

公立はこだて未来大学 2020 年度 システム情報科学実習
グループ報告書

Future University Hakodate 2020 System Information Science Practice
Group Report

プロジェクト名

フィッシュカウンター

Project Name

Fish Counter

グループ名

ぎょたんチーム

Group Name

Fish Finder Team

プロジェクト番号/Project No.

14-B

プロジェクトリーダー/Project Leader

吉野遊 Yuu Yoshino

グループリーダー/Group Leader

吉野遊 Yuu Yoshino

グループメンバ/Group Member

只野航 Wataru Tadano

吉野遊 Yuu Yoshino

毛利心之佑 Shinnosuke Mouri

上澤憂人 Yuto Uesawa

菅原直哉 Naoya Sugawara

指導教員

長崎健 和田雅昭

Advisor

Takeshi Nagasaki Masaaki Wada

提出日

2021 年 1 月 14 日

Date of Submission

January 14, 2021

概要

本プロジェクトでは、情報処理で函館市の水産業を支援することを目的とし、漁業者に実際に活用され役に立つシステムを作ることを活動の目標とする。私たちのグループは函館市の水産業のうち、定置網漁業を対象とした。

前期は、定置網内に設置された魚群探知機から得られる音響データを利用し、機械学習により漁の成果を推定するシステムを構築した。しかし、漁獲量の判別の指標になるまでの成果が得られず、予想が難しいことが明らかになった。

その後、南茅部町で定置網漁船に乗船し、漁業者にヒアリングを行った。その結果、ブリの大きさを知りたいというニーズを確認し、後期はブリの大きさを判別するシステムの構築を目指し活動を行った。

高い予測精度を実現するため、「魚影の形」と「回遊速度」に着目しデータセットの作成を行い、畳み込みニューラルネットワークにより推定をした。

推定の結果、90 %を超える精度での予測を行うことが可能であった。また、実際に漁業者に推定の結果を使ってもらった。今後は、予測の精度を高めるとともに推定手順を自動化し、実用的なサービスとして提供していきたい。

(※文責: 只野航)

Abstract

The aim of our project to support the fisheries industry in Hakodate using ICT, and we have been trying to develop a useful system for fishermen. We conducted several investigation and decided to focus on the set-net fishing.

The first semester, we constructed a system which can predict the catch result by acoustic data from fish finder installed in the set-net. However the result did not enough to support the fishermen. After that, we accompanied the set net fishing in "Minamikayabe" Town and discussed their needs with fishermen. Then, we found the need to know the size of yellowtail. The second semester, we have been trying to construct a system that can predict the size of yellowtail.

In order to improve the prediction accuracy, we created a data set focusing on "fish shadow shape" and "migration speed", and predicted it by a convolutional neural network.

As a result, it was possible to make a prediction with an accuracy of over 90 %. In addition, we got the feedback from the fishermen about the prediction results. For the future works, we will provide the practical system by improving the accuracy of prediction and automate the prediction process.

(※文責: 只野航)

目次

第 1 章 背景	1
1.1 函館市の漁業と先行研究	1
1.2 現状における問題点	1
1.3 課題の概要	2
第 2 章 到達目標	3
2.1 本プロジェクトにおける目的	3
2.2 プロジェクト学習で行う利点	3
2.3 具体的な手順・課題設定	3
2.4 課題の割り当て	4
第 3 章 課題解決のプロセスの概要	5
3.1 プロセス概要	5
3.2 課題提起	6
3.3 定置網の仕組み	6
3.4 データについて	7
3.5 データの可視化	7
3.6 周波数解析について	8
3.7 データ画像の分割について	8
3.8 データセットについて	9
3.9 人工知能の利用	9
3.10 ブリの判別	9
3.11 システムモデル	10
第 4 章 課題解決プロセスの詳細 (前期)	11
4.1 漁業の現状の把握とテーマ決め	11
4.2 目標の設定	11
4.3 環境の設定	12
4.4 定置網における魚種・漁獲量予測	12
4.5 人工知能を利用するための準備	13
4.5.1 魚群データの可視化	13
4.5.2 データセットの作成	13
4.5.3 ニューラルネットワークの利用	13
第 5 章 課題解決プロセスの詳細 (後期)	15
5.1 漁業者への聞き取り	15
5.2 テーマの再検討	15
5.3 ブリの大きさを判別する方法	16
5.3.1 魚影の形	16

5.3.2	回遊速度による周期性	17
5.4	環境設定	18
5.5	データセットの作成と人工知能の利用	18
5.6	実装	19
5.7	漁業者からのフィードバック	19
第6章	作成したデータセットとその結果(前期)	21
6.1	サケの2値分類	21
6.2	サケの多値分類	21
第7章	作成したデータセットとその結果(後期)	23
7.1	ブリの大きさとその他の魚種との判別	23
7.1.1	分割した魚群探知機の音響データ画像	24
7.1.2	深さごとのフーリエ変換の画像	24
7.1.3	短時間フーリエ変換画像	25
7.1.4	まとめ	25
7.2	ブリが定置網内に存在するか否かを判別	25
7.2.1	魚群探知機の音響データ画像	25
7.2.2	分割した魚群探知機の音響データ画像	26
7.2.3	深さごとのフーリエ変換の画像	26
7.2.4	深さごとのフーリエ変換を短い時間で行なった画像	27
7.2.5	短時間フーリエ変換画像	27
7.2.6	まとめ	28
7.3	ブリの大きさの判別	28
7.3.1	分割した魚群探知機の音響データ画像	28
7.3.2	深さごとのフーリエ変換の画像	29
7.3.3	深さごとのフーリエ変換を短い時間で行なった画像	29
7.3.4	短時間フーリエ変換画像	30
7.3.5	まとめ	30
7.4	後期結果まとめ	30
第8章	発表会	31
8.1	プロジェクト内発表-前期	31
8.2	中間発表会	31
8.3	プロジェクト内発表-後期	32
8.4	成果発表会	32
第9章	今後の課題と展望	34

第1章 背景

1.1 函館市の漁業と先行研究

私たちの住む函館市は、函館市水産振興計画によると、太平洋および津軽海峡に囲まれているほか、天然の良港にめぐまれている。また、周辺海域に流れ込む暖流(対馬海流)および2つの寒流(リマン海流および親潮)は豊かな海を育み、函館市の漁業成長の起因になっている[1]。その一方、200海里経済水域が設定されたことなどによる漁業の終焉が地域に多大な影響を及ぼし、周辺漁業は繁栄と衰退を辿ってきた。そしてまた、近年の海洋環境の変化がこの豊かな海の生態系に異変をもたらしており、過剰漁獲などを避けていかなければならない。定置網漁業は過剰漁獲に陥りにくく、継続的な漁業が可能な環境にやさしい漁法と言われており、函館市における漁業種類別漁獲量のうち、約50%を占める主要漁法でもある[2]。

過剰漁獲を防ぐ方法として、魚種によって予め獲る量を制限したTAC(漁獲可能量制度)が存在し、水産資源の管理を行っていた。定置網漁業は環境にやさしい漁法ではあるが、魚種を選択して水揚げを行うことが難しい。2017年には北海道の定置網漁業によって、産卵前の太平洋クロマグロ(30kg以下の個体をメジマグロと呼ぶ)の漁獲量がTACで定められている基準を超えて漁獲された[3]。魚群探知機による魚種判別の先行研究として、平間ら(2018)のシステムモデルの作成が挙げられる[4]。入力した音響画像から判別対象の各クラスの存在確率Xを出し、その他とメジマグロの2クラス分類を目標としていた。教師データ数は横25×縦165ピクセルにセグメントされた画像であり、メジマグロ分約2万枚、その他分約2万枚分のうち、学習に用いたのは約3万枚であった。先行研究の実験結果はメジマグロとその他の分類において、約86%の正答率を示している。

(※文責: 上澤憂人)

1.2 現状における問題点

魚は潮の流れに沿って回遊する性質がある。定置網漁業はそのポイントに網を設置し、網の中へと誘導、最終的に箱網と呼ばれる魚が逃げにくい構造になっている場所まで誘導する。そして箱網内を泳ぐ魚の一部を水揚げしている。したがって、定置網漁業には水揚げ時の魚種の選択や把握が難しい特徴が見られる。そこで、魚が周回している箱網内に魚群探知機を設置し、魚群探知機から得られる音響データを利用して漁の事前にある程度の魚種の把握を試みている。しかし、長い時間の中で培った知識と勘を持ち合わせる漁業者であっても、魚種の判断に頭を抱えることがある。そのため、事前に魚種の判断や漁獲量の予測などを行う際に、AIによって人間の思考の支援を行うシステム等の構築が望まれている。

システムの構築を行う上で、利用者の実際の声を訊くことが必要であると考え、和田先生協力の元、漁業者に直接話を伺う機会を得た。令和2年9月10日、乗船が決定した。午前4時頃、小雨の降る中、南茅部の木直漁港を出港した。当日はブリ(3kg以上の個体)が405kg、イナダ(ブリのうち、1~3kgの個体)が2212kg、主に獲れていた。帰港後、実際に話を伺った。先も記述したように、漁獲制限が規定されたマグロが定置網内にいることは出港する前から事前に把握しておきた

いこと、ブリなどの魚種の水揚げされる量が予測出来れば船に積載する箱や氷の量を変更し、コスト削減が見込めることが、網に混ざった越前クラゲの事前把握をしておきたいこと、漁獲量が少なくなってきたイカの事前把握を出来ないか、など現在の定置網漁における悩みを訊くことが出来た。

(※文責: 上澤憂人)

1.3 課題の概要

本プロジェクトでは、1.2で記述した漁業者による悩みを解決するために、魚群探知機から得られる音響データを元に音響画像を作成し、魚種判別や漁獲量の推定を目標に活動を行った。魚群探知機から得られるデータを利用するとあるが、浮き袋を持たない魚種は魚群探知機に反応しづらいという特徴があるため、越前クラゲとイカの魚種判別は難しいと判断した。そこでマグロかブリに絞られることになるが、機械学習を行っていく上では、サンプル数の量が重要になるため今回はブリが定置網内にいるかいないかの判別とブリがいる前提において、ブリ・イナダ・フクラゲ(ブリのうち、1kg未満の個体)の3つのそれぞれの漁獲予測を進めることになった。

一周約200mの箱網をブリの群れが回遊していると仮定する。また、魚群探知機は箱網のある一点の反応を取っているため、ブリが上記のように回遊しているのであれば、得られる反応に周期性が見られるはずである。その周期性を利用してブリとその他の魚種の判別を行っていく。また、ブリが存在するという予測の元、ブリの大きさごと(ブリ、イナダ、フクラゲ)の分類にも同時に行う。機械学習には、ソニーの提供する NNC(ニューラルネットワークコンソール)を用い、ニューラルネットワークの構築を目指す。前処理として、周波数解析を用いて、音響データを加工し、ラベル付けの後、畳み込みニューラルネットワークを行う。また、データの処理やそれに伴う計算手法も目標としている。

