonintrusive methods for biomass estimation in aquaculture with emphasis on fish: a review. *Rev. Aquac.* 1–22.

Li, X., Wei, Z., Huang, L., Nie, J., Zhang W., Wang, L., 2018. Real-time underwater fish tracking based on adaptive multi-appearance model. In: *Proc. IEEE 25th Int. Conf. Image Process.*, pp. 2710-2714.

Liu, K., Liang, Y., 2021. Enhancement of underwater optical images based on background light estimation and improved adaptive transmission fusion. *Opt. Express* 29, 28307-28328.

Liu, L., Lu, H., Cao, Z., Xiao, Y., 2018. Counting Fish in Sonar Images. In: 2018 25th IEEE International Conference on Image Processing (ICIP), pp. 3189-3193.

Liu, S., Li, X., Gao, M., Cai, Y., Nian, R., Li, P., Yan, T., Lendasse, A., 2018. Embedded Online Fish Detection and Tracking System via YOLOv3 and Parallel Correlation Filter. OCEANS 2018 MTS/IEEE Charleston, pp. 1-6.

Liu, X., Han, Y., Bai, S., Ge, Y., Wang, T., Han, X., Li, S., You, J., & Lu, J., 2020. Importance-Aware Semantic Segmentation in Self-Driving with Discrete Wasserstein Training. Proceedings of the AAAI Conference on Artificial Intelligence, 34(07), 11629-11636.

Long, J., Shelhamer, E., Darrell, T., 2015. Fully convolutional networks for semantic segmentation. In CVPR, pp. 3431–3440.

Marini, S., Fanelli, E., Sbragaglia, V., Azzurro, E., Fernandez, J.D.R., Aguzzi, J., 2018. Tracking fish abundance by underwater image recognition. Sci. Rep. 8 (1), 1–12.

Martignac, F., Daroux, A., Bagliniere, J. L., Ombredane, D., Guillard, J. 2015. The use of acoustic cameras in shallow waters: new hydroacoustic tools for monitoring migratory fish population. A review of DIDSON technology, FISH and FISHERIES, 16, 486-510.

Masuma, S., 2008. Development on techniques of stock enhancement for Pacific bluefin tuna *Thunnus orientalis* by the Fisheries Research Agency (formerly, Japan Sea Farming Association). J. Fish. Technol. 1, 21–36.

Melvin, G.D., 2016. Observations of in situ Atlantic bluefin tuna (*Thunnus thynnus*) with 500-kHz multibeam sonar. ICES J. Mar. Sci. 73 (8), 1975–1986.

Mohamed, H.- E.-D., Fadl, A., Anas, O., Wageeh, Y., ElMasry, N., Nabil, A., Atia, A., 2020. MSR-YOLO: Method to enhance fish detection and tracking in fish farms. Procedia Computer Science, 170, 539–546.

Muñoz-Benavent, P., Andreu-García, G., Valiente-González, J.M., Atienza-Vanacloig, V., Puig-Pons, V., Espinosa, V., 2018. Automatic Bluefin Tuna sizing using a stereoscopic vision system. ICES J. Mar. Sci. 75 (1), 390–401.

- Panwar, H., Gupta, P.K., Siddiqui, M. K., Morales-Menendez, R., Bhardwaj, P., Singh, V., 2020. A deep learning and grad-CAM based color visualization approach for fast detection of COVID-19 cases using chest X-ray and CT-Scan images. *Chaos, Solitons & Fractals*, Volume 140, 110190.
- Ravanbakhsh, M., Shortis, M.R., Shafait, F., Mian, A., Harvey, E.S., Seager, J.W., 2015. Automated fish detection in underwater images using shape-based level sets. *Photogramm. Rec.* 30 (149), 46–62.
- Rodriguez, A., Zhang, H., Klaminder, J., Bordin, T., Andersson, M., 2017. ToxId: an efficient algorithm to solve occlusions when tracking multiple animals. *Sci Rep* 7, 14774.
- Rosen, S., Jörgensen, T., Hammersland-White, D., Holst, J.C., 2013. DeepVision: a stereo camera system provides highly accurate counts and lengths of fish passing inside a trawl. *Can. J. Fish. Aquat. Sci.* 70 (10), 1456–1467.
- Salman, A., Siddiqui, S.A., Shafait, F., Mian, A., Shortis, M.R., Khurshid, K., Ulges, A., Schwanecke, U., 2019. Automatic fish detection in underwater videos by a deep neural network-based hybrid motion learning system. *ICES J. Mar. Sci.* fsz025, 1–13.
- Sawada, Y., Okada, T., Miyashita, S., Murata, O., Kumai, H., 2005. Completion of the Pacific bluefin tuna, *Thunnus orientalis*, (Temminck et Schlegel) life cycle. *Aquac. Res.* 36, 413–421.
- Shortis, M., 2019. Camera calibration techniques for accurate measurement underwater. In: McCarthy, J., Benjamin, J., Winton, T., van Duivenvoorde, W. (Eds.), *3D Recording and Interpretation for Maritime Archaeology*. Coastal Research Library, Vol 31. Springer, Cham.
- Stauffer, C., Grimson, W.E.L., 1999. Adaptive Background Mixture Models for Real - time Tracking. *Computer Vision and Pattern Recognition (CVPR)*, Vol.2, pp.246 - 252.
- Suzuki, K., Torisawa, S., Takagi, T., 2009. Numerical analysis of net cage dynamic behavior due to concurrent waves and current. In: *Proceedings of the International Conference on Offshore Mechanics and Arctic Engineering - OMAE* 4, 1513-1520.
- Takehara, K., Etoh, T., Murata, S., Michioku, K., 1996. Development of a new algorithm for PTV. *J. Jpn. Soc. Civil Eng.* 533, 107–126.

