芸術科学会論文誌 Vol. 20, No. 2, pp. 160 – 170 (2021)

iSea: 海況と漁獲データの結びつけによる関連性の可視化

丸山健太 (非会員)　松山克胤 (正会員)

岩手大学

iSea: Visualization of Relationship by Combining Sea Condition and Catch Data

Kenta Maruyama　Katsutsugu Matsuyama

Iwate University

gshrhg @ gmail.com　m18u @ iwate-u.ac.jp

概要

本研究は，海況と漁獲との関係を分析するための可視化手法を提案する．短期的かつ地域レベルで人が漁獲を予測するためには，まずは海況と漁獲との関係を理解することが不可欠であると考えて，その取り掛かりとして両者の関連性を視認できるような情報可視化ツールを開発する．本研究は，インタラクションにより，全体を見てから細部を詳細に見るような（Coarse-to-Fine 的な）ユーザインタフェースをデザインする．具体的には，漁獲量の時系列グラフによる全体的な視認からスタートし，調査条件を満たす代表的な海況の把握，そして，海況の部分的な特徴を調査できるようにする．上記ユーザインタフェースの実現のために，対象とする海況に似た海況データを集める手法や，海況の部分的な類似性と相違性を可視化する手法などを新たに開発する．本提案の可視化ツールを実装し，ユーザインタフェースの効果を確認する．

Abstract

We propose a visualization technique for analyzing relationship between sea condition and catch data. In order for people to predict fish catches in the short term and at the local level, we believe that understanding the relationship between sea conditions and fish catches is essential. We develop an information visualization tool that allows users to investigate the relationship between the two. In this research, we design a coarse-to-fine user interface to grasp the overall trend and then see the details through interaction. Specifically, our tool start with overall visibility through time series graphs of fish catches, then identify representative sea conditions that satisfy the survey conditions, and investigate partial characteristics of the sea conditions. In order to realize the user interface, we have developed a new method for collecting sea condition data similar to the target condition, and a method for visualizing partial similarities and differences in sea condition. We implemented the proposed tool and confirmed the effectiveness of our user interface.

1 はじめに

水産業に携わる人々にとって，漁獲量や魚価などの漁獲に関する情報は重要である．もし，天気予報のように，日々の漁獲を予測できれば，水産業関係者にとって非常に有益な情報になるといえる．しかしながら，漁獲に関する予測は，気象状況や海水温，潮の流れ，資源量，他地域の漁獲動向，社会状況など，非常に様々な要因に左右されるために，極めて複雑で難しい．漁業者や仲買業者に行なったインタビューでは，「何年経っても漁獲の予測はできない．昔から現在も，水揚げされた漁獲物の現物を起点とした流通やコミュニケーションが行われている．当然ながら，日々の漁獲量のバラつきは非常に大きく対応が大変である.」という意見が得られた．

漁獲の予測方法は，予測を人が行うか，あるいは，コンピュータが行うかで大別できる．後者のコンピュータによる漁獲予測に関しては，近年，機械学習を用いて良漁場を予測する研究が行われている [1, 2, 3, 4, 5]．そして，人による予測例は多数あるが，一例として，国立研究開発法人水産研究・教育機構による漁海況予報 [6] が挙げられる．この漁海況予報 [6] では，人工衛星や観測ブイなどによる観測とデータ解析を用いた，中長期的な予測が行われている．一方で，日々の，そして，地域（漁村や市場などの規模）レベルの予測，すなわち，比較的細かい粒度における予報の例は見当たらない．インタビューによれば，実際に地域で漁業関係に従事している人々については，経験に基づく属人的な予測が唯一の手段のようである．

1.1 本研究の目的

本研究は，人が，海況と漁獲との関係を分析するための可視化手法を提案する．短期的かつ地域レベルで人が漁獲を予測するためには，まずは海況と漁獲との関係を理解することが不可欠であると考えて，その取り掛かりとして両者の関係性を視認できるような情報可視化ツールをデザインする．漁業関係者が短期的な予測を行う場合，参照される海況データは基本的に直近の数日だけであることがインタビューからわかった．このような状況の下で，長期的な範囲も含めてデータ分析できるような可視化ツールの開発を試みる．

漁業者は，海水温，海上風，波浪など様々な情報を総合的に考慮して漁場を決定している．これらは全て重要な情報であるが，とりわけ海水温は，単独で漁場推定の海況（要因）として使用されており [1, 2, 3]，魚の生息に直結する最も重要な情報であるといえる．先述の通り，漁獲は様々な要因が複雑に絡み合うため，海水温だけから魚の生息や漁獲量を予測することは不可能である．しかし，海水温は支配的な情報の 1 つであり，本研究では，海況情報として海水温を用いる．

可視化ツールの具体的な実装にあたり，本研究では岩手県の海を対象とする．海況と漁獲との関係性を可視化するために，まずは，海況データと漁獲データを入手する必要がある．本研究では，海況データとして，衛星から得られた海表面水温分布画像を，そして，漁獲データとして，水産情報配信システムデータベースを使用する．どちらも，岩手県水産技術センターの水産情報配信システムである「いわて大漁ナビ [7]」から入手できる．具体的なデータの内容については 3 章に記述する．

本研究は，海況データと漁獲データを組み合わせて可視化することで，例えば，「鯖は，どんな海の状況のときに漁獲量が多くなるか？」のような，漁獲量が多くなるときの海の状態を視認・分析できるようにする．これにより，（1）例えば「親潮と黒潮との潮目は好漁場である」のような，経験的に広く知られている知識を定量的に確認できる，（2）コンピュータによって得られた予測結果を追確認できる，そして，（3）対話的操作により，新しい知見を得ることができることを期待する．