(※文責: 上澤憂人)

第2章 到達目標

2.1 本プロジェクトにおける目的

本プロジェクトは、函館市東部（南茅部町）の定置網漁業における漁獲量を予測し、漁業者のサポートを行うことを目的としている。定置網に設置された魚群探知機のデータを活用し、漁に出る前におおよその網内の魚の量を魚種別に予測する。これによって漁業者の網を引きあげるタイミングや、船に積載する道具、氷を準備する際の意思決定を支援することができると考える。また、漁港との連携が取りやすくなり流通の向上が期待できる。特に、漁業者からの意見も踏まえ、一年を通じて水揚げが多いブリ（イナダ、フクラゲを含む）の漁獲量予測が最も前述のこととに有効的であると考え、技術的目標とした。最終的には、この技術を実際に南茅部町の漁業者を利用してもらいフィードバックを得て、改善や新たな問題解決を試みる。また、函館市の漁業の活性化や情報化の推進を図る。この活動全体を通して、各人が機械学習とデータ処理、その応用までのプロセスを修得することを目指す。機械学習では主に畳み込みニューラルネットワークを用いた画像の学習について学ぶ。また、獲得した技術を用いて知りたい情報を求めるために活用できる能力を身に付ける。

(※文責: 菅原直哉)

2.2 プロジェクト学習で行う利点

プロジェクト学習として行うことで、一つの問題を解決するにあたって、多くの視点をもって開発を行うことができる。また、このような機械学習を用いてデータを処理する場合の学習用データセットの作成には、多くのパターンを効率的に試す必要がある。したがってグループで活動することで学習や開発を多角的かつ効率的に推し進めることができる。また、指導教員の和田先生のもと南茅部町の漁業者から協力を得られる。実際に現地に行き、定置網漁業の見学と聞き取りによる調査を実施し有益な課題を見出せる。

(※文責: 菅原直哉)

2.3 具体的な手順・課題設定

1. グループの構成

話し合いの結果から、魚群探知機データの活用を図るぎょたんチームとアワビ養殖のサポートをするあわびチームに分かれ活動する。それぞれグループリーダーを決定し活動の方針を立てる。

2. 現状の分析・調査

従来の漁業におけるICTやAIの活用についての調査。漁業全体と函館についての問題に分別をつけつつ情報を収集。函館の漁業の情報化に関する先行研究の学習。定置網漁業における魚群探知機の利用と関連性のある活用例を調査。

3. 目標設定

函館市の定置網漁業における魚群探知機のデータを利用し、漁業者のサポートを行うシステムの構想。機械学習を行うための技術の習得。

4. 技術の学習

魚群探知機データの処理と機械学習のモデルについて学習する。後期に向け、データセットの作成、機械学習の実行、結果の考察までのプロセスを修得する。
-データの処理：学習のために蓄積された CSV データからデータセットを作成。
-機械学習：ディープラーニングや畳み込みニューラルネットワークを用いて学習を行う。クラスタリングや数値の予測などの手法を学ぶ。

5. フィールドワーク

現地を実際に見学し定置網漁業の仕組みを理解する。漁業者へのヒアリングを行い問題点や需要を明確にする。

6. 具体的な目標の設定

フィールドワークを参考に、予測をする内容を明確に設定する。周波数解析など、新しく必要となる技術を学習する。

7. システム構築

目的の予測・判別を行うためのデータセットと学習モデルの構築。学習モデルを用いて新しいデータに対して推論を行う。

8. 結果の比較・検討

異なる手法で行った予測・判別の結果を比較しそれぞれの特徴を理解し、改善策を検討する。システム構築と成果の比較・検討を繰り返し行い、精度向上を図る。

9. フィードバック

漁業者に一定期間推論結果を提供し、その感想を聞く。フィードバックから改善点や今後の展望を考察する。

(※文責: 菅原直哉)

2.4 課題の割り当て

前期の活動においては、各人へ課題を割り当てていない。必要な技術に対して、適宜グループメンバーを分割して学習し、互いに得た情報を共有することで効率的に習得を試みた。後期ではブリの予測について、魚群探知機データを単に画像化するものと、周波数解析後の数値を画像化する二つの異なる方法で生成した学習用画像についてディープラーニングを行った。これより、この二種類の画像それぞれについて学習を行う二つの班を作成した。只野、毛利、菅原は純粋に画像化する方法で、それぞれが最適だと考えた学習データのラベリングを行った。その学習結果の比較や改善を行い判別を試みた。吉野、上澤は周波数解析について学習したのち、効果が得られると考えたいくつかの魚種に対して分類する学習を行った。結果から周波数解析による分類の精度を評価し、漁獲予測への応用を目指した。

(※文責: 菅原直哉)

第3章 課題解決のプロセスの概要

3.1 プロセス概要

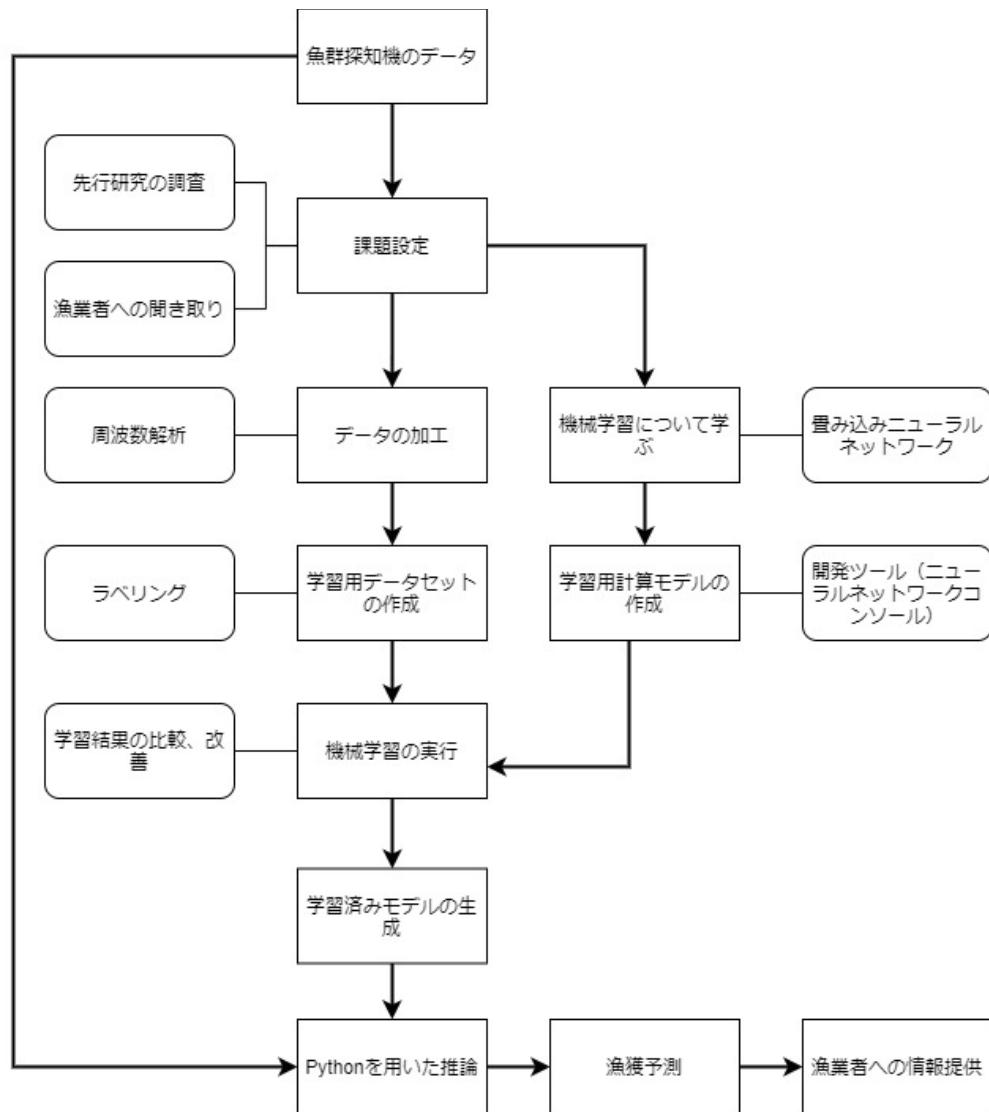


図 3.1 プロセスモデル

私たちが行う活動のプロセスの概要を図 3.1 のようにフローチャート形式でモデル化した。魚群探知機のデータから漁獲予測までのシステムについて段階的な構造とそのとき必要な学習や技術を関連付けている。このプロセスモデルに従って課題解決に向けて開発を推し進めた。

(※文責: 菅原直哉)

3.2 課題提起

函館市の定置網漁業における問題点として、漁業者の勘や経験に頼る部分が大きいことが挙げられる。漁業者の勘や経験とは漁業者が魚群探知機のデータを確認した時、これまでの経験を生かしてどの種類の魚が定置網内にいるのか予測することである。私たちは、この課題をディープラーニングによって、より正確に定置網内の魚種を把握することを目指とした。解決方法としては、担当教員である和田先生の協力のもと、定置網内に設置された魚群探知機のデータをディープラーニングによって学習することで魚種・漁獲量を予測することである。

(※文責: 毛利心之佑)

3.3 定置網の仕組み

定置網の仕組みとしては、以下の図 3.2 のようなものになっている。まず、魚の群が垣網に沿って運動場へと入っていく。運動場へ入った魚は運動場の網に沿って泳ぎ、その一部が箱網へと入っていく仕組みになっている。運動場へ入った魚は確実に逃れられないわけではない。魚群探知機が設置されている場所としては、箱網に魚が入っていく場所と箱網の中に設置されている。

(※文責: 毛利心之佑)

