機械学習を用いた衛星画像による漁場予測の研究

誌名	水産工学
ISSN	09167617
著者名	荒井,頼子 出原,真理子
発行元	日本水産工学会
巻/号	56巻1号
掲載ページ	p. 57-59
発行年月	2019年7月

水産工学 Fisheries Engineering
Vol. 56 No. 1, pp.57～60, 2019

【報　文】

機械学習を用いた衛星画像による漁場予測の研究

荒　井　頼　子[1]*・出　原　真理子[1]

Prediction the Potential Fishing Grounds Using Machine Learning and Satellite Data

Yoriko ARAI[1]* and Mariko DEHARA[1]

Abstract

Fishery prediction using satellite data has been reported by many studies. However, many of these studies use catches data sets from fishing boats and research vessels. In this study, using night-time visible images from satellite data instead of catches information, we predicted potential fishing grounds for saury using random forest, support vector machine, maximum entropy of machine learning. From September to December, the fishing ground predicted by machine learning showed moving from the north to the south as in the past catches reports. The predicted fishing ground distribution pattern was consistent with past reports. Some ships like as fleet of fishing boats were also located in the predicted fishing ground outside EEZ. The fishing ground zone predicted by using random forest showed the most reasonable in the three machine learning models. We suggest that it is possible to predict the potential fishing grounds only from satellite data sets.

1. はじめに

アルゴフロートや人工衛星等海洋の観測手法が増加し，データが増えていること，またコンピュータ技術やアルゴリズムなどの解析手法が発展したことから，近年では海況予測や漁場予測の研究が発展し，社会実装されている[1),2)]。このような漁況予測の研究開発では，一般に教師となる漁獲情報が必要となるが，手法開発に資する十分な質と量を満たす操業記録はオープンデータとして整備されておらず，教師データの収集が手法開発の重要な課題の一つである。本論では，教師データとして漁獲情報を用いず，衛星観測情報のみを利用した複数の機械学習モデルによる漁場予測を評価した。

2. 利用データと方法

1) 操業データの仮定

Googleが公開する全世界の漁船位置を可視化するグローバル・フィッシング・ウオッチ（Global Fishing Watch）では，AISなどの漁船位置情報に加え，アメリカ海洋大気庁（National Oceanic and Atmospheric Administration；NOAA）が保有するSuomiNPP衛星に搭載されているVisible Infrared Imaging Radiometer Suite（VIIRS）による夜間光画像から，船舶位置を推測することが可能[3)]である。これらの船舶には集魚灯を持つ漁船が多く含まれ，イカ釣り漁業，サンマ棒受け網漁業および西日本の一部ではイワシ・アジ・サバ等のまき網漁業の操業情報と関連づけられている。本論では，衛星夜間光の源泉をサンマ棒受け漁船の集魚灯であると

2018年12月25日受付，2019年4月17日受理
キーワード：漁場推定，機械学習，衛星画像
Key words：fishing grounds, Machine learning, satellite data

[1] Remote Sensing Technology Center of Japan, TOKYU REIT Toranomon Bldg. 3F, Toranomon 3-17-1, Minato, Tokyo 105-0001, Japan（一般財団法人リモート・センシング技術センター　〒105-0001　東京都港区虎ノ門3-17-1 TOKYU REIT虎ノ門ビル3階）
*Tel：03-6435-6776, Fax：03-5777-1580, yoriko@restec.or.jp

本論は，平成30年度日本水産工学会秋季シンポジウム「水産工学と人工知能」において講演された内容を取り纏めたものである。

Table 1 Input data list

データ内容	入手先	入手レベル，空間解像度（切り出し前），時間スケール（合成前），衛星センサ等
海表面水温 [SST]	NASA/GSFC	L3 Mapped, 4km, Daily, Aqua/MODIS Terra/MODIS https://oceandata.sci.asfc.nasa.gov/
海表面クロロフィル [CHL]	NASA/GSFC	L3 Mapped, 4km, Daily, Aqua/MODIS NPP/VIIRS https://oceandata.sci.gsfc.nasa.gov/
海面高度アノマリー [SLA]	Copernicus	L4 gridded, 0.25°, Daily, Multimission altimeter http://marine.copemicus.eu/
地衡流速 [UGOS,VGOS]	Copernicus	L4 gridded, 0.25°, Daily, Multimission altimeter http://marine.coaemicus.eu/
渦運動エネルギー [EKE]	地衡流速より算出	—
船舶検出データ [VBD]	NOAA/NGDC	CSV ポイントデータ Daily, NPP/VIIRS https://data.ngdc.noaa.gov/instruments/remote-sensing/passive/spectrometers-radiometers/imaging/viirs/vbd/v23/jpn/

仮定し，サンマ漁場を予測した。

サンマの主な漁期・漁場である秋季（8月から12月）と北部太平洋海区の一部（東経140度から162度，北緯30度から48度）とし，NOAAが配信するVIIRSによる漁船の位置情報（VIIRS Boat Detection（VBD））を漁船の分布位置情報として使用した（Table 1）。

