

原著論文

北海道東部地域で漁獲されるサケの トキシラズ自動判別技術の検討

守谷圭介*1,*2・全 慶樹*3・宮崎亜希子*1

Study on an automatic discrimination technique for grading chum salmon
Oncorhynchus keta as Tokishirazu caught in eastern Hokkaido, Japan

Keisuke MORIYA, Keiki ZEN and Akiko MIYAZAKI

Discrimination viewpoints for grading chum salmon *Oncorhynchus keta*, caught in eastern Hokkaido, Japan, as the fish brand Tokishirazu, by connoisseurs in fishery markets were determined, to develop an artificial intelligence (AI)-based technique using deep learning based on image data. Important factors identified through interviews with market connoisseurs included body depth, body width, skin color, and the size of head and mouth. Linear discriminant analysis using these measured variables achieved an F1 score of 82.6%, a basic metric for assessing classification models. Further, the deep learning model using whole-body images achieved an improved F1 score of 96.1%. These results indicate the possibility of implementing an appearance-based automated discrimination technique for grading chum salmon as Tokishirazu.

キーワード：サケ，トキシラズ判別，目利き，AI
2024年8月26日受付 2025年12月26日受理

北海道の主要な水産物の一つであるサケ *Oncorhynchus keta* は、山漬、新巻や定塩さけフィレといった塩蔵さけなどの水産加工品の原料として幅広く利用されており、日本の食生活に欠かせない魚である。北海道東部地域の沿岸定置網では、春から初夏にかけて成熟途上である索餌回遊期のサケが、秋には性成熟の進んだ産卵回帰期のサケが漁獲されており、それぞれトキシラズ、アキサケと呼ばれている（永田 2003, 清水 2018）。性成熟の進んでいないトキシラズは希少であるため、高値で取引されている。性成熟の進んでいないサケは脂肪量が多い（Ando *et al.* 1985, 清水・帰山 1991, 笠井ら 1997）が、

性成熟に伴って魚体の脂肪量は減少することが知られている（清水・帰山 1991）。アキサケでは脂質含有量 2-3% 以上あることがうまさの必要条件と報告されており（羽田野ら 1987）、サケの性成熟の変化と食味との関連性が示唆されている。しかし、漁期が秋に近づくにつれて、性成熟の進んだサケが増加するため、トキシラズであるか否かを判別する必要が生じる。

サケの外観は性成熟に伴い変化することが知られている（清水・帰山 1991）。産地市場では、サケの性成熟に伴う品質や外観の変化を経験的に把握しており、例えば北海道東部の釧路地域では、水揚げされたサケを漁業協

*1 地方独立行政法人北海道立総合研究機構釧路水産試験場
〒085-0027 北海道釧路市仲浜町4番25号

Kushiro Fisheries Research Institute, Hokkaido Research Organization, Nakahamacho 4-25, Kushiro, Hokkaido 085-0027, Japan
E-mail: moriya-keisuke@hro.or.jp

*2 現所属：地方独立行政法人北海道立総合研究機構食品加工研究センター

*3 地方独立行政法人北海道立総合研究機構工業試験場

同組合の職員による目利きで判別することで、トキシラズであることを認定し、その品質を保証している。目利きとは長年の経験や知識に基づいた熟練者が、良質なものとそうでないものを肉眼識別する能力である。一般に目利きでの生鮮水産物の品質判別は、魚体外観や鮮度、体重などの様々な情報を総合的に判断して行っており、習熟には長期の経験が必要とされている。北海道東部地域では、過疎化や少子高齢化が進んでいることから、トキシラズの目利きが可能な後継者の不足が課題となっており、目利きの継承や省力化、自動化に向けて、現状の目利きと遜色のない新たな判別技術が求められている。

近年、目利きの継承や技術水準の維持を目的とした様々な研究開発が行われている。例えば、魚市場の競り人による外観評価と魚体体表の色彩および魚肉鮮度の関連性の検証（中村ら 2012）や、魚体体表の色彩の測定値によるブリ属 *Seriola* spp. の鮮度推定モデルの開発（中村ら 2018）など、鮮度の評価技術が報告されている。また、人工知能（artificial intelligence, 以下 AI）を使用してマグロ属 *Thunnus* spp. の尾の断面画像から目利きの技術水準で品質を判定できる「TUNA SCOPE」が開発されている（<https://tuna-scope.com/jp/>, 2025年7月11日）。これらの研究開発は、いわゆるパターン認識と呼ばれる技術を水産分野に適用した事例である。しかし、トキシラズに関しては、これまで熟練者による目利きがどのような判断基準で判別しているのかを検証した報告はなく、目利きの際のトキシラズ認定基準が整理されていないことが、目利きの継承や省力化、自動化に向けた新たな判別技術の開発の妨げとなっており、判別を省力化、自動化できる技術が確立されていない。そこで本研究は、トキシラズの目利きの継承や技術水準の維持を目的に、トキシラズ判別における熟練者による目利きの判断基準を明らかにし、数値化することにより魚体の外観情報に基づいた自動判別技術の検討を行った。

なお、パターン認識には数多くのアルゴリズムが存在する。本研究では、数あるアルゴリズムから統計学的手法である線形判別分析と深層学習の一つである畳み込みニューラルネットワーク（Convolutional Neural Network, CNN）を扱うことにした。線形判別分析は、クラス間の分散を分母に、クラス内の分散を分子にとった評価関数を最小化するような評価軸を作成し、その評価軸上の正負で2クラスの判別を行う分析として知られている（間下 2018）。目利きの判別基準を数値化し線形判別分析を行うことは、判別結果が目利きに基づく説明変数から出力されているため認定方法への理解が得られやすい一方で、生物測定や分光測色計による計測が必要となり、自動判別技術の実用化を図る上で普及のハードルが高い。一方で CNN などの画像認識モデルは判別根拠の説明が困難であるが、画像のみを入力として複雑な認識処理が可能であり（Li *et al.* 2021）、スマートフォンなどのカメラを利用した実用化も想定され、普及が比較的容易であ

ると考えられる。そこで本研究では、目利きに基づく判別技術に加え、画像認識モデルを使用したトキシラズ判別技術について検討した。

材料と方法

材料 2019年5月から9月にかけて、北海道東部沿岸の定置網漁で漁獲されたサケを本研究の対象とした。6月から9月に釧路市東部漁業協同組合（以下、漁協）で購入した、トキシラズと認定された22尾（雄：6尾、雌：11尾、性別不明：5尾）、非認定の30尾（雄：14尾、雌：15尾、性別不明：1尾）を、後述する生物測定および職員の目利きに基づく判断基準を分析するための線形判別分析に用いた。また、購入したサケおよび漁協で出荷される直前のサケについてデジタルカメラ（Tough TG-5, オリンパス株式会社）を用いて外観画像データ（4,000 × 3,000pixel, RGB画像, 24bit, JPEG形式）を取得し、目利きに基づくトキシラズ認定結果を予測する画像認識モデルの構築に供した。