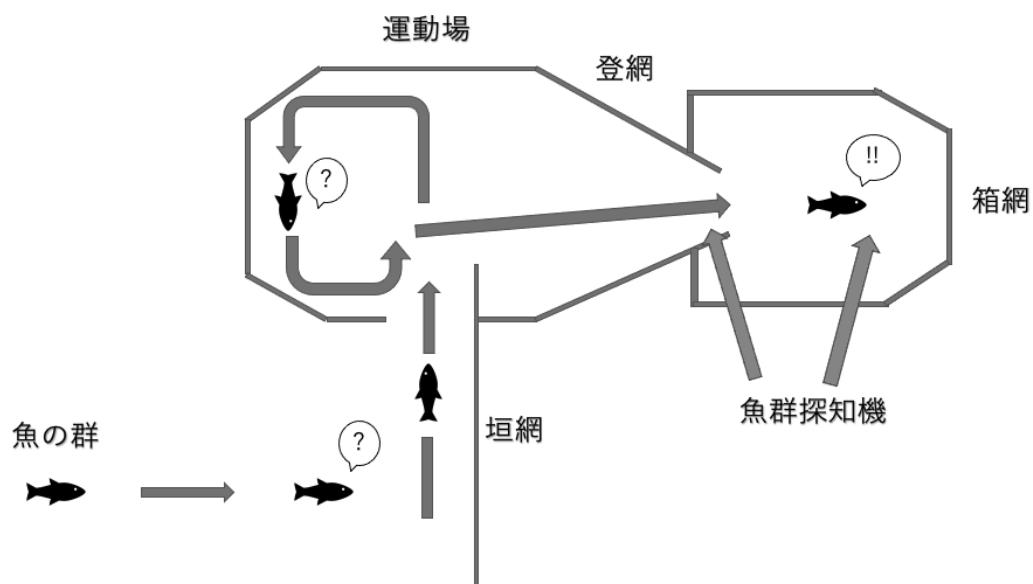


図 3.2 定置網の仕組み

3.4 データについて

魚群探知機からサーバーへ送られるデータについて、以下の図 3.3 のような csv 形式のデータがサーバーに保存されている。Unix 時間とはコンピュータ上での時刻表現の一種であり、3 秒毎に魚群探知機から送られる音波の反射による強弱によって 16 進数の値が記録される。実際に私たちが使用したデータは、平成 30 年 1 月 1 日から 12 月 31 日と平成 31 年 4 月 5 日から令和元年 12 月 19 日と令和 2 年 1 月 1 日から 10 月 31 日である。

(※文責: 毛利心之佑)

Unix時間	強弱を表す16進数の値
1572447600	ffffffff507484b2a8bbb8ada294a7a3aea7...
	...
1572447603	ffffffff6e81adb6a8ae9f9d8b98a69da09a...
	...
1572447606	ffffffff6881adb9b5a9879285a4b2b19b9.....
1572447609	ffffffff7b90abb6c2a98792859db2b19b9.....
1572447612	ffffffff699bacb6beb1a5ada39eb2aca79.....
1572447615	ffffffff6979aebac6c5c6c1ad9eb49fa191.....

図 3.3 データ画像

3.5 データの可視化

図 3.3 のデータを用いて、PC ではディープラーニングを行う。私たちは、図 3.3 のようなデータを以下の図 3.4 のような画像にした。図 3.4 は横軸が時間、縦軸が水深、色が音波の強弱を表している。画像化の方法としては、Python を用いて、横軸を時間、縦軸を上記のデータ画像の 16 進数の値を 2 文字ずつ区切り、0 から 255 までの 10 進数の値に変換し、RGB 値として音波の強弱を色で指定することで画像化した。画像化した理由としては、図 3.3 のようなデータのままでは人が見て理解し難いと考えた。そのため、私たちがデータを見て理解しやすいようにするために画像化した。

(※文責: 毛利心之佑)

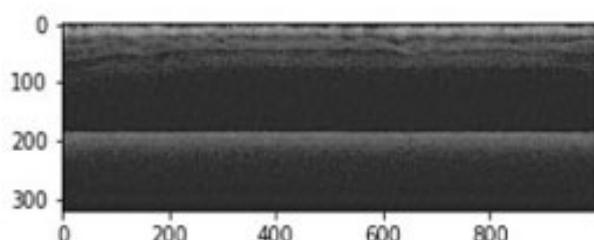


図 3.4 データ画像の可視化

3.6 周波数解析について

魚群探知機から得られた画像に対して周波数解析を行った。周波数解析を行った理由としては、定置網内の箱網を周回している魚はそれぞれ泳ぐ速度が異なっているため、魚種ごとに回遊速度の周期性が見られるのではないかと考えたためである。周波数解析について、図 3.4 のような魚群探知機から得られる画像の縦軸は水深、横軸は時間となっている。私たちは、水深に対してフーリエ変換を行った。深さごとにフーリエ変換を行うことによって私たちは図 3.5 のような画像を得ることができた。

(※文責: 毛利心之佑)

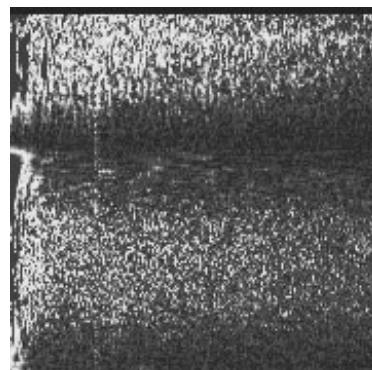


図 3.5 周波数解析画像

3.7 データ画像の分割について

魚群探知機から得られるデータ画像に対して図 3.6 のように 75 秒毎にデータ画像を分割した。理由としては、ディープラーニングを実行する際に私たちは、畠み込みニューラルネットワークを採用していたため、データ数が少なすぎることが問題点として挙げられていた。そのため、データ数を多くすることによってより多くの画像をディープラーニングによって学習することができると思ったためである。画像を分割し、ラベリングを行った結果、精度は大幅に向上した。

(※文責: 毛利心之佑)

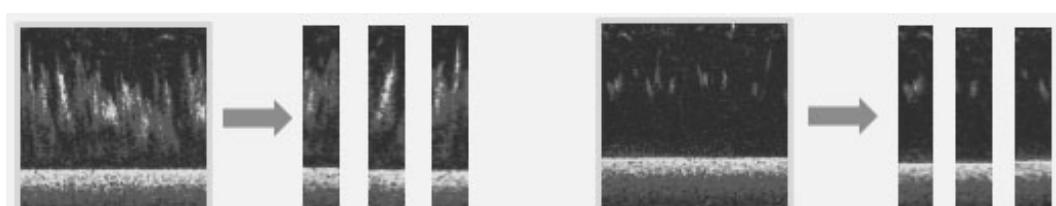


図 3.6 データ画像の分割

3.8 データセットについて

データセットとは、プログラムで処理されるデータの集合体のことである。データセットには、トレーニングセットと、バリデーションセットいうものがある。トレーニングセットとは、機械学習の最初に使用され、かつ最も規模が大きいデータセットである。機械学習アルゴリズムに与えることで、開発モデルのトレーニングに使用する。バリデーションセットとは、トレーニングセットで訓練を行ったのち、分類器のハイパーパラメーター（機械学習アルゴリズムの動きを制御するパラメーター）をチューニングするために用いられるデータセットのことである。様々なハイパーパラメーターを同様のトレーニングセットによって訓練したのち、バリデーションセットを使いパフォーマンスを見て最も優れたものを採用する。私たちは、魚群探知機から得られたデータに対して周波数解析を行った画像を用いたデータセットと、魚群探知機から得られた画像に対してセグメントした画像のデータセットの2つを作成し、ディープラーニングを行った。

(※文責: 毛利心之佑)

3.9 人工知能の利用

前期では、NNCというGUIをベースにしたツールを用いて私たちはディープラーニングを行った。ディープラーニングでは、図3.4のような画像とサケに対して、漁獲量がある日を1、漁獲量がない日を0として学習させる2値分類と、サケに対して、漁獲量の範囲を設定しラベル付を行い、学習させる多値分類を行った。後期では、実際に漁業者にヒアリングし、ブリの漁獲量を把握したいという要望に応えるためにブリに着目し、ディープラーニングを行った。まず、私たちは、ブリが定置網内に存在しているのかどうかという2値分類を行った。次に、網内にブリがいた場合に、大きい順から、ブリ、イナダ、フクラゲと分けられている3種類に対して、それぞれがどのくらいの確率で定置網内に存在しているのかという大きさに着目することで漁獲量が把握できるのではないかと考え、3種類に対して多値分類を行った。

(※文責: 毛利心之佑)

3.10 ブリの判別

私たちは、実際に漁業者にヒアリングした結果を生かしブリの大きさを予測することを目標とした。そのために、私たちは、ブリの魚影の形と回遊速度の周期性について着目した。魚影の形とは、魚群探知機から得られる音響データの反応強度の違いによって得られる形のことである。回遊速度とは、設置された定置網の外周約200mの中を魚が回遊する速度のことである。この回遊速度は魚種ごとによって異なると考えられるため、フーリエ変換を行い、周期性が表わると仮説を立てた。私たちはこの2つの特徴を生かし、ブリの大きさを判別した。また、ブリの大きさを予測するために、ブリが定置網内に存在するか否かを予測し、その結果を元にブリの大きさ判別を行った。

(※文責: 毛利心之佑)

3.11 システムモデル

以下の図 3.7 のようなシステムモデルを構築し、漁業者に利用していただいた。

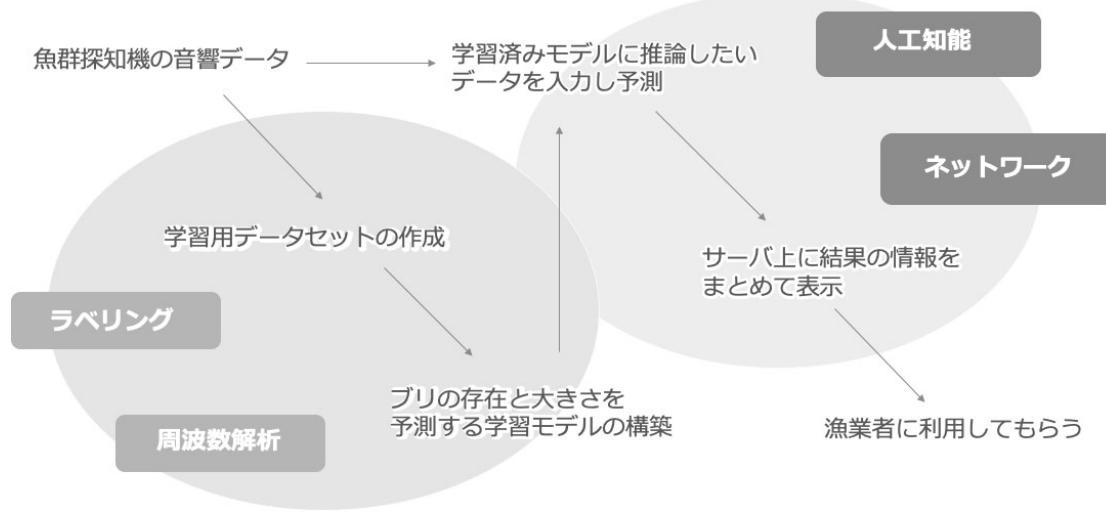


図 3.7 システムモデル

魚群探知機の音響データを元に、学習用データセットを作成した。学習用データセットについては、ブリが存在するかどうかの 2 値分類とブリ、イナダ、フクラゲの 3 種類の多値分類を行うための学習用データセットを作成し、それぞれディープラーニングによる推論を行った。推論を行った結果を元にサーバー上に結果の情報を午前 3 時にまとめて表示し、漁業者の方々が端末でそのデータを確認し、推論した結果と実際のブリ、イナダ、フクラゲの漁獲量を比較していただいた。