2 関連研究

2.1 漁獲予測・漁場推定

水産学の分野では，HSI（Habitat Suitability Index, ハビタット適正指数）を用いて，魚が分布しやすい場所を示す手法がある．HSI は，質の異なるデータを統合して，野生動物の生育場所の状態を 1 つの指標で表すものであり [8]，具体的な研究例に，アカイカの漁場予測 [9, 10] などがある．

また，機械学習を用いて漁場を予測する研究も行われている [1, 2, 3]．これは，漁獲量との相関に基づいて，海水温画像のクラスタリングを行うものであり，アカイカを対象に実験を行っている．そして，ディープラーニングを使ったサンマ漁場の予測 [4, 5] なども報告されている．ただし，現時点においては [4, 5] についての具体的な詳細や評価に関する報告は見当たらない．

このように，漁場推定や漁獲予測の研究は，どちらかといえば局所的な漁場や漁獲の予測が目的であるといえる．また，現時点ではアカイカ [1, 2, 3, 9, 10] やサンマ [4, 5] など，限られた魚種のみで実験が行われている．

2.2 画像グループの抽出

本論文で提案する可視化手法には，ユーザが指定した条件に応じて，多数の衛星画像から，相互に類似した画像のグループを抽出するプロセスが含まれている．このプロセスについては，何らかの条件を考慮して，画像の集合から相互に類似した画像グループを見つけ出す研究が関連する．

例えば，Doersch らは，都市のストリートビュー画像から，画像グループを見つけ出す手法を提案した [11]. [11] は，ある特定の都市に多く含まれ，かつ，他の都市にはあまり含まれないような特徴を持つ画像グループを見つけ出すことで，その都市の特徴を可視化することができる．そして，Arietta らは，[11] の手法を応用して，ストリートビュー画像と犯罪率や住宅価格などの非視覚的な情報を条件として結びつけて，特定の非視覚的特性と強い関連性を持つ画像グループを見つけ出す [12].

本研究は，衛星画像と，非視覚的な情報である漁獲データとの結びつけを行い，条件に応じた画像グループを見つけ出す点で，[12] と類似性があるといえる．しかし，対象とする画像が写真ではなく海水温画像であること，そして，[12] ではストリートビュー画像と非視覚情報が位置座標（緯度経度）で紐付けされているのに対し，海水温画像は時系列的な情報も含み，非視覚情報とは時系列的に紐付けされるなどの違いがあることから，既存の研究を直接的に適用することはできない．

筆者らは，衛星画像に対し，オートエンコーダを用いて相互に類似した画像グループを見つけ出す予備的実験を行った [13]．本論文は，画像グループ抽出の部分で，[13] を拡張した手法を用いる．[13] ではユーザインタフェースが考慮されておらず，抽出条件が固定されているのに対し，本論文では，ネットワーク構造の改良，ユーザインタフェースの提案，より柔軟な画像グループの抽出，そして，局所的な差分に関する可視化を行っている．

3 本研究で使用するデータ

漁獲に関する情報や市況情報，海況情報などは，地方自治体が，データを収集・公開しているところも多く，オープンデータとして利用可能なところもある．本研究では，海況データとして，衛星から得られた海表面水温分布画像を，そして，漁獲データとして，水産情報配信システムデータベースを使用する．どちらも，岩手県水産技術センターの水産情報配信システムである「いわて大漁ナビ [7]」から入手できる．具体的なデータの内容を次節に記述する．

3.1 海況データ

「いわて大漁ナビ [7]」から，海表面水温分布画像を得ることができる．2010 年からのデータが存在し，今日までの毎日の衛星画像が，1 日 1 枚の画像として蓄積されている．

3.2 漁獲データ

水産情報配信システムデータベースは，岩手県水産技術センター水産情報配信システムによって集計されたデータセットである．1994 年からのデータが存在し，今日までの毎日の漁獲データが蓄積されている．データ項目には，魚種，漁業種類，漁港名，漁獲量，および，売値（高値，平均値，安値）がある．各項目の具体的なデータ例と要素数を表 1 に示す．

表 1　漁獲データの項目

項目	データ例	要素数
魚種	クロマグロ，サンマ，ブリ	88
漁業種類	定置網，近海延縄，一本釣り	40
市場名	大船渡，釜石	13
漁獲量	＜整数＞ [kg]	N/A
売値	＜整数＞ [円/kg]	N/A

3.3 データ構造

海況データと漁獲データはどちらも日付情報を持っており，日付情報で両者の紐付けが可能である．前処理として，日付を使った紐付けを行い，トリプレット［日付，海況データ，漁獲データ］を要素とする集合を作成する．

ここで，漁が行われていないと判断できるデータを探索し，タグ付けを行う．漁が行われていない理由として，市場が休日のために漁を行わなかった（漁獲そのものは期待できる）か，はじめから漁獲が期待できないために漁を行わなかったかなどが考えられる．

なお，本研究では，データの欠損が比較的少ない 2012 年から 2018 年までのデータを使用する．

4　ユーザインタフェース

3 章に記述した海況データと漁獲データを可視化する最も単純な方法として，漁獲量を時系列グラフで表示する，同じ日付のデータを併記的に表示する，海況データをアニメーション表示することが考えられる．このような可視化により，時系列的な変化の視認や，漁獲量に基づいた画像の検索が可能になる．しかしながら，例えば昨日の海況に対して，数年前の似たような海況との比較を行うなど，大きな時間の間隔で，海況と漁獲との関係性を調査することは難しい．