生物測定 生物測定は漁協で購入した52尾を対象に行った。すなわち、図1に示すように、サケの尾叉長（Fork length, FL；1mm単位）、体長（Standard length, SL；1mm単位）、吻長（Snout length, SnL；0.1mm単位）、頭長（Head length, HL；1mm単位）、頭高（Head depth, HD；0.01mm単位）、体高（Body depth, BD；0.01mm単位）、体幅（Body width, BW；0.01mm単位）を測定し、併せて体重（10g単位）を測定した。その後、開腹摘出した生殖腺重量（0.01g単位）を測定し、生殖腺重量と体重から生殖腺体指数を次の式により算出した。

$$\text{生殖腺体指数 (\%)} = (\text{生殖腺重量 (g)} / \text{体重 (g)}) \times 100$$

サケの外観画像データの取得 漁協で購入した52尾のサケについては、釧路水産試験場（以下、試験場）で生物測定後に画像を取得した。撮影は、サケを1尾ずつ撮影台に載せ、照明は室内灯を使用し、カメラのISO感度等の設定はデジタルカメラのオートモードを使用して行った。魚体全体の両面を撮影し、1尾あたり2枚の画像を撮影した。その後、同じ個体の頭部のみが写るようにカメラを近接させて撮影し、魚体全体の画像と同数取得した。撮影対象となった52尾のうち、トキシラズと認定されたサケ1尾と非認定のサケ3尾の画像データは欠測し、また非認定のサケ1尾に関しては魚体全体および頭部の両面撮影のうち片面1枚の欠測が生じた。その結果、撮影された画像は、トキシラズと認定されたサケ21尾の42枚、非認定のサケ27尾の53枚であり、合計で48尾分の魚体全体と頭部の画像それぞれ95枚を取得した。なお、9月に漁協で購入したサケ18尾は、目利きによるトキシラズの認定を実施せず、アキサケとして取




図 1. サケの生物測定および色調測定箇所

り扱っているため、全てトキシラズではないものとした。

一方、漁協で出荷される直前のサケについては、5月から9月にかけて、出荷される直前のプラスチックケースに入った状態で1尾ずつ撮影し、トキシラズと認定されたサケ 223尾の画像 223枚、非認定のサケ 76尾の画像 76枚を取得した。カメラの設定は試験場での撮影と同じ条件とした。撮影は人の多い競りの現場で行ったため、追加の照明や撮影台による撮像条件のコントロールは行わず、魚体の鉛直方向約 1mの距離から魚体全体が画像の水平方向に収まるように手動で行い、頭部画像の撮影も試験場での撮影と同様に行い、魚体全体と頭部の画像をそれぞれ 299枚取得した。なお、9月に撮影したサケは全てトキシラズではないものとした。

以上の試験場および漁協での撮影により、トキシラズ 244尾分の魚体全体および頭部の画像それぞれ 265枚、非認定のサケ 103尾分の魚体全体および頭部の画像それぞれ 129枚、計 394枚の画像を取得した。

トキシラズ認定の判断基準項目の把握 2019年4月から6月にかけて、トキシラズの目利きが可能な産地市場職

員 4名、仲買人 2名に対し、目利きに関する聞き取り調査を行った。すなわち、外観からトキシラズであると判断する際に注視する箇所を聞き取り、同じ判断基準項目をあげた人数の割合を回答率 (%) として算出した。

トキシラズ認定の判断基準項目の数値化 目利きに関する聞き取り調査により明らかになったトキシラズ認定の判断基準項目に基づき、生物測定値と色調測定値を用いて形態および体色の数値化を行った。各個体の形態は、以下の式を用いて生物測定値から数値化した。

$$\text{体高率} = \text{BD} / \text{FL}$$

$$\text{体幅率} = \text{BW} / \text{FL}$$

$$\text{頭部面積割合} = (\text{HL} \times \text{HD}) / (\text{SL} \times \text{BD})$$

$$\text{相対吻長} = \text{SnL} / \text{HL}$$

体色の数値化は、背側の体色として背鰭付け根付近、腹側の体色として腹鰭付け根付近の表皮をそれぞれ測定部位とし、各測定部位の L* 値 (明度)、a* 値 (赤～緑の色相) および b* 値 (黄～青の色相) を分光測色計 (CM-600d Spectrophotometer, コニカミノルタ株式会社) で測定することにより実施した。

得られた結果は、エクセル統計 (株式会社社会情報サービス社製) を用いて Mann-Whitney の U 検定を行い、有意水準は 5% としてトキシラズ認定と非認定のサケ間の有意差検定を行った。

数値化した判断基準項目に基づく線形判別分析 数値化した判断基準項目を用い、目利きによるトキシラズ認定の再現性を検討するため、線形判別分析を実施した。本研究では少ないサンプルで安定した結果を得るため二次判別分析ではなく線形判別分析を用いた。具体的には、数値化した判断基準項目を説明変数、目利きによるトキシラズ認定結果を目的変数として、統計解析ソフトウェア R (バージョン 4.3.3) (R Core Team 2018) の MASS パッケージに含まれる lda 関数を用いて線形判別分析を行った。なお、説明変数に用いた数値化した判断基準項目は、体高率、体幅率、頭部面積割合、相対吻長、背側 b* 値、腹側 L* 値の 6 変数とした (結果を参照)。線形判別分析では、以下の 2 つの前提条件が成立する必要がある。(1) 各グループは多変量正規分布している。(2) 全てのグループが同じ共分散行列を持つ (等分散性) (James *et al.* 2013)。当分析に用いたデータは Shapiro-Wilk 検定により (1) の多変量正規性を満たしていることを確認した。(2) の前提条件に関しては、各説明変数に対して分散を安定させデータを正規分布に近づける統計手法である Yeo-Johnson 変換の適用の有無を全ての組み合わせで検討し、Box の M 検定の p 値が最も高くなる組み合わせを求めて変換を適用することで仮定される条件に近づけた。これにより 6 つの説明変数のうち、頭部面積割合、