(※文責: 毛利心之佑)

第4章 課題解決プロセスの詳細（前期）

4.1 漁業の現状の把握とテーマ決め

本プロジェクトの目的は漁業を情報技術でサポートすることである。前期では、はじめに漁業の現状について調べてくることで、テーマ決めのための前準備を行った。プロジェクトの時間では各自調べてきたことの発表を行うことで、プロジェクトメンバー全員が漁業の現状について大きな理解を得ることができた。調べて分かった現状を踏まえて、情報技術でサポートできることを話し合った結果、アワビ養殖における情報技術の活用と定置網漁業における情報技術の活用を主なテーマとした二つのグループに分かれて活動を進めることにした。

定置網漁業における情報技術の活用を目指すチーム（ぎよたんチーム）では、担当教員である和田先生の協力のもと、定置網の中に設置された魚群探知機から得られるデータを利用し魚種・漁獲量の判別を目標に活動を始めた。チームごとの最初の活動では、漁業についての知識が足りてないという意見から、引き続き全体の活動で行っていた漁業の現状把握を行い、それに加えて定置網漁業に絞った現状の把握と定置網の仕組みについての調査を行った。漁業について調べることで分かったことは、漁業全体では、漁業におけるあらゆる予測は長年の経験による漁業者の勘に頼ることが多いことや、漁業者人口の減少などの問題があること、そのほかにも漁獲量が減っていることや、漁業者はTAC(漁獲可能量制度)を守りながら漁業をしなければいけないことなどがわかつた。特に、TAC(漁獲可能量制度)は規定の量を超えるとペナルティが課せられることもあり、実際に南茅部では過去にメジマグロの漁獲量が規定を超えたことによる罰金が課せられたこともある[3]。定置網漁業について分かった問題は、定置網を引き上げるまではその魚種や漁獲量をおおよそ判断できないことや、事前に漁獲量が分からることによる人員必要数や氷などの経費の無駄があること、卸売業者は獲れる魚種の不安定性から、漁港に水揚げされるまで卸せる魚種がわからないことなどである。

（※文責：菅原直哉）

4.2 目標の設定

定置網漁業の現状や和田先生らの研究成果から、定置網内の魚種・漁獲量を予測することで、様々な利点があることが分かった。漁業者は人件費や船に積載する箱の量や氷の量を削減でき、卸売業者も事前に獲れる魚種が分かることで流通が行いやすくなる。また、TACによる漁獲量の制限のある魚種について、漁獲量を守るために漁業をサポートすることができる。これらのことから、私たちは魚種・漁獲量を予測することで、漁業のサポートや効率化、コストの削減を目指すことにした。

（※文責：菅原直哉）

4.3 環境の設定

定置網内から得られる魚群反応と一日ごとの魚種別の漁獲量データを加工するために Jupyter-Notebook で Python を使用することをグループ内で統一した。また、人工知能の活用には Python が使われることが多いが、ソニーが提供する NNC（ニューラルネットワークコンソール）では AI 開発をレイヤーごとのブロックのドラッグ操作によって簡単に設計できるため、前期ではこの NNC を使用し人工知能の処理を行った。ただ、人工知能の処理では GPU の高い性能が必要であり、NNC では処理が追いつかない可能性がある。よって後期では、処理負荷に応じて、NTT 東日本協力のもと、スマートイノベーションラボの GPU サーバーを利用させていただくことになった。

(※文責: 只野航)

4.4 定置網における魚種・漁獲量予測

定置網内に設置された魚群探知機から送られるデータと漁獲量のデータを活用して魚種・漁獲量の予測を行う。魚群探知機から送られるデータには、3 秒ごとの魚群探知機による音響データが 256 段階の強弱で記録されている(表 4.1)。また、漁獲量のデータには一日の漁獲量が魚種ごとに記録されている(表 4.2)。この二つのデータに対してディープラーニングを用いることで魚種・漁獲量の予測を行う。プロジェクトでは、人工知能のためのデータの加工やその組み方を考え、魚種判別の正解率と漁獲量予測の精度を上げていく。

(※文責: 上澤憂人)

表 4.1 魚群探知機による音響データ

46	-30	17.9	1000	99999.9	-30	12.6	0	99999.9	3	320	40 ffffffff2618272017383d223d454441283342
46	-30	17.9	1000	99999.9	-30	12.6	0	99999.9	3	320	40 ffffffff301b251f133e4d43474e432e0c1638
45	-30	17.9	1000	99999.9	-30	12.6	0	99999.9	3	320	40 ffffffff213251f1332353b4545392e0c1638
45	-30	17.9	1000	99999.9	-30	12.6	0	99999.9	3	320	40 ffffffff15141810222e02783d473e301f1e3b1
45	-30	17.9	1000	99999.9	-30	12.6	0	99999.9	3	320	40 ffffffff151418222f2e27283d473e2439404b1
45	-30	17.9	1000	99999.9	-30	12.6	0	99999.9	3	320	40 ffffffff2620273193a4e51941243b948
46	-30	17.9	1000	99999.9	-30	12.6	0	99999.9	3	320	40 ffffffff30e312e0e5158434e04046515c4d
47	-30	17.9	1000	99999.9	-30	12.6	0	99999.9	3	320	40 ffffffff483c2b28243ab363e3c3d4953635c6
46	-30	17.9	1000	99999.9	-30	12.6	0	99999.9	3	320	40 ffffffff24102828404145353e40331b274959

表 4.2 漁獲量データ

日付	固定値	固定値.1	魚種コード	規格コード	本数	数量 (kg)
2019/4/5	1		64	0	1	3
2019/4/5	1		31	0	0	0.8
2019/4/5	1		83	0	1	3
2019/4/5	1		89	0	0	1
2019/4/5	1		99	0	1	9
2019/4/5	1		89	0	0	0.8
2019/4/5	1		101	0	0	0.8
2019/4/5	1		124	0	0	0.6

4.5 人工知能を利用するための準備

4.5.1 魚群データの可視化

定置網から得られる魚群データは3秒ごとの音響データを深さが320段階、それぞれの反応強度を256段階で表している。つまりデータ上では、3秒につき256段階の反応強度が16進数2桁の320個分で表される。これらはcsvファイルで保存されていて反応強度が16進数で表されていることから、グループではこれらのデータを画像として可視化することから活動を始めた。可視化の方法としてPythonを利用する。一般的な魚群探知機画像を模倣して、反応強度を数値に対してのRGBで表すものと、グレースケールで表すものの二つの魚群画像を作ることにした。ここで、1日の魚群データをそのまま画像とすると 320×28801 の大きさとなり、人工知能を利用する際に負荷が大きすぎることから、画像を任意の大きさに区切る必要があった。また、解像度を意図的に落とした画像の生成もを行い、人工知能の精度と負荷のバランスを保つ工夫をしている。

(※文責: 吉野遊)

4.5.2 データセットの作成

人工知能を利用する際にデータセットと呼ばれるプログラムで処理されるデータのまとめが必要となる。データセットは学習用データセットと評価用データセットの2つが必要となる。私たちは、データセットの作成にPythonを用いた。

前期では、ディープラーニングについて学ぶことを目的に、サケに対しての魚種判別を行なった。私たちは2値分類と多値分類の二つの方法で判別を行なった。2値分類とは、データの集合に対して、ある特定の属性をもつかどうかで2種類にグループ分けする分類方法である。私たちが用いた方法としては、0時から3時までの魚群データ1年分を画像化し、それに対して魚種をサケのみに絞り、日付ごとに1kg以上の漁獲量の日に1を、それ以下の日を0としてラベル付けを行った。多値分類とは、データの集合に対して、3つ以上の特定の属性のいずれかにグループ分けしていく分類方法である。私たちが用いた方法としては、0時から3時までの魚群データ1年分の画像に対し、魚種をサケのみに絞り、漁獲量に対して0から14の範囲でラベル付けを行った。

(※文責: 毛利心之佑)

4.5.3 ニューラルネットワークの利用

人工知能にはたくさんのアルゴリズムがあり用途によって使い分ける必要がある。グループでは、その中でディープラーニングに着目して魚種・漁獲量の予測を目指した。ディープラーニングとは、ニューラルネットワークと呼ばれる脳の機能の特性を模した学習モデルを多層にしたアルゴリズムである。これは画像分類、画像生成、自然言語処理、時系列データの予想など様々な分野で応用されていている。私たちは定置網内の魚群データをなんらかの形に変形させ、データセットとしたのちにディープラーニングを使うことで魚種・漁獲量の予測が行えると考えた。前期では、ディープラーニングにNNCを利用した。特に、画像分類に強いとされる畳み込みニューラルネット

Fish Counter

トワーク（CNN）を用いて魚種・漁獲量の予測を目指した。

(※文責: 吉野遊)

第5章 課題解決プロセスの詳細（後期）

5.1 漁業者への聞き取り

後期では、初めに和田先生協力のもと南茅部町の定置網漁業に同行し、漁業者へのヒアリングを行った。私たちは前期で定置網漁業についての課題やニーズを調べたが、それだけではわからない、実際の現場を見てわかった課題が多くあった。その点をいくつかピックアップする。

一つ目に、現在定置網漁業の漁獲量が少なく、網や船の費用や修理費がとても高いことである。網は一つ約3000万円、船も約1億円の費用が必要となる。また、船にはたくさんの機械が装備されているがそれらの修理費も何千万とかかる。そのため、借金をして設備を購入し定置網漁業を始める漁業者も少くない。このような漁獲量の不足や、網や船の費用と修理費の高さから定置網漁業を辞める漁業者も年に数件あり、定置網漁業者は減少傾向にあるという。

二つ目に、獲れる魚の種類が毎年違うということである。漁獲量がその年で大きく変化することは勿論のこと、獲れる魚種までもが変化している。その要因として水温の1度違いや、潮の流れの微小な変化といった小さな要因から、台風や、暖流、寒流の影響といった大きな要因まである。南茅部町でこれまで獲れなかった魚が獲れ、南茅部町で獲れる魚が、遠く離れたところで獲れるなど、予測のつかない事態が発生している。

三つ目に、マグロが大量に獲れるということである。漁業者はTAC(漁獲可能量制度)を守りながら漁業をしなければならない。前期で学習したように、過去に南茅部町ではメジマグロの漁獲量が規定を超えたことによる罰金が科せられたことがあるが、今でも獲れる日は2000本近く1日で獲れてしまい、多い日は網を切って逃がすという。そのため、大きなマグロは高い値が付くためできる限り獲り、小さいマグロは網を切り逃がすという作業を行っている。個体の大きさの判断や網を切る作業はすべて人の手で行っており、魚群探知機の画像を見ても魚の大きさまでは漁業者も判断ができない。