本研究では，類似画像の探索に基づく，離れた時間間隔における類似した海況の調査を可能とするユーザインタフェースをデザインする．

本研究は，インタラクションにより，全体を見てから細部を詳細に見るように（Coarse-to-Fine 的に）海況と漁獲を調査できるようなユーザインタフェースを目指す．具体的には，最初に，漁獲量の時系列グラフによる全体的な視認からスタートし，調査条件を満たす代表的な海況の把握，そして，海況の部分的な特徴を調査できるようなユーザインタフェースを設計する．

4.1　本提案のユーザインタフェース

本論文で提案するユーザインタフェースについて，具体的な対話例を用いて説明する（図 1）．なお，本節では，調査条件は「漁獲量」であるものとして説明を行う．調査条件として「売値（高値，平均値，安値）」を用いる実装も可能である．

図 1 の (a) と (b) で，調査対象の設定を行う．ユーザは，(a) 魚種，漁業種類，および，市場名を選択し，次に，(b) 調査対象の期間を選択する．ここで期間を選択しなかった場合はすべての期間が対象となる．ユーザが調査対象を設定すると，(c) 漁獲量の時系列グラフが表示される（図 2）．次に，ユーザは，(d) 漁獲量の閾値を与えることで調査条件を指定する．システムは，(e) 与えられた調査条件を満たす代表的な海況データを表示する（図 3）．ユーザが，(f) 代表的な海況データの 1 つを選択する（図 4）と，システムは，(g) 選択された海況に似た海況のデータを一覧表示する（図 5）．この際，各海況が調査条件を満たすかどうかに応じた振り分けが行われる．そして，(h) 選択された海況の，似た海況と比較した部分的な類似度が重畳表示される（図 6）．

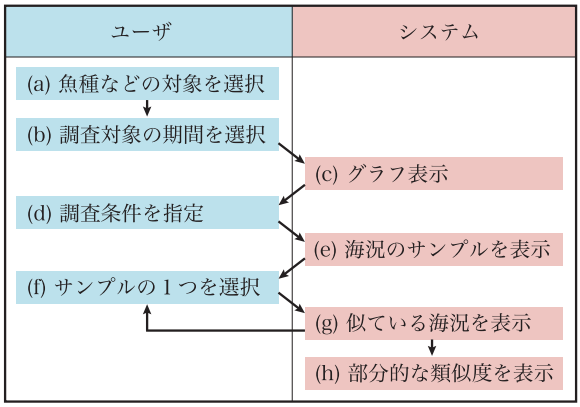

図 1　具体的な対話例

ユーザ操作 (a), (b), (d), (f) は任意のタイミングで実行できる．(f) の選択については，(e) からだけでなく，(g) で一覧表示された画像から選択することも可能で，(g) と (h) の表示を繰り返し的に見て回ることが可能である．

5　提案インタフェースの実装

本章では，4 章に記述したユーザインタフェースを実現するための手法について記述する．

5.1　対象の選択とグラフ表示 (c)

はじめに，3 章で作成したデータから，ユーザによって選択された (a) と (b) を満たすデータを集める．このデータの集合を $A = \{a_i\}$ とする．要素 a_i は，3.3 節のトリプレット［日付，海況データ，漁獲データ］である．そして，集合 A を日付でソートして，漁獲量のグラフ表示を行う（図 2）．

5.2　海況データサンプルのピックアップ (e)

ユーザによって指定された閾値を l とする．はじめに，集合 A の要素を，閾値 l を使って以下のように振り分ける．

$$\begin{aligned} A_P &= \{a_i \,|\, C(a_i) \geq l\} \\ A_N &= \{a_i \,|\, C(a_i) < l\} \\ A_O &= \{a_i \,|\, \text{漁が行われていない}\} \end{aligned} \tag{1}$$

ここで，$C(a_i)$ は，要素 a_i の漁獲量を取得する関数である．式 (1) の添字 P と N は，それぞれ，Positive と Negative を表している．そして，集合 A_O は，3.3 節でタグ付けされた要素の集合を表す．

次に，式 (1) の各集合について，いくつかのデータを

図 2　グラフ表示の例

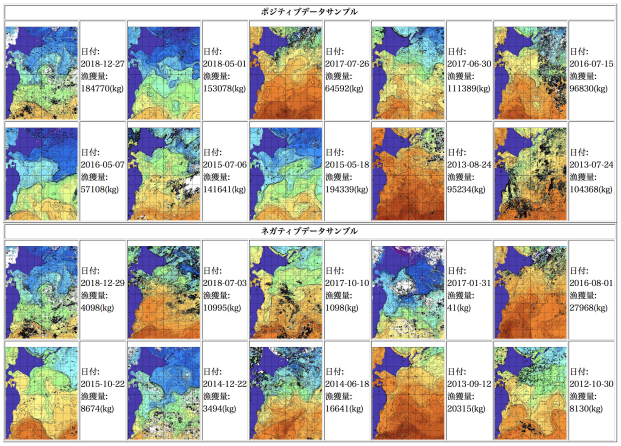

図 3　ピックアップされた海況データサンプル

ピックアップして，サンプルとして表示する．本システムでは，調査条件を満たす A_P だけでなく，A_N についてもサンプル表示を行う（図 3）．

ピックアップする海況データは，相互に異なる特徴であることが望ましい．一般に，日付が近い海況は相互に類似しているために，近い日付のデータを選択することを避ける．本研究では，以下の方法でサンプルデータを選択する．