相対吻長, 背側b*値, 腹側L*値に, Yeo-Johnson変換を適用し (BoxのM検定 $p=0.031$), 線形判別分析を行った。線形判別分析では, 6つの説明変数から変数選択の組み合わせを検討した。説明変数を1つ以上有する全63モデルの評価指標として, 適合率 (precision), 再現率 (recall) および正解率 (accuracy) について, 真陽性 (TP), 真陰性 (TN), 偽陽性 (FP), 偽陰性 (FN) の数を用いて次式により算出した。

$$\begin{aligned}\text{適合率 (\%)} &= \text{TP} / (\text{TP} + \text{FP}) \times 100 \\ \text{再現率 (\%)} &= \text{TP} / (\text{TP} + \text{FN}) \times 100 \\ \text{正解率 (\%)} &= (\text{TP} + \text{TN}) / (\text{TP} + \text{TN} + \text{FP} + \text{FN}) \times 100\end{aligned}$$

さらに, 全63モデルの中から, モデルのパフォーマンスを示すF1スコアを適合率と再現率の調和平均として次式により算出し, F1スコアの高いモデルを最適モデルとして選択した。

$$\text{F1スコア (\%)} = 2 \times (\text{適合率} \times \text{再現率}) / (\text{適合率} + \text{再現率}) \times 100$$

なお, トキシラズは未成熟のため外観からの雌雄判別は困難であり, 産地市場ではトキシラズの雌雄判別は行われていないため, 線形判別分析は雌雄混合のデータで実施した。

トキシラズ認定結果を予測する画像認識モデルの構築

サケの魚体全体または頭部の画像から目利きに基づくトキシラズ認定結果を予測する画像認識モデルをそれぞれ構築した。モデルの予測においてサケの外観情報以外の利用を最小限とするため, 前処理として画像に映り込んだ認定札やメモを塗りつぶして隠すマスク処理を画像編集ソフトウェアGIMP (<http://www.gimp.org/>, 2025年11月5日) により行った。魚体全体および頭部それぞれの画像認識モデルの構築において, 漁協で撮影した299枚の画像と試験場で撮影した95枚の画像の計394枚の画像を使用し, ホールドアウト検証によって汎化性能を評価するため, データを学習用287枚, 検証用31枚, テスト用76枚に分割した。データの分割では, 同一個体の複数枚の画像が異なる分割に分かれないようにするとともに, 学習用, 検証用, テスト用データ間で, トキシラズ認定と非認定の割合がそれぞれ等しくなるようにランダムに分割した。なお, 画像認識モデルでは判断基準の数値化に基づく線形判別分析と同様に雌雄混合で利用した。機械学習では, データ数に対してモデルのパラメータ数が過剰に多い場合に過学習が発生しやすく (James *et al.* 2013), 本研究では一般的な画像認識タスク (例えばStanford Dogsでは画像約2万枚; <http://vision.stanford.edu/aditya86/ImageNetDogs/main.html>, 2025年11月5日) よりデータ数が少ないことから, 普及し

ているCNNアーキテクチャのうちパラメータ数の比較的少ないNASNet (Zoph *et al.* 2018), EfficientNet (Tan and Le 2019), EfficientNetV2 (Tan and Le 2021) から検討した。プログラミング言語にはPython 3.11を使用し, 深層学習フレームワークとしてTensorFlow 2.13をバックエンドとするKeras 2.13を使用した。また, 計算を高速化するためCUDA 11.8, cuDNN 8.8.0をNVIDIA GeForce RTX 3090で使用した。モデルの学習は, 大規模な画像認識データセットであるImageNetで事前学習されたモデルをタスクに合わせて再学習する転移学習により行った。具体的には, KerasのAPIから事前学習モデルを読み込んだ後, 最後の全結合層を取り除き, Global Average Pooling (GAP) 層と過学習を抑制するためのドロップアウト層 (学習時のみ20%のユニットを無効化), ソフトマックス層を追加し, 再学習を行うためのモデルとした。事前学習モデルとしてNASNetのNASNetMobile (パラメータ数5.3百万), EfficientNetの入力画像サイズが224 × 224pixel, 240 × 240pixel, 260 × 260pixel, 300 × 300pixel, 380 × 380pixelであるモデル (パラメータ数5.3~19.5百万), EfficientNetV2の入力画像サイズが224 × 224pixel, 240 × 240pixel, 260 × 260pixel, 300 × 300pixel, 384 × 384pixelであるモデル (パラメータ数7.2~21.6百万) の計11のモデルを使用した。また, 過学習を抑制するためデータを疑似的に増加させるデータ拡張処理を適用した。具体的には, Kerasのlayersクラスを使用して, 入力画像に対する水平および垂直方向へのランダムな反転 (RandomFlipクラス), コントラスト調整 (RandomContrastクラス, 引数0.01), 明るさ調整 (RandomBrightnessクラス, 引数0.05), 拡大縮小 (RandomZoomクラス, 引数(-0.05, 0)), 回転 (RandomRotationクラス, 引数10/360) 処理を適用した。転移学習では学習を安定化させるため, 初めに追加した全結合層のみを最適化アルゴリズムAdam (Kingma and Ba 2015) (学習率 10^{-2}) により50エポック学習し, その後, 全ての層のパラメータをAdam (学習率 10^{-5}) で学習した。ミニバッチサイズは16とし, 2回目の学習ではKerasのcallbacksクラスを使用した早期終了 (EarlyStopping) により, 検証用データの交差エントロピー誤差による損失関数が200エポック改善されない場合に学習を停止した。検証用データにおける損失関数が増加傾向へ転じる前の損失関数の値が最小のモデルを選択し, 学習結果とした。最終的なモデルとして全ての学習させたモデルの中から検証用データの損失が最小のものを最適モデルとして選択し, テスト用データを使用して性能を評価した。なお, データの分割とデータ拡張に使用される乱数のシードは, 本研究を通して固定した。

構築した画像認識モデルが重視している箇所の可視化

機械学習ではデータの不備等により, 構築したモデルが実運用場面では利用できない特徴を使用することで, テ

スト用データに対する性能が高いにも関わらず、汎化性能が著しく低下する場合がある。このような目的外の特徴の学習を検出することを目的として、本研究では構築した画像認識モデルが、入力画像のどの領域に基づいてトキシラズ認定結果を予測しているかを調べるため、畳み込みニューラルネットワークモデルの代表的な予測根拠領域の可視化手法の一つである Grad-CAM (勾配荷重クラス活性化マッピング) (Selvaraju *et al.* 2017) を使用した。具体的には、全結合層直前の畳み込み層に対して Grad-CAM を適用し、モデルが予測において重視したと考えられる箇所の強度が高くなる顕著性マップとして出力し、予測根拠の参考とした。