(※文責: 只野航)

5.2 テーマの再検討

定置網漁業において、プロジェクト学習という活動だけで網や船の費用を削減するところまで情報技術でサポートするのは現実味を帯びておらず、魚種や漁獲量の予測は潮の変化や気候の変動、台風などの異常気象による魚種や漁獲量が年々変化を続けていることから高度な予測が難しい。

ヒアリングを行い把握できた課題を踏まえ、情報技術で函館市の定置網漁業をサポートするにあたり、私たちは特に魚の大きさが知ることができれば定置網漁業者の支援に繋がると考えた。特に、南茅部町周辺では近年ブリが多く漁獲されており、ブリは主要魚種であり安定した収入源である。さらに、定置網漁業者が魚群探知機を見ても大きさは判断できず、大きさが事前に分かれば船に積む箱の量や氷の量を調節できる。以上の利点があることから私たちはブリの大きさの事前予測を行うシステムを構築することを目標に後期の活動を行うことにした。

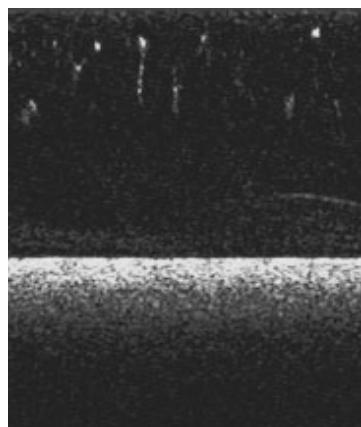
5.3 ブリの大きさを判別する方法

ブリの大きさを判別するために、魚群探知機の音響データを画像にした際に表れる魚を示す部分「魚影の形」と、ブリが定置網内を回遊する際の速度に周期性があると仮定した「回遊速度の周期性」に着目し判別を行った。このそれぞれに着目して作成した画像に人工知能を活用することでブリの大きさを判別できると考えた。また、データセットを作る際に、初めからブリの大きさを判別する方法とブリが定置網内に存在するか否かの判別を元に、ブリの大きさを判別する二つの方法を評価した。

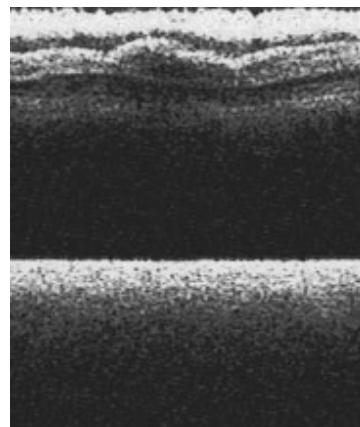
(※文責: 吉野遊)

5.3.1 魚影の形

魚群探知機は、主に浮き袋を持つ魚が反応し、音響データとして表れる。この反応が魚種ごとに特徴があると仮定して、画像分類を行った。下図はイナダとフクラゲそれぞれの漁獲量が全体の漁獲量に対して 80% 以上の日の画像である。このように魚種によって異なる特徴が表れる。漁業者はこのような画像をみて、どの魚種が獲れるのかを予想している。



(a) イナダ



(b) フクラゲ

図 5.1: 魚種による魚影の形の違い

(※文責: 吉野遊)

5.3.2 回遊速度による周期性

定置網に入ってきた魚は最終的に、箱網と呼ばれる外周 200m ほどの場所に入る。その場所で魚は回遊し、設置された魚群探知機に反応する。その際、ある一定の速度で回遊する魚は箱網に設置された魚群探知機に周期性をもって映ると仮定して判別を行なった。私たちは、周期性を表すためにフーリエ変換を用いた。ある時間帯の音響データに対してフーリエ変換を行い、その時間内に同じような反応が繰り返し現れるほど、高周波となり、図 5.2 はフーリエ変換の結果である。イナダとフクラゲが多く獲れた日それぞれでフーリエ変換したところ、フクラゲに対してイナダはより高周波での反応が強く出た。このような結果を画像として特徴づけ、人工知能を使って判別する。フーリエ変換した結果を画像に変換する際には、二つの方法で変換した。

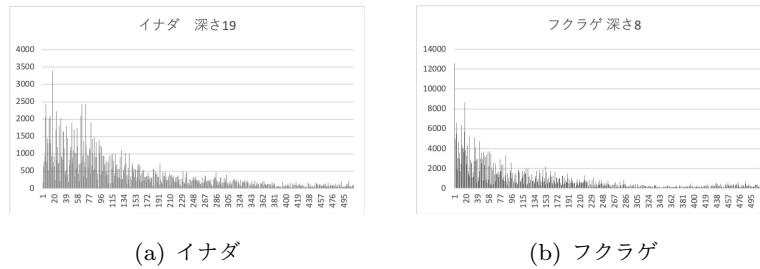


図 5.2: フーリエ変換の結果

一つ目はある範囲時間に対して、深さごとにフーリエ変換をそれぞれ行い、その値に対して色付けを行なった。その結果、画像は縦軸に深さを横軸には周期を表す画像となる。これによってある範囲時間のうち、特徴的な反応がどの程度現れていたのかを表す「深さごとのフーリエ変換画像」となった。

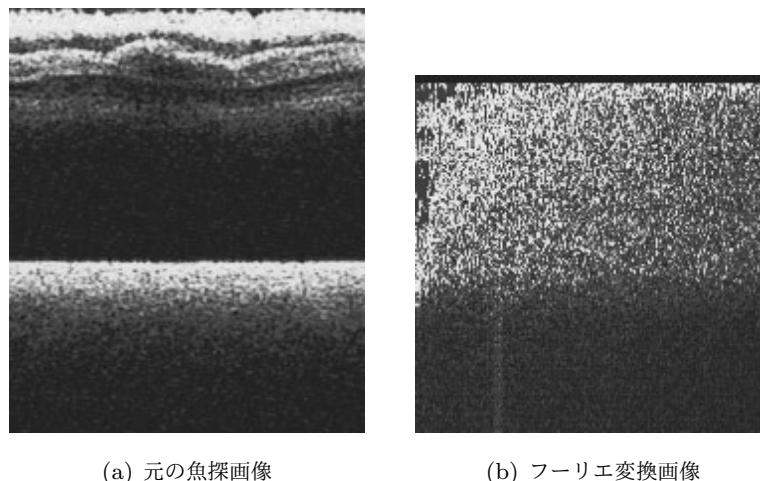


図 5.3: 深さごとのフーリエ変換画像

二つ目は、ある範囲時間に対して、上記のフーリエ変換をした際に反応が大きかった深さに着目し、フーリエ変換を行った。その際に指定した範囲時間の中で、さらに時間を分割し、決定した深さでフーリエ変換を行う。それによって分割した時間ごとのフーリエ変換の結果が表れるため、そ

Fish Counter

れを縦軸に周波数成分、横軸には時間分割ごとに 1 ピクセルとした画像を並べることで、時間成分を表した。このように、一つ目のフーリエ変換では表せなかった時間成分を組み込んだ「短時間フーリエ変換画像」を作成した。

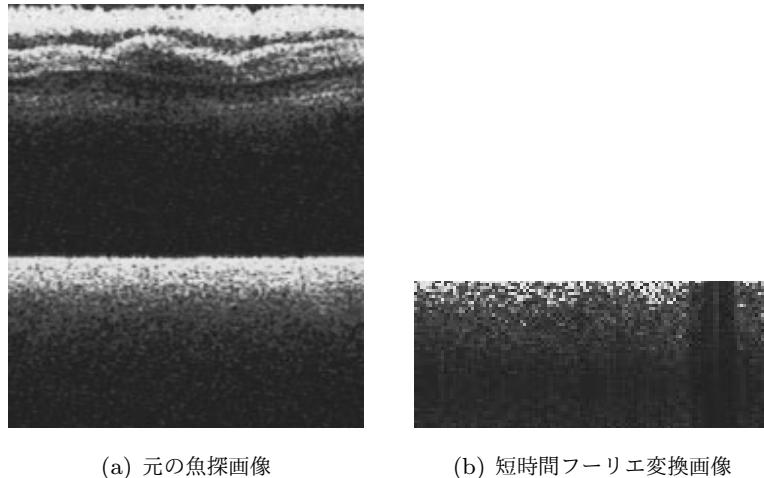


図 5.4: 短時間フーリエ変換画像

(※文責: 吉野遊)

5.4 環境設定

後期でも引き続き、python を使って画像の作成やデータセットの作成を行なった。ディープラーニングに関しても、SONY が提供する NNC を前期に引き続き使用した。

(※文責: 吉野遊)

5.5 データセットの作成と人工知能の利用

ブリの大きさを判別する際にデータセットを作成する必要がある。私たちは、ブリの大きさをそのまま判別する方法とブリが定置網内に存在するか否かを予測した上で、ブリの大きさを判別する方法を比較した。ブリの大きさを判別するにあたって画像の範囲や学習データを変えることで、様々な形のデータセットを作成した。

(※文責: 吉野遊)

5.6 実装

NNCで学習したネットワークを用いて、Neural Network libraries (以下、nnabla) を使って推論システムを作り、実装を行う。nnablaには、pythonを用いることで必要最小限のコード量でニューラルネットワークを定義することが出来るメリットが存在する。NNCで学習させた結果は results.nnp というファイルに保存されており、そのファイルを利用する。推論を行う当日の魚群探知機データを csv 形式でダウンロードし、それを元に画像を作成する。得られた画像を推論システムの入力とし、その日ブリがいるかいないかの確率とブリが定置網内にいる前提において、ブリの大きさをブリ・イナダ・フクラゲの3つに分類し判別した確率を得た。その結果を csv ファイルに書き込み、htm 形式で保存し、サーバーにアップロードした。実際にアップロードしたファイルを図 5.5 に示す。漁業者に出港前に確認していただき、推論結果と漁の結果の一一致度を確かめていただいた。

日付	2020/11/30
時間	AM3:00
定置網内にブリ、イナダ、フクラゲがいる確率	46%
定置網内のブリ、イナダ、フクラゲの種類別確率	
ブリ	34%
イナダ	4%
フクラゲ	62%

図 5.5 アップロード画像

(※文責: 上澤憂人)

5.7 漁業者からのフィードバック

実際に、私たちが構築したシステムによりその日に獲れるブリの大きさを推定し、定置網漁業者が漁に出る前の午前3時30分までに推定したデータを送り利用してもらった。その後、推定したデータについてのフィードバックを頂くことができた。

後期の活動において私たちが行ったブリの存在の有無とその大きさの予測は役に立っているのかという点については、「今はブリが多く獲れる季節でないため役になったとは言えないが、面白い結果になっている」と返答をもらった。私たちの構築したシステムは、意義のあるものになっていることがわかった。