集合 A_P を例に説明すると，A_P を日付でソートし，$\lfloor n/m \rfloor * i$ 番目の要素をピックアップする．ここで，n は A_P の要素数を，m はサンプル数である．

これにより，近い日付のデータを選択することを防ぐことができ，ある程度ばらつきのある海況データが表示できる．ユーザは，調査範囲 (a,b) と調査条件 (c)，および，サンプル数 m を自由に変更できるために，これらパラメータの調整を行い，サンプルの表示をコントロールできる．

なお，筆者らは，海況データの画像をクラスタリングし，各クラスターの代表画像を取得することで，相互に異なる画像の抽出を試みたが，時間計算量が多くなってしまった（最悪の場合で集合 A のクラスタリングが必要）ために，クラスタリングを使用しないアプローチを採用した．また，できるだけ時系列的に等間隔になるようなデータの抽出も検討したが，漁が行われていないデータ A_O を含め，元々のデータに時系列的な欠損があることや，l の境界付近のデータを拾う傾向が懸念されたため，上記の手法を採用した．

5.3　似ている海況データの探索 (g)

本節では，似ている海況データの探索手法を説明する．２つの画像間の類似度の計算は，画像の特徴量ベクトルを計算して，ベクトル間の距離で表すのが一般的である．特徴量ベクトルを求める手法は多数あり，一例として，カラーヒストグラムに基づく手法，SIFT や SURF などのキーポイントに基づく手法，t-SNE などの次元圧縮手法，そして，VGG16 などのディープラーニングで学習されたモデルを使用する手法が挙げられる．これらの手法の多くは，入力画像が何らかの被写体を撮影した写真であることを想定している．

一方で，本研究で扱う画像は衛星画像であり，海水温が色で表現されている，陸地や経緯線が常態的に表示されている，雲が画像上ノイズのように表れるなど，写真とは異なる特徴が多く見られる．また，本節では，どちらかといえば大局的に似た画像を探索したいのに対し，カラーヒストグラムに基づく手法は大局的な特徴を捉えにくいこと，そして，t-SNE などの次元圧縮手法は，実行結果が安定しにくいことから，本研究では，既存の画像類似度の計算とは異なるアプローチを採用する．

5.3.1　オートエンコーダ

本研究では，オートエンコーダに衛星画像を学習させることにより，特徴量ベクトルを計算する．オートエンコーダはニューラルネットワークによる学習手法の 1 つで，ネットワークモデルの入力と出力に同じデータを与えるものである．オートエンコーダは，エンコーダ

（ネットワークの前半部分）とデコーダ（後半部分）のペアで構成されると考えることができる [14, 15]．すなわち，エンコーダは，高次元の入力データを低次元のコードに変換し，デコーダはコードからデータを復元する．そして，この低次元のコードは，特徴ベクトルとみなすことができる．オートエンコーダは，ローパスフィルタのようなノイズ除去の役割も併せ持つ．このフィルタ機能により，ノイズのように表れる雲部分の「重み」が低減できることも期待した．

本研究では，オートエンコーダの畳み込みニューラルネットワーク（CNN, Convolutional neural network）モデルを採用する（表 2）．表 2 の各レイヤーは畳み込み層とプーリング層の組みで構成される．このネットワークの入力と出力に衛星画像を与えてモデルの学習を行う．なお，前処理として，オリジナルの画像サイズ (700x913) をネットワークモデル (512x512) に合わせて変更し，画素値の正規化を行う．画像サイズの変更は，対象領域である岩手県沿岸付近でのトリミングではなく，画像のスケーリングにより行う．これは，画像内に含まれる領域全体としての傾向を捉えるためであり，また，局所的に存在する雲の影響を減らすためである．画素値の正規化は，各画素値 RGB について，最大値 255 で除算することでデータ範囲を [0, 1] とする．この正規化処理はオートエンコーダで一般的に行われている [16]．なお，正規化によりデータの特徴そのものは変化しないため，正規化処理により生じる問題はない．オートエンコーダによる学習の結果を用いて，各衛星画像の特徴量ベクトルを計算することができる．

この特徴量ベクトル空間内のユークリッド距離で，2 つの画像間の類似度 $dist()$ を計算する．すなわち，

$$dist(I_1, I_2) = ||code(I1) - code(I2)|| \qquad (2)$$

である．ここで，I_1, I_2 は画像を，$code()$ はオートエンコーダで計算されたコードを，$||\cdot||$ はユークリッド距離を表す．なお，本節のオートエンコーダは，筆者らの予備的実験 [13] のネットワーク構造を改良したものである．

式 (2) を用いて，ユーザによって選択された海況衛星画像から近い画像を N 枚選択する．N は自由に変更可能であるが，本研究では $N = 19$ とした．選択された各画像について，式 (1) による漁獲量に応じた振り分けを行い，一覧表示する．

表 2　本研究の CNN オートエンコーダモデル

レイヤー番号	出力 (x, y, channel)
0 (input)	512, 512, 3
1	256, 256, 64
2	128, 128, 32
3	64, 64, 16
4	32, 32, 8
5	64, 64, 16
6	128, 128, 32
7	256, 256, 64
8	512, 512, 3