結果

生殖腺体指数の季節変化 漁協から購入したサケ 52 尾の FL および体重は、それぞれ $639 \pm 51\text{mm}$, $3,440 \pm 720\text{g}$ (平均 \pm 標準偏差) であった。サケの生殖腺体指数の季節変化を図 2 に示した。雄の生殖腺体指数は、7 月まで概ね 3% 以下であったが、7 月以降は 5% を超える個体が漁獲され始め、9 月には 4-7% となり、増加傾向を示した。トキシラズ認定された雄の中には生殖腺体指数が 5% 以上の個体が存在する一方、非認定の雄でも 1-4% 程度の個体が存在していた。雌の生殖腺体指数は、7 月前半まで概ね 3% 以下であったが、7 月後半は 6-9%、9 月には 11-17% となり、雄と同様に増加傾向を示した。トキシラズ認定された雌の中には生殖腺体指数が 5% 以上の個体が存在していた。

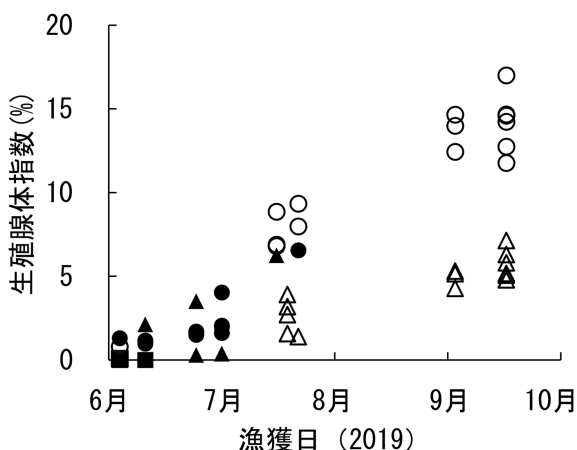


図 2. 北海道東部地域で漁獲されたサケの生殖腺体指数の季節変化

▲: トキシラズ認定 - 雄; ●: トキシラズ認定 - 雌; ■: トキシラズ認定 - 性別不明; △: 非認定 - 雄; ○: 非認定 - 雌; □: 非認定 - 性別不明

トキシラズ認定の判断基準の把握 目利きに関する聞き取り調査結果を表 1 に示した。目利きの際に注視する箇所は、体高率、体幅率、体色、頭部面積割合、相対吻長、眼の色、鰓の色、歯の発達程度、脂鱗の大きさ、鱗の状態、腹部の形状、尾鱗の模様であった。このうち回答率が 80% 以上の項目は、体高率、体幅率、体色、頭部面積割合、相対吻長であった。これらの項目に関するトキシラズの主な特徴は、体高や体幅が大きい、背側の体色が青い、腹側の体色が白い、頭と口が小さいことであった。

表 1. 目利きの聞き取り調査によるトキシラズ認定の判断基準

| 判断基準となる項目 | 回答率 (%) |
|-----------|---------|
| 体高率 | 100 |
| 体幅率 | 100 |
| 体色 | 100 |
| 頭部面積割合 | 83 |
| 相対吻長 | 83 |
| 眼の色 | 50 |
| 鰓の色 | 50 |
| 歯の発達程度 | 50 |
| 脂鱗の大きさ | 50 |
| 鱗の状態 | 33 |
| 腹部の形状 | 33 |
| 尾鱗の模様 | 33 |

回答率: 6 人の目利きが可能な市場関係者のうち、同じ判断基準項目としてあげた人数の割合 (%)

形態の季節変化 目利きに基づく判断基準のうち形態に関するもの (体高率、体幅率、頭部面積割合、相対吻長) の季節変化を図 3 に示した。体高率は、雌雄ともに 7 月以降減少する傾向がみられ、トキシラズ認定されたサケの体高率は非認定の個体よりも高い傾向であった。体幅率も同様に、雌雄ともに 7 月以降減少する傾向がみられ、トキシラズ認定されたサケの体幅率は非認定の個体よりも高い傾向であった。頭部面積割合は、雌では変化がみられなかったが、雄では 6-7 月にかけて大きくなる傾向がみられた。相対吻長は、雌では変化がみられなかったが、雄では 9 月にかけて大きくなる傾向がみられた。体高率、体幅率、相対吻長はトキシラズ認定と非認定のサケの間で有意な差が認められた (U -test, $p < 0.01$)。

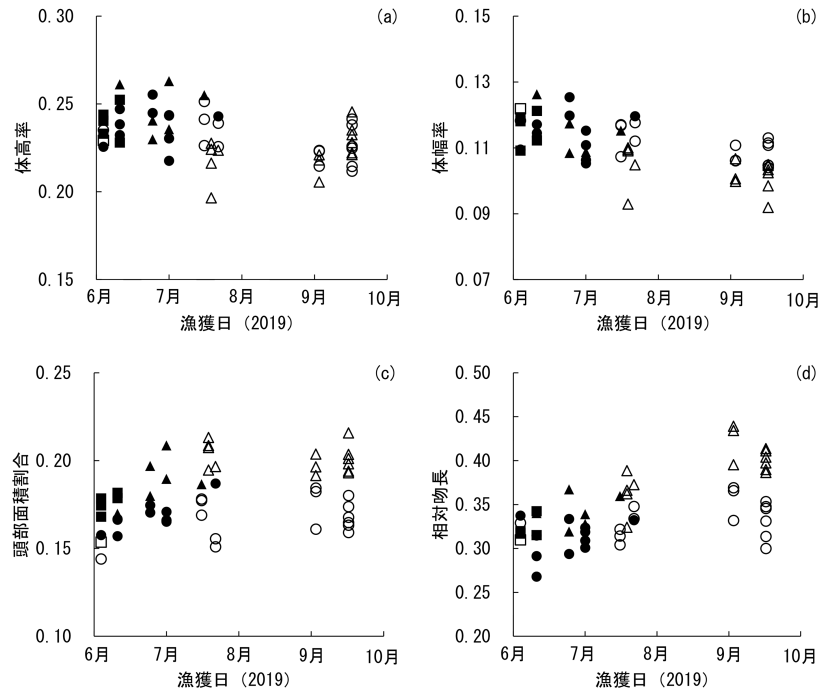


図3. 北海道東部地域で漁獲されたサケの形態の季節変化

(a): 体高率; (b): 体幅率; (c): 頭部面積割合; (d): 相対吻長

▲: トキシラズ認定 - 雄; ●: トキシラズ認定 - 雌; ■: トキシラズ認定 - 性別不明; △: 非認定 - 雄; ○: 非認定 - 雌; □: 非認定 - 性別不明