また、他にもマグロや、サケの大きさの予測をしてほしいというニーズがあることもわかった。最近ではマグロの数が多くなっており、定置網漁業者でも魚群探知機に映ったマグロの魚影を見ても、大きいのか小さいのかわからないという。また、サケについては、漁業者は魚群探知機の魚影を見てもどれがサケなのかわからず、判断に苦しんでいるという。その年によって魚群探知機の反応が違い、どの魚種を見てもやはり大きさの判断は難しいそうだ。

続いて、「もしブリが獲れる時期にこのシステムが使えて、ほとんど予測が当たるものであればコストの削減になるか」という点については、削減にはならないことがわかった。本州の大規模な定置網漁業であれば、事前に予測がついていると氷の量を減らしたりすることがあり、そちらでは役に立つ可能性があるという情報を頂いた。また、予測が当たるものであれば市場との連携が取れ

Fish Counter

やすくなるため流通の面で役立つということがわかった。

最後に、「今までたくさんの学生を見てきたができればモノを作るなら完成させてから卒業してほしい、もっと楽しませてほしい」というメッセージも頂いた。

今後、予測の精度の向上はもちろんのこと、ブリだけでなくマグロやサケの予測もしていきたい。

(※文責: 只野航)

第6章 作成したデータセットとその結果 (前期)

前期では、魚群探知機の音響データを画像にしたものを使用し、函館で漁獲量の多かったサケについて判別を行なってみた。判別では2値分類と多値分類を行なった。

6.1 サケの2値分類

2値分類によるディープラーニングを行った。サケがとれなかった日を0、サケがとれた日を1とするデータセットを作成した。そのデータセットをNNCで学習させた。はじめに、サケがとれた日について、評価した際に結果がサケがとれた日となり正しかったものが15個、誤って判定したものは0個となった。次に、サケがとれなかった日について評価した際に、結果がサケがとれない日となり正しかったものが1個、誤って判定したものが4個となった。よって、これらの結果による再現率は100%となり、正解率は80%となった。ただ、これは学習用データにサケがとれた日が多かったことから、評価が大部分の結果に対してサケがとれた日として判別していたためであり、正しく判別できている訳ではなかった。

(※文責: 毛利心之佑)

表 6.1 NNC の実行結果 (2 値分類)

評価データ 正解データ	サケがとれた日	サケがとれなかった日
サケがとれた日	15	0
サケがとれなかった日	4	1

6.2 サケの多値分類

多値分類によるディープラーニングを行った。時間を0時から3時までのその日のサケの漁獲量に対し、50kgごとの範囲でラベル付けし、長さ3600ピクセルの1年分の画像をNNCで学習させた。しかし、学習時間が20時間ほどかかり、学習結果を求めることができなかった。次に、画像の解像度や閾数の組み方に問題点があるのではないかと考え、改善してもう一度ディープラーニングを行った。改善した点としては、画像の解像度を32*360に変換してから畳み込みニューラルネットワークを構築し、学習させた。実行時間は3分ほどになり、改善された。実行結果は、サケがほぼとれなかった日に対しての再現率が100%の結果となり、全体の正解率は90%となった。ただ、サケがほぼとれなかった日が全体に対して多いことから、評価ではサケがほぼとれなかった

Fish Counter

日の分だけ正解率が上がるため、しっかりと判別ができることが分かった。

(※文責: 毛利心之佑)

表 6.2 NNC の実行結果 (多値分類)

評価データ 正解データ	サケの漁獲量 [0~50kg]	サケの漁獲量 [50~100kg]	サケの漁獲量 [100~150kg]	サケの漁獲量 [150~200kg]	サケの漁獲量 [200~250kg]	サケの漁獲量 [250~300kg]	サケの漁獲量 [300~350kg]	サケの漁獲量 [350~400kg]	サケの漁獲量 [400~450kg]	サケの漁獲量 [450~500kg]	サケの漁獲量 [500~550kg]	サケの漁獲量 [550~600kg]	サケの漁獲量 [600~650kg]	サケの漁獲量 [650~700kg]	サケの漁獲量 [700~750kg]	再現率
サケの漁獲量 [0~50kg]	18	0	0	0	0	0	0	0	0	0	0	0	0	0	0	100%
サケの漁獲量 [50~100kg]	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0%
サケの漁獲量 [100~150kg]	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0%
サケの漁獲量 [150~200kg]	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0%
サケの漁獲量 [200~250kg]	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0%
サケの漁獲量 [250~300kg]	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0%
サケの漁獲量 [300~350kg]	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0%
サケの漁獲量 [350~400kg]	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0%
サケの漁獲量 [400~450kg]	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0%
サケの漁獲量 [450~500kg]	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0%
サケの漁獲量 [500~550kg]	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0%
サケの漁獲量 [550~600kg]	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0%
サケの漁獲量 [600~650kg]	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0%
サケの漁獲量 [650~700kg]	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0%
サケの漁獲量 [700~750kg]	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0%

第7章 作成したデータセットとその結果 (後期)

後期では、ブリの大きさを判別するために、「魚影の形」と「回遊速度の周期性」に着目しデータセットを作成した。その際に「ブリの大きさとその他の魚種との判別」と「ブリが定置網内に存在するか判別」、ブリが定置網に存在するという条件下での「ブリの大きさの判別」を行なった。この章では作成したデータセットとその結果を記す。また、データセットに利用した画像は主に5つで、魚群探知機の音響データを画像にした「魚群探知機の音響データ画像」、魚群探知機の音響データ画像を複数枚に分割した「分割した魚群探知機の音響データ画像」、深さごとにフーリエ変換した結果を画像として表した「深さごとのフーリエ変換の画像」、深さごとのフーリエ変換を短い時間で行なった「深さごとのフーリエ変換を短い時間で行なった画像」、反応が強い深さに対して短時間フーリエ変換を行なった結果を画像にした「短時間フーリエ変換画像」を作成した。

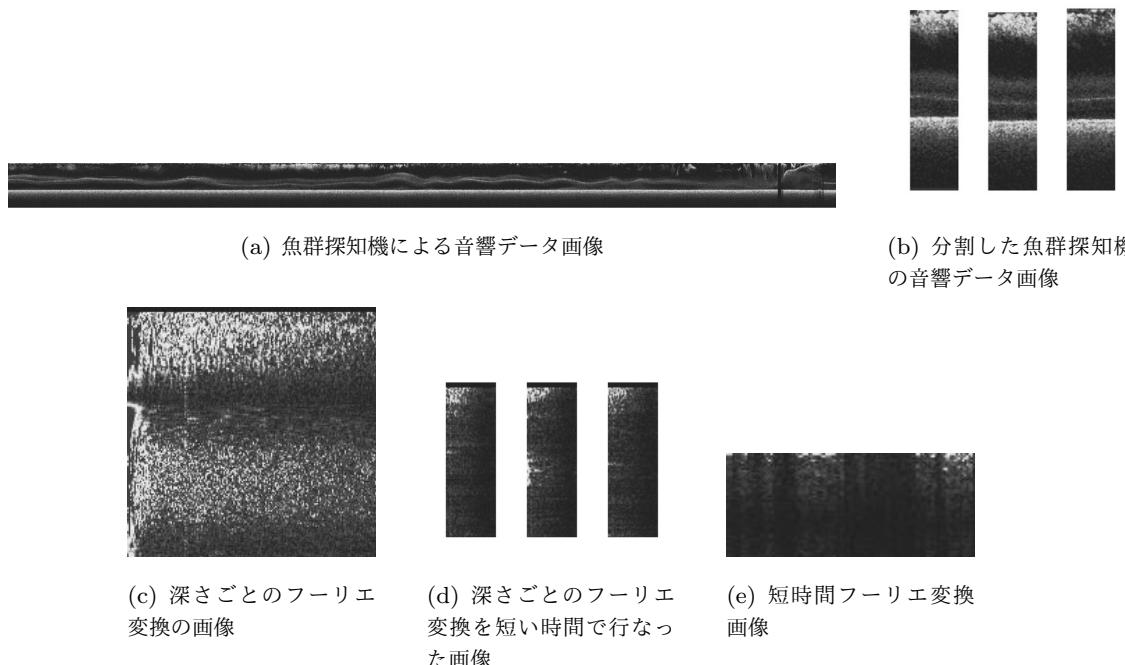


図 7.1: データセットに利用した画像

(※文責: 吉野遊)

7.1 ブリの大きさとその他の魚種との判別

ブリの大きさ(ブリ・イナダ・フクラゲ)とその他の4つで判別を行なった。ブリの大きさについて、全体の漁獲量におけるブリがしめる割合(占有率)によってデータセットのラベルを作成した。また、学習させるのは魚群探知機の音響データを画像にしたもの、深さごとのフーリエ変換を画像にしたもの、短時間フーリエ変換したものである。

7.1.1 分割した魚群探知機の音響データ画像

0時から3時までの3600ピクセルの音響データによる画像に対して、ブリ・イナダ・フクラゲそれぞれの占有率が8割以上の日には画像の中に写っている反応はその魚種であると仮定し、75秒ごとに分割し、1日の全てに同じラベルをつけた。また、占有率が8割以上でない日をランダムに抽出してその他とした。

種類 2値分類

画像 分割した魚群探知機の音響データ画像

モデル 2層のCNN

ラベル ブリ・イナダ・フクラゲが占有率が8割以上の日を抽出してラベルをつけ、その他をランダムに抽出した

データ数 5472枚

結果 正解率 84% F値 84%

F値 76%(その他) F値 81%(ブリ) F値 95%(イナダ) F値 85%(フクラゲ)

結果、ブリとイナダとフクラゲそれぞれを80%を超える精度で分類することができた。また、ブリ系が獲れなかった画像に関しても高い精度で分類可能であった。ただ、ブリ・イナダ・フクラゲそれぞれにおいて漁獲量の占める割合が8割以上の日のみを学習データとしていることから、漁獲量が少ない日の判別が難しいと思われる。

(※文責: 吉野遊)

7.1.2 深さごとのフーリエ変換の画像

0時から3時までに対して、深さごとにフーリエ変換を行い、縦軸に深さ、横軸に周波数の画像を作成した。ラベルはブリ・イナダ・フクラゲの占有率が大きいものにラベルをつけ、漁獲量がない日をその他とした。また、短い時間でフーリエ変換を行なった場合は結果が出なかった。

種類 2値分類

画像 3時間に対して深さごとのフーリエ変換画像

モデル 2層のCNN

ラベル ブリ・イナダ・フクラゲの占有率が大きいものをラベルづけし、漁獲量のない日をその他とした

データ数 297枚

結果 正解率 40% F値 33%

F値 50%(その他) F値 28%(ブリ) F値 0%(イナダ) F値 54%(フクラゲ)

少ないデータ数で学習させたことから、精度が低くなったと思われる。データ数を増やす工夫や、適した学習モデルを組む必要がある。

(※文責: 吉野遊)