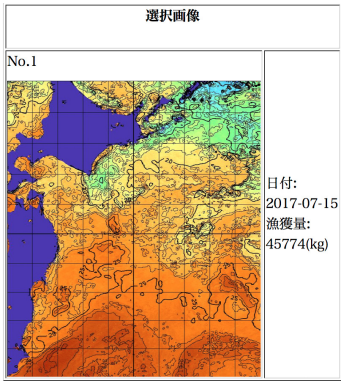

図 4　選択した画像

5.4　部分的な類似度の重畳表示 (h)

前節で得られた N 枚の類似画像を対象として，部分的な類似度の計算を行う．選択された画像を I_0，類似画像を $I_i\,(1 \leq i \leq N)$ とする．そして，式 (1) を用いて Positive グループの集合 $\zeta^{(P)} = \{I_i | D(I_i) \in A_P\}$ と Negative グループの集合 $\zeta^{(N)} = \{I_i | D(I_i) \in A_N\}$ に分ける．ここで，$D(I_i)$ は，画像 I_i が所属する要素 a_i を取得する関数である．

部分的な類似度の計算を以下のように行う．Positive グループの集合 $\zeta^{(P)}$ を例とすると，画像 $I_i^{(P)} \in \zeta^{(P)}$ から，部分 j を切り抜いた画像 $I_{ij}^{(P)}$ について，画像 I_0 から部分 j を切り抜いた画像 I_{0j} との類似度 $d_{ij}^{(P)}$ を計算する．すなわち，

$$\begin{aligned} d_{ij}^{(P)} &= w_1 \cdot RMSE(I_{ij}^{(P)}, I_{0j}) \\ &+ w_2 \cdot SSIM(I_{ij}^{(P)}, I_{0j}) \\ &+ w_3 \cdot PSNR(I_{ij}^{(P)}, I_{0j}) \end{aligned} \qquad (3)$$

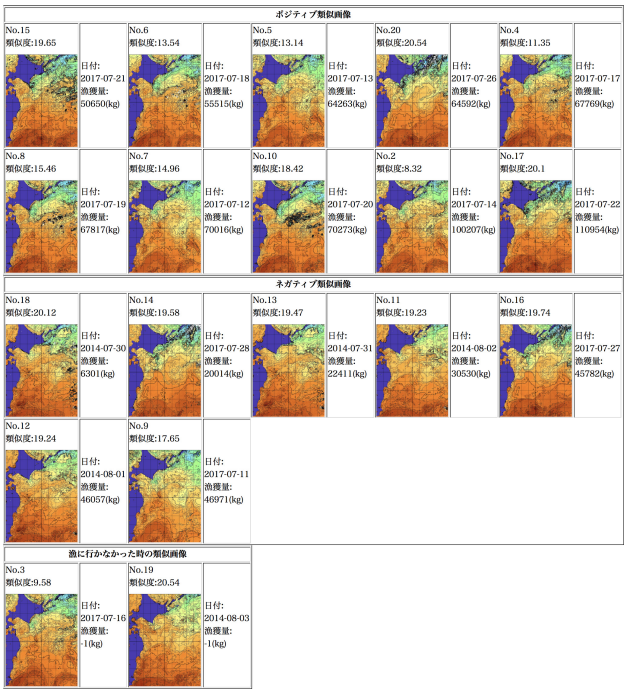

図 5　類似した海況データの表示例．選択した海況データ（図 4）と似た海況データが表示されている．

上式において，類似度の計算に RMSE，SSIM，PSNR を用いる．w_i は重み係数である．そして，部分 j の類似度 $d_j^{(P)}$ を，

$$d_j^{(P)} = \frac{1}{M}\sum_{i}^{M} d_{ij}^{(P)} \tag{4}$$

で計算する．類似度の表示は，類似度にカラーバーを割り当て，類似度に対応する色の長方形を重畳表示する．図 6 は重畳表示の例である．カラーバーは，類似度が高いものを赤，中程度のものを緑，低いものを青と 3 等分したものを使用した．Negative グループの集合 $\zeta^{(N)}$ に対しても同様の操作を行い，類似度 $d_j^{(N)}$ を計算する．重畳表示においては，Positive グループと Negative グループは，それぞれ別の画像として表示する（図 6）．

5.5　具体的な実装

本研究では，ブラウザ上で動作するウェブアプリケーションとして実装する．全体的なユーザインタフェースの様子を図 7 に示す．図 7 左は (a) 対象，(b) 期間，および，(d) 条件を選択したときの，そして，図 7 右は，(f)1 つを選択したときの画面の一部である．ブラウザのタブを使用することで，タブごとに入出力を行うことが可能である．これにより，たとえば，(e) のサンプル内から