体色の季節変化 サケの体色の季節変化を図4に示した。背側のL*値, a*値は, 雌雄ともに変化がみられなかったが, b*値は6-7月にかけて雌雄ともに増加する傾向がみられ, 青色度合が低下していた。7月にトキシラズ認定されたサケの背側のb*値は低い傾向がみられ, 非認定よりも青色度合が高かった。腹側のL*値は雌雄ともに6-9月にかけて減少する傾向がみられ, 明度が低下していた。トキシラズ認定されたサケの腹側のL*値は高い傾向がみられ, 非認定よりも明度が高かった。また, 腹側のa*値およびb*値については, 雌では大きな変化がみられなかったが, 雄では9月にかけて増加する傾向がみられた。トキシラズ認定と非認定のサケの間で有意差検定を行った結果, 背側のb*値および腹側のL*値には有意な差が認められた(U-test, $p < 0.01$)。これらの結果および聞き取り調査の結果から, 線形判別分析には, 背側b*値と腹側L*値を用いることとした。

線形判別分析によるトキシラズ判断基準項目の重要度の検討 目利きに関する聞き取り調査およびサケの形態と体色の季節変化の結果から, 数値化した判断基準項目(体高率, 体幅率, 頭部面積割合, 相対吻長, 背側b*値, 腹側L*値)に基づくトキシラズ認定結果に対する線形判別分析を行った。重要な判別基準項目を検討するため, 全63モデルのうちF1スコアが高い上位2モデルのほか, すべての説明変数を使用したモデルおよび各説明変数を単

独で使用したモデルの結果を示す(表2)。説明変数として背側b*値, 腹側L*値, 相対吻長を使用した場合にF1スコア(82.6%)が最も高くなった。次点でF1スコアが高かった組み合わせは, 背側b*値, 腹側L*値を説明変数とした場合で, F1スコアは81.8%であった。全ての判断基準項目を説明変数として使用した場合, F1スコアは75.0%となった。また, 背側b*値, 腹側L*値, 頭部面積割合, 相対吻長, 体高率, 体幅率をそれぞれ単独の説明変数とした場合, F1スコアは75.6%, 76.6%, 12.5%, 63.6%, 66.7%, 63.4%となった。

トキシラズを予測する画像認識モデルの構築 魚体全体の画像を使用した画像認識モデルでは, 検証用データに対する損失が最小のEfficientNetV2(入力画像サイズ: 240 × 240pixel)モデルを選択した。当該モデル学習時のエポックに対する損失と正解率の推移を図5(a)(b)に示す。モデル選択では, 過学習を防ぐために検証用データにおける損失が増加傾向へ転じる340エポックより前のエポックのうち, 損失が最小の267エポックのモデルを選択した。当該モデルのテスト用データに対するF1スコアは96.1%となった(表3)。また, 頭部の画像を使用した画像認識モデルの構築も同様の方法により, EfficientNet(入力画像サイズ: 300 × 300pixel)モデルを選択した。当該モデル学習時のエポックに対する損失と正解率の推移を図5(c)(d)に示す。モデル選択では, 検証用データにおける損失が増

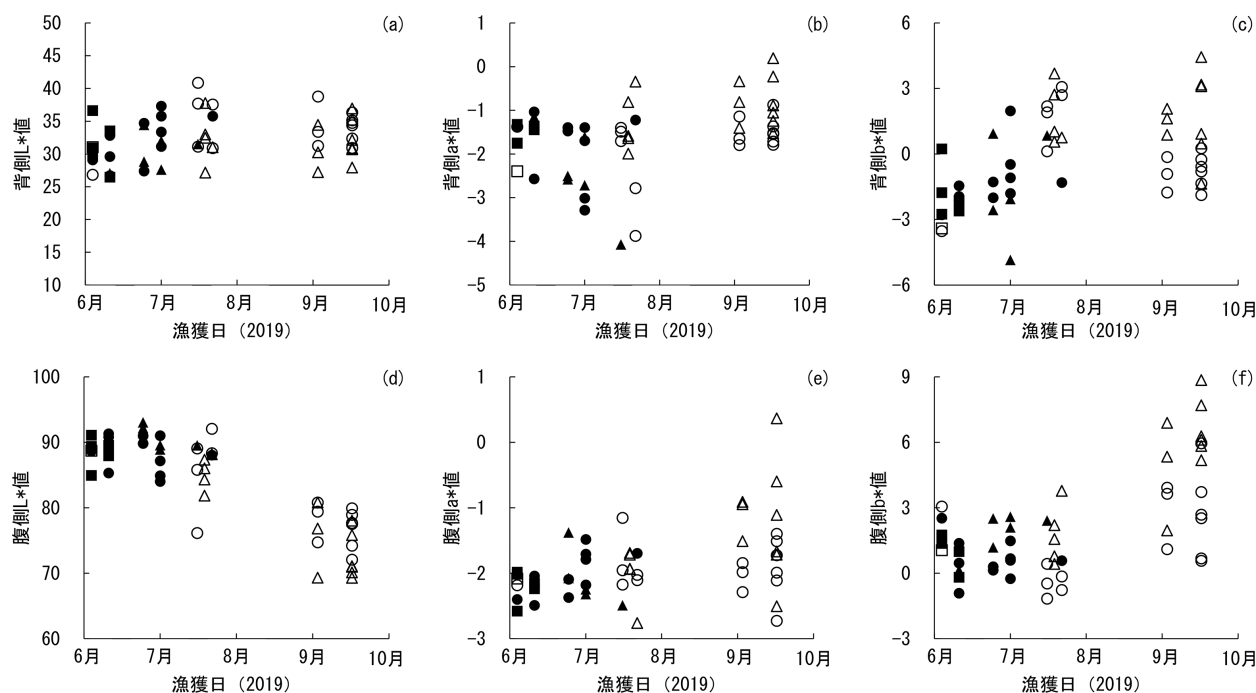


図 4. 北海道東部地域で漁獲されたサケの体色の季節変化

(a): 背側 L* 値; (b): 背側 a* 値; (c): 背側 b* 値; (d): 腹側 L* 値; (e): 腹側 a* 値; (f): 腹側 b* 値

▲: トキシラズ認定 - 雄; ●: トキシラズ認定 - 雌; ■: トキシラズ認定 - 性別不明; △: 非認定 - 雄; ○: 非認定 - 雌; □: 非認定 - 性別不明