7.1.3 短時間フーリエ変換画像

0時から3時までに対して、反応が強い深さに対して短時間フーリエ変換を行い、縦軸に周波数、横軸に時間の画像を作成した。ラベルはブリ・イナダ・フクラゲの占有率が大きいものにラベルをつけ、漁獲量が0の日をその他とした。

種類 2値分類

画像 3時間に対して短時間フーリエ変換画像

モデル 2層のCNN

ラベル ブリ・イナダ・フクラゲの占有率が大きいものをラベルづけし、漁獲量のない日をその他とした

データ数 297枚

結果 正解率40% F値38%

F値50%(その他) F値46%(ブリ) F値25%(イナダ) F値32%(フクラゲ)

少ないデータ数で学習させたことから、精度が低くなったと思われる。データ数を増やす工夫や、適した学習モデルを組む必要がある。

(※文責: 吉野遊)

7.1.4 まとめ

ブリの大きさとその他の魚種との判別では、分割した魚群探知機の音響データ画像を学習した場合に正解率が84%と高い予測精度となった。一方で、データ数が少ないので精度が低い結果となった。

(※文責: 吉野遊)

7.2 ブリが定置網内に存在するか否かを判別

ブリの大きさを判別するために、ブリが定置網内に存在するか否かを予測した後に存在するときにブリの大きさを学習させることで判別精度が上がると思った。ブリが定置網内に存在するか否かについて、全体の漁獲量におけるブリがしめる割合(占有率)によってデータセットのラベルを作成した。また、学習させるのは魚群探知機の音響データを画像にしたものとそれを分割したもの、深さごとのフーリエ変換を画像にしたもの、短時間フーリエ変換したものを作成した。

(※文責: 吉野遊)

7.2.1 魚群探知機の音響データ画像

0時から3時までの3600ピクセルの音響データによる画像に対して、その日のブリの占有率によってブリ系(ブリ、イナダ、フクラゲ)かその他でラベルをつけたデータセットを作成し、2値分類を行なった。

結果、1日の画像に対してでは画像が大きすぎるためか良い学習が進まずに、評価は全て同じ値になってしまった。

(※文責: 吉野遊)

7.2.2 分割した魚群探知機の音響データ画像

0時から3時までの画像に対して、3時間で1枚の画像では結果が出なかったことから、ブリ系(ブリ、イナダ、フクラゲ)の占有率が8割以上の日には画像の中に写っている反応はブリであると仮定し、ブリ系が占有率が8割以上の日に対して、3600ピクセルの画像を25ピクセルごとに分割したもの全てにブリのラベルをつけ、それ以外の日をその他でラベルをつけた。

種類 2値分類

画像 分割した魚群探知機の音響データ画像

モデル 2層のCNN

ラベル ブリ・イナダ・フクラゲを占有率が8割以上の日を抽出してまとめてブリとした

データ数 5472枚

結果 正解率 83% F値 83%

結果、正解率83%と高い精度での分類が行えた。これによって、分割した75秒の画像にブリが存在するか否かを判別できるため、一日全体を通じてブリが定置網内に存在するか否かの予想をすることが可能である。

(※文責: 吉野遊)

7.2.3 深さごとのフーリエ変換の画像

0時から3時までに対して、深さごとにフーリエ変換を行い、縦軸に深さ、横軸に周波数の画像を作成し、占有率に応じてラベルづけを行なった。

ブリ系の占有率が1割以上の日に1を、それ以外の日に0のラベルをつけた場合とブリ系の占有率が5割以上の日に1を、それ以外の日に0のラベルをつけた場合を行なった。

種類 2値分類

画像 3時間の深さごとのフーリエ変換画像

モデル 2層のCNN

ラベル ブリ系の占有率が1割以上の日をブリとした

データ数 297枚

結果 正解率 58% F値 56%

種類 2値分類

画像 3時間の深さごとのフーリエ変換画像

モデル 2層のCNN

ラベル ブリ系の占有率が5割以上の日をブリとした

データ数 297枚

結果 正解率 48% F値 32%

結果、正解率は5割程度とうまく学習が行われなかった。これは、データ数が少ないことが原因であると予想される。ただ、周波数成分で表した際には魚種ごとの特徴のようなものが見られたので学習方法次第で良い精度が得られると推測する。

(※文責: 吉野遊)

7.2.4 深さごとのフーリエ変換を短い時間で行なった画像

0時から3時までに対して、ブリ系の占有率が8割以上の日には画像の反応はブリ系を表していると仮定し、300秒ごとに深さごとのフーリエ変換を行なった。ブリ、イナダ、フクラゲの占有率が8割以上の日に対して、フーリエ変換して作成した画像それぞれにラベルをつけた。

種類 2値分類

画像 300秒で深さごとのフーリエ変換した画像

モデル 2層のCNN

ラベル ブリ・イナダ・フクラゲを占有率が8割以上の日を抽出してまとめてブリとし、それ以外をその他とした

データ数 1800枚

結果 正解率 71% F値 70%

結果、正解率は71%と高い精度での分類が可能であった。フーリエ変換による画像で精度が得られたのは、300秒の中に複数回同じ反応が現れているためと思われる。また、学習データの数が多くかったことも精度が高くなった要因だと思われる。

(※文責: 吉野遊)

7.2.5 短時間フーリエ変換画像

0時から3時までに対して、短時間フーリエ変換を用いて作成した画像を使用した。ブリ系の占有率が1割以上の時にブリとラベルをつける場合と、5割以上の時にラベルをつける場合で行なった。

種類 2値分類

画像 短時間フーリエ変換画像

モデル 2層のCNN

ラベル ブリ系の占有率が1割以上の日をブリとした

データ数 297枚

結果 正解率 62% F値 61%

結果、正解率が5割を超えることができた。このことから、短時間フーリエ変換には少なからず魚種ごとの特徴があると思われる。

種類 2値分類

画像 短時間フーリエ変換画像

モデル 2層のCNN

Fish Counter

ラベル ブリ系の占有率が5割以上の日をブリとした

データ数 297枚

結果 正解率 48% F値 32%

結果、正解率は5割を下回った。ラベルをつける際に占有率を1割にした際に比べて低くなるのは、ブリは獲れるが5割を下回る場合に対して誤判断を起こしているためだと思われる。

(※文責: 吉野遊)

7.2.6 まとめ

ブリが定置網内に存在するか否かの判別では、分割した魚群探知機の音響データ画像を利用した場合、正解率83%。深さごとのフーリエ変換を短い時間で行なった場合、正解率71%と高い予測精度となった。

(※文責: 吉野遊)

7.3 ブリの大きさの判別

ブリが定置網内に存在するとした条件のもと、ブリの大きさを、ブリ・イナダ・フクラゲの3つで分類し判別を行なった。大きさを判別するために、分割した魚群探知機の音響データを画像、フーリエ変換したものを作像にしたものとそれを短い時間でおこなった画像、短時間フーリエ変換したものを作像にしたもの用いた。

(※文責: 吉野遊)

7.3.1 分割した魚群探知機の音響データ画像

0時から3時までの3600ピクセルの音響データによる画像に対して、ブリ・イナダ・フクラゲそれぞれの占有率が8割以上の日には画像の中に写っている反応はその魚種であると仮定し、ブリ・イナダ・フクラゲの占有率が8割以上の日のみを抽出し、3600ピクセルの画像を25ピクセルごとに分割したもの全てに占有率が高かった魚種のラベルをつけた。

種類 2値分類

画像 分割した魚群探知機の音響データ画像

モデル 2層のCNN

ラベル ブリ・イナダ・フクラゲを占有率が8割以上の日を抽出してラベル

データ数 2736枚

結果 正解率 98% F値 98%

F値 98%(ブリ) F値 95%(イナダ) F値 100%(フクラゲ)

結果、正解率が9割以上と高い精度となった。占有率が8割を超える日のみで学習と評価を行なっていることから、画像に映るものがブリ・イナダ・フクラゲのみのそれを分類していることになる。よって、ブリが獲れると予想できる日において、その大きさを判別することが可能である。また、精度が高かった要因として、データ数が多かったことと魚群探知機の音響データを画像

Fish Counter

にした際に大きさごとに特徴が現れるからだと思われる。ただ、ブリが獲れるかどうかの予想と組み合わせた時には精度は下がってしまう。

(※文責: 吉野遊)

7.3.2 深さごとのフーリエ変換の画像

0時から3時までに対して、深さごとにフーリエ変換を行い、縦軸に深さ、横軸に周波数の画像を作成した。ラベルは、ブリ・イナダ・フクラゲが少量でも獲れた日を抽出し、占有率が一番大きい魚種のラベルをつけた。

種類 2値分類

画像 3時間に対して深さごとのフーリエ変換画像

モデル 2層のCNN

ラベル ブリ・イナダ・フクラゲで占有率が大きいもの

データ数 218枚

結果 正解率 50% F値 45%

F値 52%(ブリ) F値 28%(イナダ) F値 55%(フクラゲ)

結果、データ数が少なかったためか正解率は5割となった。ただ、正解率が3割を超えていることからフーリエ変換画像には少なからず大きさごとの特徴が現れているのだとおもわれる。データ数を多くすることや、学習のモデルを変更する必要がある。

(※文責: 吉野遊)

7.3.3 深さごとのフーリエ変換を短い時間で行なった画像

0時から3時までに対して、300秒ごとにフーリエ変換を行い画像を作成した。抽出した画像は、ブリ・イナダ・フクラゲそれぞれの占有率が8割以上の日のもので、それぞれのラベルをつけた。

種類 2値分類

画像 300秒で深さごとのフーリエ変換画像

モデル 2層のCNN

ラベル ブリ・イナダ・フクラゲを占有率が8割以上の日を抽出してラベル

データ数 865枚

結果 正解率 83% F値 82%

F値 87%(ブリ) F値 74%(イナダ) F値 86%(フクラゲ)

結果、8割と高い精度での分類が可能であった。ブリの大きさごとに回遊速度が違うため、短い時間のフーリエ変換画像にブリの大きさごとの特徴が現れていると思われる。また、データ数が多くなったことも精度の向上の要因である。

(※文責: 吉野遊)

7.3.4 短時間フーリエ変換画像

0時から3時までに対して、短時間フーリエ変換を用いて作成した画像を使用した。ラベルは、ブリ・イナダ・フクラゲが少量でも獲れた日を抽出し、占有率が一番大きい魚種のラベルをつけた。

種類 2値分類

画像 短時間フーリエ変換画像

モデル 2層のCNN

ラベル ブリ・イナダ・フクラゲで占有率が大きいもの

データ数 218枚

結果 正解率50% F値37%

F値59%(ブリ) F値0%(イナダ) F値52%(フクラゲ)