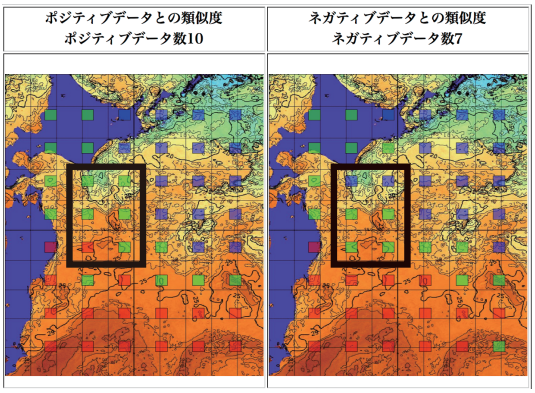

図 6　部分的な類似度の表示例．黒色の長方形は筆者らにより追加されたものである．

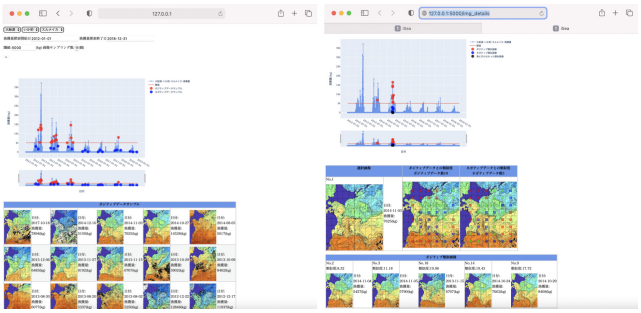

図 7　アプリケーションのスクリーンショット例

(f)1 つを選択するときに，別のタブで表示することが可能である．

6　実行結果

上記のユーザインタフェースを実装し，動作の確認を行った．実装は Python 言語を使用し，データベース処理に sqlite，オートエンコーダモデルの作成に Keras，特徴量ベクトル空間での類似画像探索に Annoy，Web フレームワークに Flask，そして，グラフ表示に Plotly のライブラリをそれぞれ使用した．実行環境は MacBook Air（CPU: Intel Core i5, メモリ: 16GB 3733MHz LPDDR4X）である．実行結果例を図 2-6 に示す．これは，魚種，漁業種類，市場名は，それぞれ「サバ類」,「定置網」,「大船渡」と設定し，閾値 l は 50,000[kg] に設定したものである．

海況データサンプルのピックアップ

図 3 は，5.2 節の手法でピックアップされた海況データサンプルである．なお，サンプル数 m は 10 である．海況データは，ユーザが設定した閾値 l に応じて Positive または Negative に振り分けられて一覧表示される．ピッ

クアップされた海況データは，時系列的には図 2 上の丸が付されたデータである．日付の間隔がとられた海況データが表示されていることが確認でき，相互に異なる海況データ画像がサンプルとして選択されている．

似ている海況データの探索

図 5 は，選択された海況に似た海況データの表示例である．5.3 節の手法により，画像的に相互に類似した海況データが探索できている．本提案の探索機能により，対話的に類似した状況と漁獲量との関係の概略を視認して確認することができる．

部分的な類似度の重畳表示

図 6 は，選択された海況画像の部分的な類似箇所の表示結果（5.4 節）である．図 6 左は，Positive グループ $\zeta^{(P)}$ との比較結果，そして，図 6 右は，Negative グループ $\zeta^{(N)}$ との比較結果である．赤色で重畳表示された付近が，類似度の大きい部分を表し，次いで緑色，青色の順に類似度が小さい部分を表している．図 6 中の黒色の長方形は，筆者らにより追加されたものである．図 6 の左の黒色長方形の部分には，図 6 の右の黒色長方形の部分と比較して，相対的に類似度が高い部分が多く，海況と漁獲高との相関を調査する上で検討の材料になりそうな部分であるといえる．ユーザは，調査対象を自由に変更できるため，データを対話的に選択し，注目する部分を探索的に発見できる．

7 議論

開発したシステムを実行し，その結果得られた知見の収集と整理を行った．また，岩手県水産技術センターの職員に本システムを紹介し，意見交換を行なった．本章では，得られた知見と意見を基に，本提案ユーザインタフェースの効果について議論する．

論文の冒頭で記述したように，漁獲の精確な予測は，様々な要因が極めて複雑に絡み合っているため不可能に近い．このような状況を踏まえ，本提案インタフェースの貢献に関する議論を以下に記述する．

7.1 相関の発見

図 6 の黒色の長方形の部分は，「サバ類」の漁獲が多い時の相関を可視化したものである．サバは回遊魚であり，親潮と黒潮の潮目に集まることは一般に広く知られている．その意味では，図 6 は沿岸付近に潮目があることを再確認したものであるともいえる．しかし，インタビューによれば，潮目は明確に定義されているものではなく，潮目を指し示すことは実際には難しいという意見が得られた．このことから，本提案インタフェースを用いることで，漁獲と相関がありそうな部分を発見できたといえる．水産技術センターの職員からは，このような相関の発見は，漁獲を考える上で重要な要因となりうるものであり，意味のある情報を発見できたといえるものであるとの意見があった．

7.2 市場による違いの可視化

図 8 は，漁業種類と魚種を，それぞれ「いか釣」と「スルメイカ」とし，市場名を「久慈」と「大船渡」としたときのグラフである．グラフから，漁獲量は久慈市場の方が高いことと，どちらの市場も年が経つにつれて漁獲量が減少傾向にあることがわかる．ここで，閾値 l を 10,000[kg] に設定したときの，閾値以上の海況データサンプルを図 9 に示す．図 9 を見比べると，大船渡湾の方が全体的に青い，すなわち，海水温が低い画像が多いことがわかる．スルメイカは，経験的に，青森県付近の親潮とともに南下していると考えられている．久慈は大船渡より北にあるため，潮目が北方にある時に久慈市場の漁獲が期待できそうなこと，そして，大船渡の場合は，大船渡付近まで親潮が流れ込み，潮目が形成されていることが漁獲を考える際に重要そうなことを示すことができた．この知見そのものは，既に経験的に知られていることであるが，本提案インタフェースを用いることで，簡単な対話型操作によって，衛星画像とともに視覚的に示すことができた．

7.3 発展性

本システムの実行，および，意見交換を行ったことで，以下のようなアプリケーション案を発想することができた．

漁業者の意思決定の支援

例えば，現在の海況に似た海況を探索し，その時に漁獲量が多かった魚種を表示することで，「今の海況はあの年に似ていて，あの魚種が多く獲れていたのか」のように，漁業者の操業の参考となる情報を提示することで，漁業者の意思決定を支援できることが期待できる．