表 2. 数値化した判断基準項目に基づく線形判別分析結果

| 使用した説明変数 | | | | | | 線形判別分析結果 | | | | | | | |
|----------|---------|--------|------|-----|-----|----------|----|----|----|---------------|------------|--------------|--------------|
| 背側 b* 値 | 腹側 L* 値 | 頭部面積割合 | 相対吻長 | 体高率 | 体幅率 | TP | TN | FP | FN | Precision (%) | Recall (%) | Accuracy (%) | F1 score (%) |
| ✓ | ✓ | | ✓ | | | 19 | 25 | 5 | 3 | 79.2 | 86.4 | 84.6 | 82.6 |
| ✓ | ✓ | | | | | 18 | 26 | 4 | 4 | 81.8 | 81.8 | 84.6 | 81.8 |
| ✓ | ✓ | ✓ | ✓ | ✓ | ✓ | 18 | 22 | 8 | 4 | 69.2 | 81.8 | 76.9 | 75.0 |
| ✓ | | | | | | 17 | 24 | 6 | 5 | 73.9 | 77.3 | 78.8 | 75.6 |
| | ✓ | | | | | 18 | 23 | 7 | 4 | 72.0 | 81.8 | 78.8 | 76.6 |
| | | ✓ | | | | 2 | 22 | 8 | 20 | 20.0 | 9.10 | 46.2 | 12.5 |
| | | | ✓ | | | 14 | 22 | 8 | 8 | 63.6 | 63.6 | 69.2 | 63.6 |
| | | | | ✓ | | 14 | 24 | 6 | 8 | 70.0 | 63.6 | 73.1 | 66.7 |
| | | | | | ✓ | 13 | 24 | 6 | 9 | 68.4 | 59.1 | 71.2 | 63.4 |

TP: 真陽性; TN: 真陰性; FP: 偽陽性; FN: 偽陰性; Precision: 適合率; Recall: 再現率; accuracy: 正解率; F1 score: F1 スコア

表 3. 画像認識モデルの推定結果

| モデル | | | 予測結果 | | | | | | | |
|------|----------------|----------------|------|----|----|----|---------------|------------|--------------|--------------|
| 入力画像 | アーキテクチャ | 入力画像サイズ (ピクセル) | TP | TN | FP | FN | Precision (%) | Recall (%) | Accuracy (%) | F1 score (%) |
| 魚体全体 | EfficientNetV2 | 240 × 240 | 49 | 23 | 4 | 0 | 92.5 | 100.0 | 94.7 | 96.1 |
| 頭部のみ | EfficientNet | 300 × 300 | 45 | 21 | 6 | 4 | 88.2 | 91.8 | 86.8 | 90.0 |

TP: 真陽性; TN: 真陰性; FP: 偽陽性; FN: 偽陰性; Precision: 適合率; Recall: 再現率; accuracy: 正解率; F1 score: F1 スコア

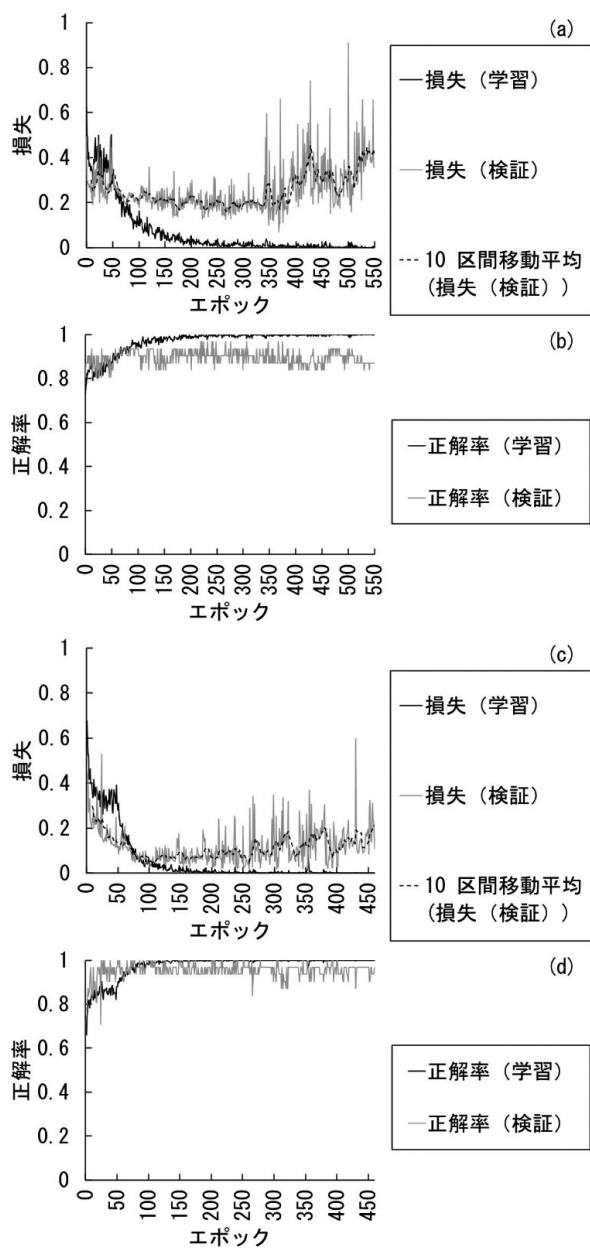


図5. 画像認識モデル学習時の損失と正解率の推移
 (a): 魚体全体画像の損失; (b): 魚体全体画像の正解率; (c): 頭部画像の損失; (d): 頭部画像の正解率

加傾向へ転じる 300エポックより前のエポックのうち、損失が最小の 260エポックのモデルを選択した。当該モデルの F1 スコアは 90.0% となった (表 3)。

画像認識モデルが重視している箇所の可視化 魚体全体画像のモデルに対して Grad-CAM を適用し、対象とした畳み込み層の出力と同じ幅と高さを持つ顕著性マップ (サイズ: 8 × 8) を得た。入力画像と対応する顕著性マップの代表的な例を図 6 に示す。モデルは予測において魚体のある箇所を重視し、背景は重視しない傾向がみられた。なお、

顕著性マップで数値の高かった魚体部位と漁獲時期やトキシラズ認定の有無との関連はみられなかった。

考 察

本研究では、トキシラズ認定における目利きの継承や省力化、自動化に向けて、熟練者による目利きと遜色のない新たな自動判別技術の開発を目指して取り組んできた。自動判別技術を検討する際に重要となるのは、サケの性成熟に伴う外観等の変化を客観的に把握することと、目利きが可能な市場関係者が着目している判断基準を明確化し、なおかつ、それらを数値化することである。これら一連の作業をトキシラズ認定魚と非認定魚の間で対比させることが当該技術開発の初歩では極めて重要なプロセスとなる。