Tang, T. Y., Fu, B. L., Lou, P. Q., Bi, L., 2020. SEGNET-BASED EXTRACTION OF WETLAND VEGETATION INFORMATION FROM UAV IMAGES. In: ISPRS International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XLII-3/W10, pp.375-380.

Terayama, K., Habe, H., Sakagami, M., 2016. Multiple fish tracking with an NACA airfoil model for collective behavior analysis. *IPSP Transactions on Computer Vision and Applications*, 8, 1, 1-7.

Thorley, J. L., Eatherley, D. M. R., Stephen, A. B., Simpson, I., MacLean, J. C., Youngson, A. F., 2005. Congruence between automatic fish counter data and rod catches of Atlantic salmon (*Salmo salar*) in Scottish rivers. *ICES Journal of Marine Science*, 62, 809-817.

Tieleman, T., Hinton, G., 2012. Lecture 6.5-rmsprop: Divide the Gradient by a Running Average of Its Recent Magnitude. COURSERA: Neural Networks for Machine Learning, 4, 26-31.

Torisawa, S., Kadota, M., Komeyama, K., Suzuki, K., Takagi, T., 2011. A digital stereo-video camera system for three-dimensional monitoring of free-swimming Pacific bluefin tuna, *Thunnus orientalis*, cultured in a net cage. *Aquat. Living Resour.*, Vol.24, pp. 107-112.

Wang, Y., Zhang, J., Kan, M., Shan, S., Chen, X., 2020. Self-supervised Equivariant Attention Mechanism for Weakly Supervised Semantic Segmentation. In: *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 12272-12281.

Yang, X., Zeng, Z., Teo, S.G., Wang, L., Chandrasekhar, V., Hoi, S., 2018. Deep learning for practical image recognition: case study on kaggle competitions. In: *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining - KDD' 18*. London, UK, pp. 923–931.

Yazawa R, Takeuchi Y, Amezawa K et al (2015) GnRH α -induced spawning of the eastern little tuna (*Euthynnus affinis*) in a 70-m³ land-based tank. *Aquaculture* 442:58–68.

Yazawa, R., Takeuchi, Y., Iwata, G., Kabeya, N., Komoda, A., Yoshizaki, G., 2011. Rearing of Pacific bluefin tuna *Thunnus orientalis* in a 70 m³ land-based tank system. *Aquac Sci* 59:473–481.

Zhang, W., Wu, C., Bao, Z., 2021. DPANet: Dual Pooling-aggregated Attention Network for fish segmentation. *IET Comput. Vis.* 1– 16.

Zivkovic, Z., Heijden, F., 2006. Efficient Adaptive Density Estimation per Image Pixel for The Task of Background Subtraction. *Pattern Recognition Letters*, vol.27, no.7, pp.773 - 780.

“第 1 章 特集 世界とつながる我が国の漁業～国際的な水産資源の持続的利用を考える～”. 水産白書, 平成 28 年度版. 農林水産省. 3-58.

浅野 晃., 2010. マセマティカルモルフロジーの思想. *IEICE Fundamentals Review*, Vol.4 No.2, 113-122.

大津 展之., 1980. 判別及び最小 2 乗基準に基づく自動しきい値選定法. *電気通信学会論文誌*, Vol. J63-D No.4, 349-356.

升間主計., 2019. マグロ資源の管理・保全に向けてー完全養殖の役割. In: 海洋フォーラム.