魚種別のより詳しい解析

現在，岩手県では放流したサケの稚魚が戻ってこないために不漁が続いており，要因の究明が行われている．高い海水温がサケの回帰を妨げていると考えられてお

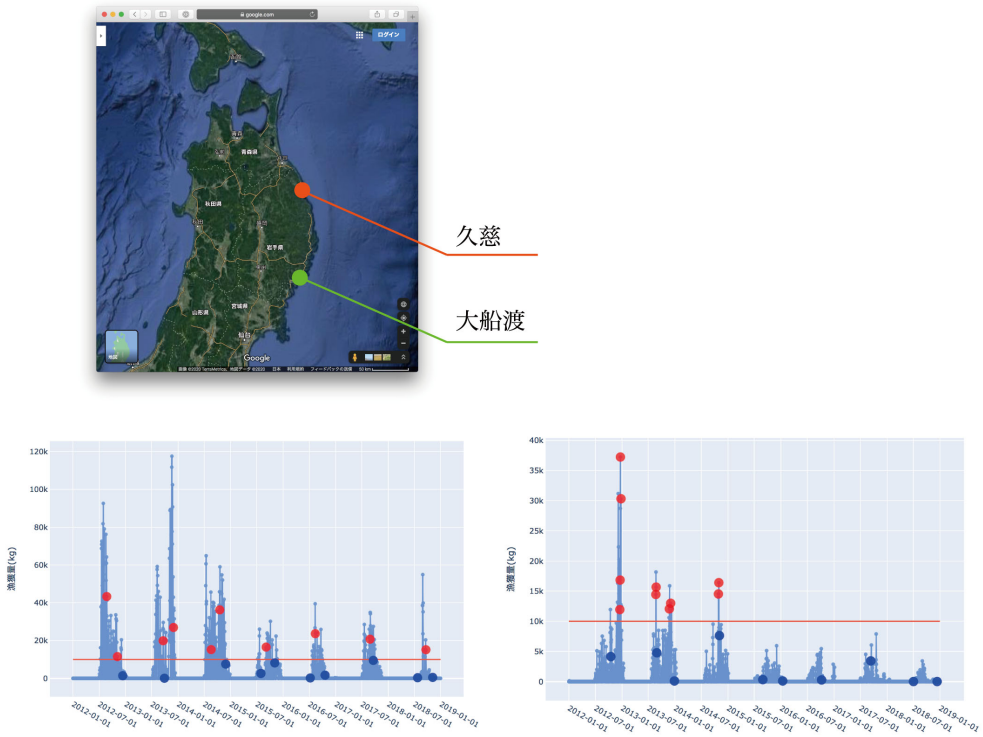

図 8　久慈と大船渡のスルメイカ漁獲量グラフ

(a) 久慈市場

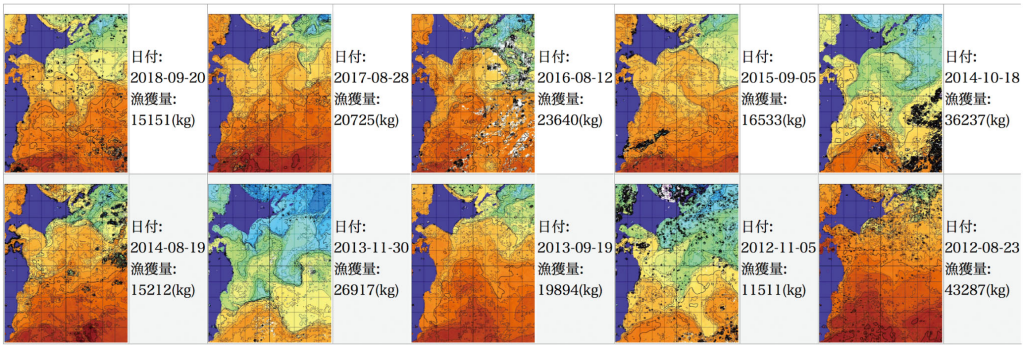

(b) 大船渡市場

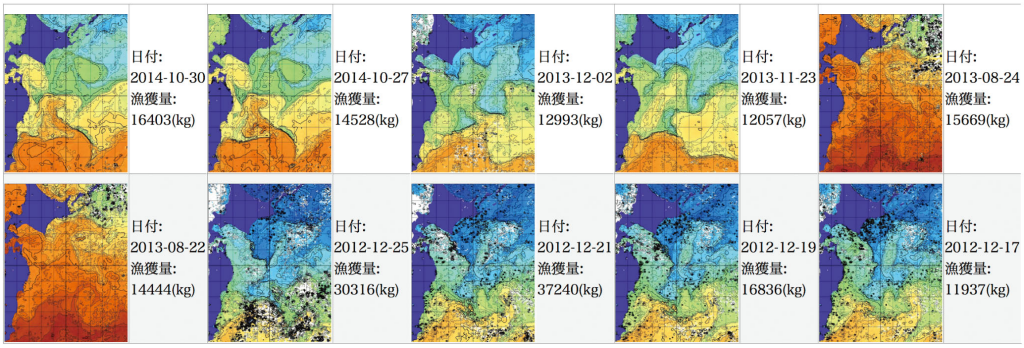

図 9　市場による海況データサンプルの違い

り，本研究を発展させて長期的な海況の類似性・相違性を可視化することで，より詳しい解析が期待できる．このように，魚種固有の特徴に応じた可視化アプリケーションが考えられる．