サケの生殖腺の季節変化を調べた結果、雌雄により生殖腺体指数の変化に差はみられるものの 9月に増加する傾向がみられ、雄は 4-7%、雌は 11-17% といずれも高い数値であった (図 2)。清水・野村 (1986) は、6月に門別沿岸で漁獲されたサケでは雄が 0.6%、雌は 1.1% と雌雄ともに著しく低い値であるのに対し、9月に雄武沿岸で漁獲されたサケでは雄が 5.8%、雌が 12.6% で、性成熟に伴う変化は雌雄により異なっていると報告している。また、Ando *et al.* (1985) も索餌回遊期のサケの生殖腺体指数では雄が 0.1%、雌が 1.3% であるのに対し、産卵回帰期のサケでは雄が 6.3%、雌が 17.2% と大幅に増加し、雌雄間で生殖腺体指数の変化が異なっていると報告している。したがって、本研究で供したサケの生殖腺体指数の変化は、これまでの報告と同様の傾向であると確認された。トキシラズ認定されたサケの生殖腺体指数は雌雄ともに概ね 3% 以下であったが、中には雌雄ともに生殖腺体指数が 5% 以上の個体が存在していた (図 2)。一方で、非認定のサケの雄の生殖腺体指数の中には 1-4% 程度の個体が存在していた (図 2)。これらのことから、4月から7月の北海道東部地域の沿岸定置網では、トキシラズでありながら生殖腺体指数の高い魚が存在する一方で、非認定魚でありながら生殖腺体指数の低い魚が存在する実態が確認された。生殖腺体指数とトキシラズ認定が不一致だということは目利きの判断が難しいことを示している。しかし、これまでのトキシラズ認定は人間の肉眼識別によるものであるため、それが目利きの誤りとはいえない。これまでの研究報告より、生殖腺体指数が低いサケをトキシラズとされているため (永田 2003, 清水 2018)、性成熟が進んだ個体と区別するための精度の高い判別技術の開発だけでなく、科学的根拠に基づいたトキシラズ認定の標準化の検討が必要と考えられた。

トキシラズ判断基準の聞き取り調査において回答率が高かった項目は、体高率、体幅率、体色、頭部面積割合、相対吻長であった (表 1)。体高率と体幅率は雌雄とも

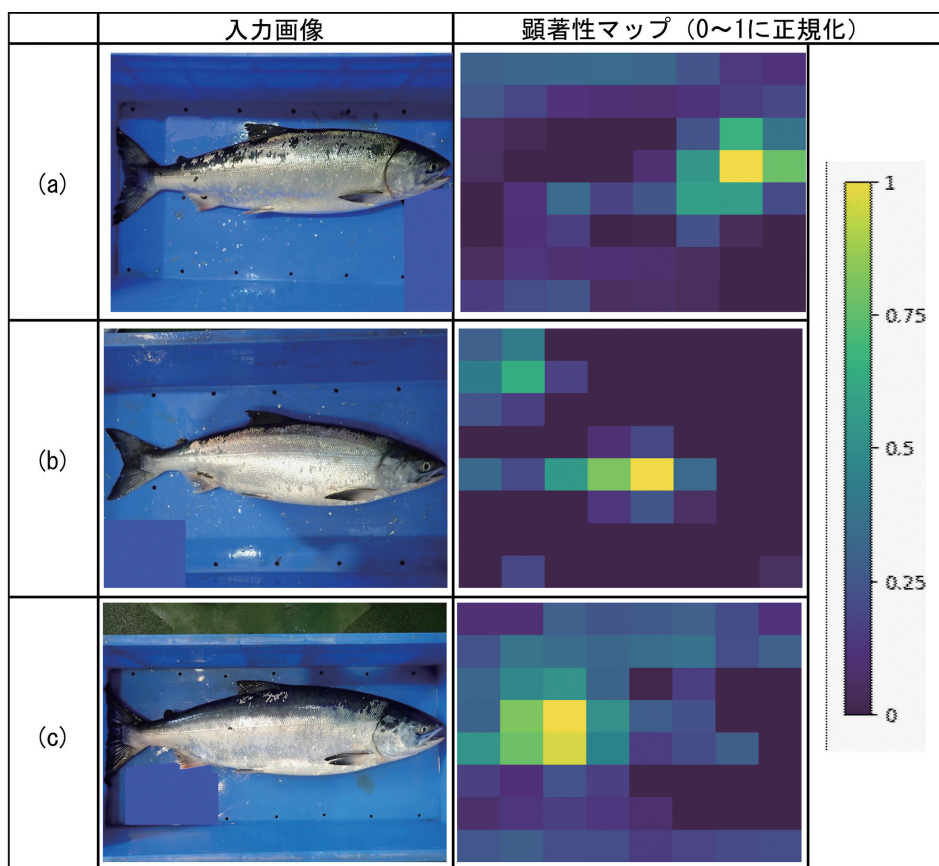


図 6. 構築した画像認識モデルにおける Grad-CAM の代表的な顕著性マップ

- (a): 頭部を重視した顕著性マップ; (b): 魚体中央部を重視した顕著性マップ;
(c): 尾部を重視した顕著性マップ

に7月以降減少する傾向がみられた。頭部面積割合および相対吻長は雄において6-9月にかけて変化していた(図3)。また、体色は雌雄ともに6-9月にかけて変化していた(図4)。目利きにおいて重要であると考えられる頭部、体高、体幅に関して、清水・帰山(1991)は、これらの部位が性成熟に伴って変化し、特に雄において顕著であると報告しており、本研究においても同様の傾向がみられた。本研究では、トキシラズ認定されたサケは体高率および体幅率が大きく(図3)、背側は青く、腹側は明度が高い傾向がみられた(図4)。これらの結果は、トキシラズ認定における目利きの聞き取り調査で得られたトキシラズの特徴と一致していた。以上のことから、長年にわたり様々な性成熟度のサケを見てきた市場関係者は、これらの部位の違いを経験的に認識し、トキシラズを判別していると推察された。

線形判別分析の結果、サケ外観の測定データからトキシラズを比較的高い性能で判別できることが明らかとなった(表2)。また、数値化した判断基準となる形態および体色を全て用いた場合と体色を単独で用いた場合の性能が同程度であった(表2)。一方、頭部面積割合

や相対吻長を単独で用いた場合の性能が低くなったのは、サケの外観変化に雌雄差があるためと考えられた。これらのことから、目利きに基づく判断基準のうち、雌雄ともに外観変化のみられた体色が最も重要な判断基準となると推察された。本研究の結果では、体色と相対吻長を用いた場合にF1スコアが最も高かったが、これは雌雄ともに外観変化のみられた体色に対して、外観変化に雌雄差のある吻長を補うことで、体色を単独で用いた場合の性能よりも精度が向上したためと考えられた。