結果、正解率は5割となった。イナダのF値が0%なのは、イナダのデータ数が少なかったことが要因だと思われる。

(※文責: 吉野遊)

7.3.5 まとめ

ブリの大きさの判別に関しては、分割した魚群探知機の音響データ画像に着目した場合が最も正解率が高く98%となった。また、フーリエ変換を短い時間で行なった場合の正解率は83%となり、高い予測精度となった。

(※文責: 吉野遊)

7.4 後期結果まとめ

後期ではブリの大きさを判別するために、様々なデータセットを用いて推論を行なった。データセットの作成にあたって、1日に対して1枚のみの画像を作りラベルづけを行なった場合、データ数が極端に少ないとから、高い精度を得ることができなかつた。一方で、画像を増やした推論では、「魚影の形」に着目した際にはブリの大きさとその他の予測を84%の精度で、ブリが定置網内に存在するか否かの判別を83%で推論ができた。「回遊速度の周期性」に着目した際には、ブリが獲れるという条件のもとで83%の精度で推論ができた。このことから、ブリを判別する際に、「魚影の形」と「回遊速度の周期性」はブリの大きさを予測するという目的に対して十分な指標になると言える。

(※文責: 吉野遊)

第8章 発表会

8.1 プロジェクト内発表-前期

本プロジェクトでは、中間発表会や成果発表会の他にプロジェクト内発表を定期的に行つた。目的として、グループ間での到達具合を把握することや、発表に対して慣れることがある。発表では、グループごとに発表スライドを作成し全体で発表を行い、改善点などを話し合つた。前期では二回の発表を行い、発表準備の効果的な役割分担やスライドの見やすさに着目した。発表の中で、著作権などの資料の取り扱い方法に関して意見などが挙がつた。

(※文責: 菅原直哉)

8.2 中間発表会

中間発表の準備はあわびチームと合同で行い、ポスター作成班と動画作成班に分かれ活動した。ポスター作成班では全体構成チームとぎよたんチーム、あわびチームの三つに分かれ活動した。初めての人にも伝わるポスターを目標にして活動に取り組んだ。動画班ではぎよたんチームとあわびチームの二つに分かれて活動し、プロジェクト内発表から目標にしている見易いスライド作りを意識して活動した。

中間発表会はコロナウイルスの影響により、zoom 上での開催となつた。発表動画とポスターは事前に web サイトにて公開され、各自それを閲覧してから zoom 上で質疑応答をする形式であり、プロジェクト内では前半と後半に分かれ質疑応答を担当する。それぞれの質疑応答ではタイムキーパー、司会進行、質問者の指名係、グループごとの説明者に役割を分担した。

発表会本番では聴講者に評価をいただいた。項目は発表技術と発表内容についての二つであり、発表技術では zoom 上での発表や質疑応答の対応などを評価対象とし、発表内容は前期プロジェクト活動とポスターや動画の中身についての評価を 10 段階でいただいた。評価者は前後半合わせて 38 名となり、その内教員が 4 名、職員が 1 名で残り 33 名が学生であった。それぞれの評価については以下の通りである（上図 8.1 発表技術、下図 8.2 発表内容）。

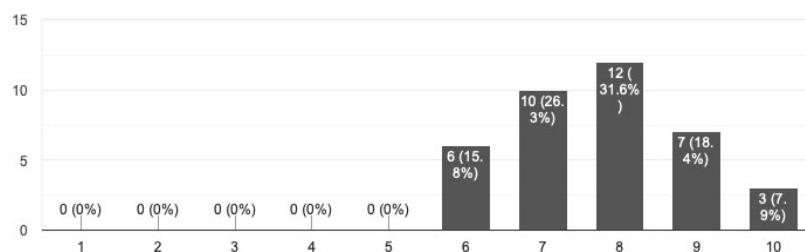


図 8.1 発表技術

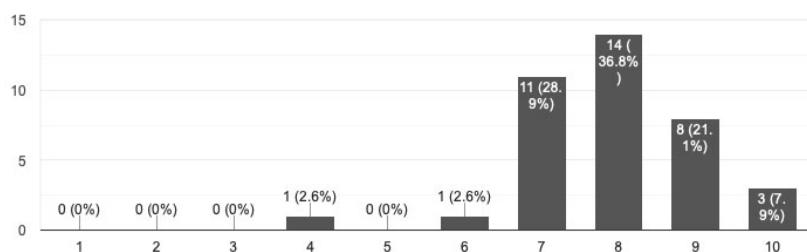


図 8.2 発表内容

発表技術については、「発話と動画のスライド内テキストとのリンクについて一致度がまちまちで、どちらに着目して理解すればいいのか迷う」などのマイナスの意見があった。発表内容に関しても、「もう少し、個人の役割や個人の開発プロセスなどをまとめた項目が欲しい」などの意見があったので成果発表会でこれらを改善する必要がある。

(※文責: 菅原直哉)

8.3 プロジェクト内発表-後期

前期と同様に、あわびチームと進捗を報告し合った。前期では zoom を利用したオンライン上の開催であったが、後期では対面で行った。成果発表に向けてスライドを作成し、成果発表会の練習を踏まえて行った。お互いの発表を聴くことで、自分たちのスライドと発表内容に対して第三者の目で見ることが出来た。そうすることで、スライド内容の言葉足らずな部分や初見の人間にとつて分かりにくい箇所を見つけることに成功し、有意義な発表にすることが出来た。

(※文責: 上澤憂人)

8.4 成果発表会

成果発表の準備もまたあわびチームと合同で行った。前回同様、ポスター作成班と動画作成班に分かれ活動を行った。ポスター作成班は中間発表会で使用したポスターを更に見やすくなるようデザインの修正、後期活動内容を追記した。前期での他のグループのポスターを参考に、色味の使い方などを適宜修正した。動画作成班では前期発表会にて作成したスライドの修正、加筆を行い、後期活動に対応させた。

成果発表会ではコロナウィルスの影響により、zoom 上での開催となった。開催の仕方は中間発表と同じ形式であった。当日、zoom のエラーにより、メインルームから各プロジェクトルームへの移動が出来なくなるトラブルがあった。発表会本番では聴講者に評価をいただいた。項目は発表技術と発表内容に関しての二つであり、発表技術では zoom 上での発表や質疑応答の対応の仕方、事前に公開されている動画の見やすさを評価対象とし、発表内容はプロジェクト活動とポスター、動画の内容についての評価を対象にしている。評価者は前後半合わせて 41 名となり、その内教員が 8 名、学生が 33 名であった。それぞれの評価については以下の通りである(上図 8.3 発表技術、下図 8.4 発表内容)。

Fish Counter

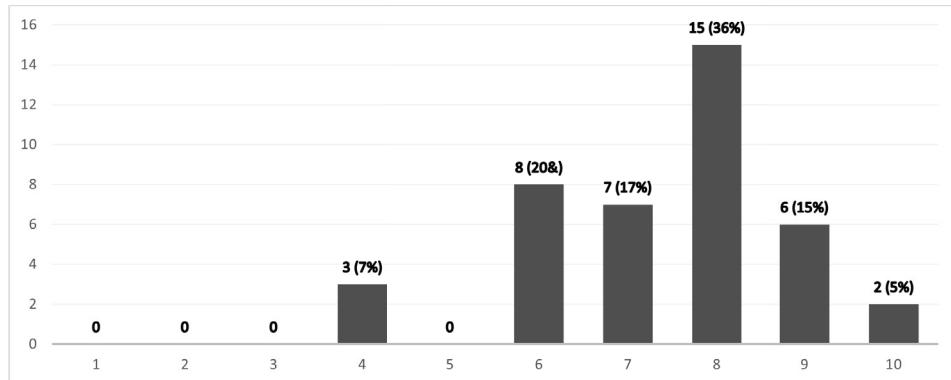


図 8.3 発表技術

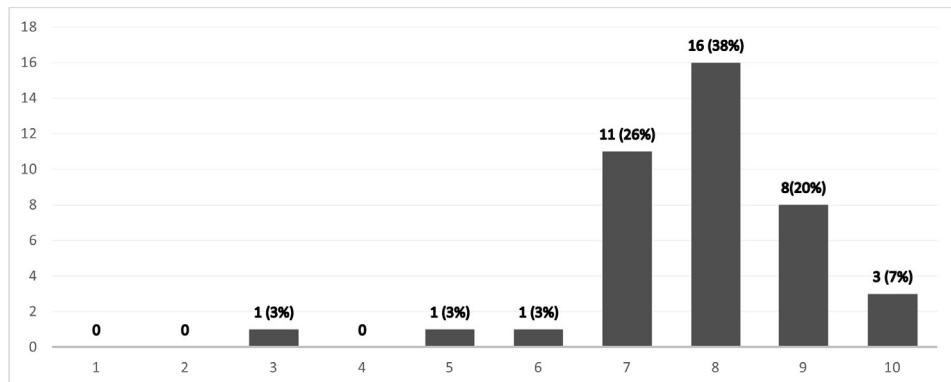


図 8.4 発表内容

発表技術については、「動画の話し方が適切でスライドが見やすかった」などのプラスの意見から、「無言の時間が長かった」などのマイナスの意見があった。zoom のトラブルによって聴講者が少ない時間帯が存在し、対応に迷ってしまったところが反省点である。発表内容については、「しっかりとした背景のもとで目標が設定されていた」などのプラスの意見から、「実践できなかった部分の説明を詳しくしてもよかったです」などのマイナスの意見があった。

(※文責: 上澤憂人)

第9章 今後の課題と展望

実際に漁業者へ推論の結果を提供し利用してもらった結果、私たちが構築したブリの大きさを推定するシステムは、ブリが水揚げされる時期に評価できなかったという課題が残った。しかしながら、漁業者はブリの大きさについては正確に予測できていないためもっと実用性のあるシステムを構築していかなければならない。また、漁の成果の予測は流通の面でも役に立つ。そのため、大きさの判別だけではなく漁獲量など他の推定も視野に入れる、予測の精度を上げることでさらなる実用化を図る、他の魚種に対して応用する、サービスとして利用しやすい形にする等の活動を行っていく必要がある。

(※文責: 只野航)

参考文献

- [1] 一般財団法人 函館国際水産・海洋都市推進機構とは
<https://www.marine-hakodate.jp/about/>
- [2] IoT による持続可能な定置網漁業の取り組み
<https://www.jstage.jst.go.jp/article/lca/14/3/14207/pdf/-char/ja>
- [3] 産経ニュース マグロ取りすぎ「迷惑料」1億円支払いへ、2017.12.12.
<https://www.sankei.com/economy/news/171212/ecn1712120037-n1.html>
- [4] 魚探音響画像に基づく魚種推定モデルの検証
https://www.jstage.jst.go.jp/article/pjsai/JSAI2018/0/JSAI2018_1B2OS11b02/pdf/-char/ja