予測結果の追確認

漁獲予測 [1, 2, 3, 4, 5, 9, 10] の結果を，本可視化システムと結びつけることで，追視認を行えることが期待できる．このように，漁業に関するデータを統合的に可視化できるようなプラットホームの発展性がある．

8 まとめと今後の課題

海況と漁獲との関係を理解することを目的に，取り掛かりとして両者の関連性を視認できるような情報可視化ツールを開発した．インタラクションにより，全体を見てから細部を詳細に見るような（Coarse-to-Fine 的な）ユーザインタフェースをデザインし，ユーザインタフェースの実現のために，対象とする海況に似た海況データを集める手法や，海況の部分的な類似性と相違性を可視化する手法などを開発した．筆者らの知る限りでは，本提案のような可視化ツールはこれまでになく，提案したインタフェースにより，新しい相関の発見を行うことができた．今後，7.3 節に記述した発展的なアプリケーションの実現に向けた検討を行っていく．

謝辞

貴重なご意見をいただきました岩手県水産技術センター職員の方々と，本学職員の田村直司様に感謝申し上げます．本論文は，NICOGRAPH 2020 で発表した論文 [17] に加筆したものです．論文査読者の有益なご指摘に感謝申し上げます．本研究は JSPS 科研費 JP17K00261，JP21K11990 の助成を受けたものです．

参考文献

[1] 飯山, 趙, 橋本, 笠原, 美濃, 海水温パターンのクラスタリングによる良漁場推定, 電子情報通信学会論文誌, Vol. J101-D, no. 8, pp. 1070-1078, 2018.

[2] M. Iiyama, K. Zhao, A. Hashimoto, H. Kasahara, M. Minoh, Fishing Spot Prediction by Sea Temperature Pattern Learning, Oceans 2018, pp. 1-4, 2018.

[3] T. Shimura, M. Sonogashira, H. Kasahara, M. Iiyama, Fishing Spot Detection Using Sea Water Temperature Pattern by Nonlinear Clustering, Oceans 2019, pp. 1-4, 2019.

[4] 水産経済新聞, 2020 年 3 月 18 日新聞記事, https://www.suikei.co.jp/ｊａｆｉｃ，ａｉでサンマ漁場を視覚化/, 2020 年 8 月アクセス.

[5] 水産新聞, 2020 年 3 月 23 日新聞記事, https://suisan.jp/article-11867.html, 2020 年 8 月アクセス.

[6] 国立研究開発法人水産研究・教育機構, 漁海況予報, http://abchan.fra.go.jp/index2.html, 2020 年 8 月アクセス.

[7] 岩手水産技術センター, いわて大漁ナビ（岩手県水産情報配信システム）, https://www.suigi.pref.iwate.jp, 2020 年 8 月アクセス.

[8] 斎藤克弥, 水産振興-水産海洋分野の衛星リモートセンシングと ICT, 日本水産振興会, Vol. 52, no. 9, pp. 34-36, 2018.

[9] 五十嵐弘道, 淡路俊之, 石川洋一, 蒲池政文, 碓氷典久, 酒井光夫, 加藤慶樹, 齊藤誠一, 清藤真樹, 海洋再解析データを用いたアカイカ好適生息域モデルの構築とその応用, JAMSTEC Report of Research and Development, Vol. 18, pp. 89-101, 2014.

[10] I. D. Alabia, S. Saitoh, H. Igarashi, Y. Ishikawa, N. Usui, M. Kamachi, T. Awaji and M. Seito, Ensemble squid habitat model using three-dimensional ocean data, ICES Journal of Marine Science, Vol. 73, No. 7, pp. 1863-1874, 2016.

[11] C. Doersch, S. Singh, A. Gupta, J. Sivic, and A. A. Efros, What Makes Paris Look like Paris?, ACM Transactions on graphics (SIGGRAPH 2012), Vol. 31, No. 3, 2012.

[12] S. Arietta, A. A. Efros, R. Ramamoorthi, and M. Agrawala, City forensics: Using visual elements to predict non-visual city attributes, IEEE Trans. Visual. Comput. Graph, Vol. 20, No. 12, pp. 2624-2633, 2014.

[13] K. Maruyama, K. Matsuyama, A method of finding characteristic ocean-satellite-image groups using autoencoder, Proc. SPIE 11515, Interna-

tional Workshop on Advanced Imaging Technology (IWAIT) 2020, id. 115151J, 5pages, 2020.
[14] A. Gulli, S. Pal, Deep Learning with Keras, Packt Publishing, Birmingham, 2017.
[15] G. E. Hinton, R. R. Salakhutdinov, Reducing the Dimensionality of Data with Neural Networks, Science, vol. 313, no. 5786, pp. 504-507, 2006.
[16] The Keras Blog, Building Autoencoders in Keras, https://blog.keras.io/building-autoencoders-in-keras.html, 2021 年 3 月アクセス.
[17] 丸山健太, 松山克胤, iSea: 海況と漁獲データの結びつけによる関連性の可視化, NICOGRAPH 2020, 2020.

丸山 健太

2019 年岩手大学理工学部卒業．2021 年岩手大学大学院総合科学研究科修士課程修了．

松山 克胤

岩手大学理工学部准教授。博士（工学）。岩手大学大学院工学研究科博士後期課程修了。公立はこだて未来大学助教、岩手大学理工学部助教を経て、現在、岩手大学理工学部准教授。博士（工学）。CG、情報可視化、インタラクティブシステムなどの研究に従事。