サケの外観画像からトキシラズを判別する画像認識モデルを構築した結果、魚体全体または頭部の画像を使用したモデルは、F1スコアがそれぞれ96.1%と90.0%と高い予測性能を示した(表3)。本研究では、光源等の厳密な撮影条件を揃えていないが、この判別性能により、その影響は無視できると考えられた。魚体全体の画像を使用したモデルの性能は、頭部のみの画像を使用したモデルより性能が高いことから、頭部のみの画像では利用できない魚体の形態や体色などの特徴がトキシラズ認定結果の予測において重要であると推察された。この結果は、線形判別分析において体色(背側b*値および腹側

L*値)が最も重要な判別基準と示された結果や目利きの聞き取り調査の結果と整合している。このことから、画像認識モデルと目利きが類似した観点でトキシラズを認定している可能性が考えられた。また、画像認識モデルの構築に使用したデータ数が少ないことから一般に過学習が懸念される。そこで、過学習への対策としてデータ拡張やドロップアウト層などとともに、学習において検証用データの損失が増加傾向へ転じる前の損失が最小のモデルを選択することで、過学習を抑制した(図5)。一方、過学習は発生していないがモデルが実運用場面で利用できない特徴を学習することで汎化性能が著しく低下する場合がある。そこで、画像認識モデルの予測根拠の可視化手法を用いて目的外の特徴の学習について検出を試みた。魚体全体のモデルにGrad-CAMを適用し、入力画像に対する顕著性マップを出力した結果、背景を重視しない傾向がみられたことから、モデルは魚体以外の特徴を予測に使用していないことが示唆された(図6)。しかし、Grad-CAMなどの説明可能なAIは、予測根拠を確実に保証するものではなく、目的外の特徴を学習している可能性を完全には排除できない。モデルの汎化性能の推定精度を高めるため、より多様性のある学習データに基づくモデルの構築が今後の課題である。また、本研究の結果は2019年のサンプリングに基づく解析結果であるため、年によって認定基準が変化していないのか、あるいはモデルの説明変数に違いがないのかといった検証がされていない。さらに、月ごとにトキシラズ認定魚と非認定魚のサンプル数を一定数に揃えていないため、漁獲月のバイアスに関する検証がされていない。

以上から、複数年の調査データに基づく検証などの課題は残されているものの、サケの外観情報からトキシラズを判別できる可能性が示唆された。本研究では、目利きの継承や技術水準の維持を目的に釧路地域の目利きによるトキシラズ認定結果を線形判別分析では目的変数として、また画像認識モデルでは入力データとしてそれぞれ実験を行ったが、トキシラズの認定基準は北海道内の各地域によって異なっている。そのため、本研究の実用化、北海道内への普及にあたっては、各地域の漁業協同組合や流通関係者などの共通の理解を得た、トキシラズ認定の標準化が求められる。今後、標準化に向けてサケの生殖腺体指数や外観変化に関するデータをさらに積み重ね、流通関係者等の主観評価との関連性を詳細に調査する必要があると考えている。

謝辞

聞き取り調査に協力頂いた釧路市東部漁業協同組合をはじめとした市場関係者の皆様にご心からお礼申し上げます。

文献

- Ando S, Hatano M, Zama K (1985) Deterioration of chum salmon (*Oncorhynchus keta*) muscle during spring migration-1. Changes in proximate composition of chum salmon muscle during spawning migration. *Comp. Biochem. Physiol. B*, **80**, 303-307.
- 羽田野六男・高橋是太郎・高間貞敏・中島登三 (1987) 秋サケ肉質の官能評価. 北大水産彙報, **38**, 311-321.
- James G, Witten D, Hastie T, Tibshirani R (2013) An introduction to statistical learning. Springer, New York, 621p.
- 笠井孝正・大澤昭彦・日笠志津・辻村 卓・長谷川忠男 (1997) 低生殖腺体指数シロザケ背肉の一般成分、脂肪酸組成および無機質含有量. 食科工誌, **44**, 724-730.
- Kingma DP, Ba JL (2015) Adam: a method for stochastic optimization. in "Proc. 3rd International Conference on Learning Representations" (ed. by Bengio Y, LeCun Y).
- Li Z, Liu F, Yang W, Peng S, Zhou J (2021) A survey of convolutional neural networks: analysis, applications, and prospects. *IEEE Trans. Neural Netw. Learn. Syst.*, **33**, 6999-7019.
- 間下以大 (2018) 機械学習は線を引きアルゴリズム. 映像情報メディア学会誌, **72**, 412-417.
- 永田光博 (2003) 26. サケ(シロザケ) *Oncorhynchus keta* (Walbaum). 「漁業生物図鑑 新北のさかなたち」(上田吉幸・前田圭司・嶋田宏・鷹見達也編). 北海道新聞社, 北海道, pp. 132-137.
- 中村 誠・太田博光・平雄一郎・森元映治・江副 覚・前田俊道・三好佳廣 (2012) 鮮魚の熟練の品質評価の解析-彩度の低い魚種の外観評価について-. 人間工学, **48**, 142-149.
- 中村 誠・渡邊敏晃・椎木友朗・徳永憲洋・太田博光・前田俊道 (2018) ファジィ推論を用いたブリ属の鮮度推定モデル. 知能と情報, **30**, 509-516.
- R Core Team (2018) R: a language and environment for statistical computing. R Foundation for Statistical Computing, Vienna.
- Selvaraju RR, Cogswell M, Das A, Vedantam R, Parikh D, Batra D (2017) Grad-cam: Visual explanations from deep networks via gradient-based localization. in "Proc. 2017 IEEE International Conference on Computer Vision", pp. 618-626.
- 清水幾太郎 (2018) サケ定置網漁業による六次産業化と漁村活性化のための課題. 地域漁業研究, **58**, 20-29.
- 清水幾太郎・野村哲一 (1986) サケの産卵回遊時における体成分の変化. さけ・ますふ研報, **40**, 1-9.
- 清水幾太郎・帰山雅秀 (1991) 産卵回遊期におけるサケの生物学および化学的特性. さけ・ますふ研報, **45**, 47-56.
- Tan M, Le QV (2019) Efficientnet: rethinking model scaling for convolutional neural networks. in "Proc. 36th International Conference on Machine Learning" (ed. by Chaudhuri K, Salakhutdinov R), pp. 6105-6114.
- Tan M, Le QV (2021) Efficientnetv2: smaller models and faster training. in "Proc. 38th International Conference on Machine Learning" (ed. by Meila M, Zhang T), pp. 10096-10106.

Zoph B, Vasudevan V, Shlens J, Le QV (2018) Learning transferable architectures for scalable image recognition. in "Proc. IEEE Conference on Computer Vision and Pattern Recognition", pp. 8697–8710.