2) 衛星リモートセンシングによる海洋環境情報

海況情報には衛星リモートセンシングにより観測した海洋環境データを利用した（Table 1）。なお，地衡流速プロダクトは，東西成分のuと南北方面のvに分かれているため，漁場推定モデルを作成する際にはそれぞれを1つの説明変数として扱った。

3) 方　　法

漁船位置と一致する地点の海洋環境情報を抽出したデータセットを共通入力データとして整備し，衛星による好適生息域推定モデルの報告がある複数の機械学習[4]から3つの機械学習モデル，最大エントロピー（MaxEnt），ランダムフォレスト（RF），およびサポートベクターマシン（SVC）による漁場推定を行った。2012年から2016年，8月から12月のデータをランダムサンプリングし，学習用と評価用のデータとしてそれぞれ全データの70%と30%に区分した。また，機械学習に用いない2017年の全データも評価用データとした。

機械学習から得られた漁場分布の推定値は0から1000の値に規格化し，数値が大きいほど漁場形成の確率が高くなるよう可視化した。各海洋環境情報の寄与率は各モデル内で1に正規化した。

また，各モデルの漁場分布推定精度は，ROC（Receiver Operating Characteristic）曲線から算出するAUC（Area Under the Curve）の値により評価した。AUCは0から1の値を示し，1に近いほど精度が良いとされる。

3. 結果および考察

各モデルによる漁場分布推定図をFig. 1に示す。高い数値はサンマ漁場の可能性が高いことを示す。9月から12月にかけて，漁場分布域は北から南に移動しており，過去の報告[5]と一致していた。また，各手法を比較すると，MaxEnt，RF，SVMの順に漁場推定域が絞られており，RFとSVMでは船舶位置（×印）と良く一致していた。また，各モデルの漁場分布推定精度をAUCで比較すると，最適モデルはRFであった（Table 2）。さらに，各モデルにおける説明変数となる海洋環境情報の寄与率（Table 3）を見ると，MaxEntとRFでは，SSTやChl.aの寄与が高いのに対し，SVMでは全要素での違いは見られなかった。

また，Chl.aおよびSSTの寄与率が高い結果を示した。これは，サンマが小型の低次消費者であり，その分布は海面水温の分布や動植物プランクトン量と関係があることによる効果であると推測できる。

なお，北緯42度付近，東経150度以東のEEZ外に位置する漁場推定域に夜間画像による船団が見られた。2017年サンマ漁期のEEZ付近において，国内および海外の漁船が同時に操業している報告がある[5]。国内操業への情報提供に加え，海外漁船の動向予測にも利用の可能性がある。

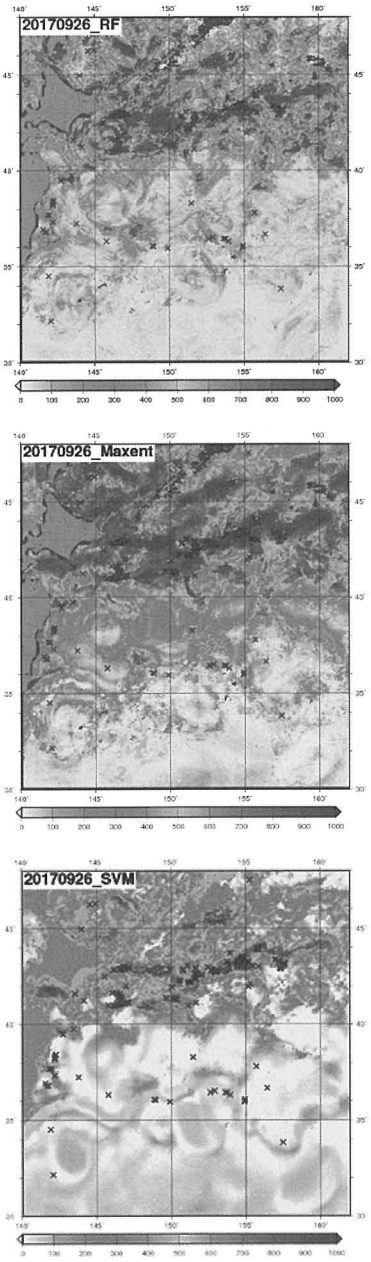

Fig. 1　Predicted results by MaxEnt, RF and SVM

4. ま と め

衛星データのみを用いて，三つの機械学習モデルによるサンマ漁場予測結果を評価した。推定した漁場分布域は，過去の漁場報告と同様な結果を示した。RFの推定精度が最も高く，推定分布の広さも妥当な結果が得られた。今後，他国船の操業モニタリングも含め，簡易的な漁場推定への利用が期待できる。

Table 2　Model evaluation by AUC

モデル	2012－2016	2017
Maxent	0.854	0.836
RF	0.902	0.849
SVM	0.804	0.802

Table 3　Contribution rate of explanatory variables

説明変数	Maxent	RF	SVM
SST	27.1	26.2	18.1
Chi. a	48.8	33.1	16.2
MSLA	8.0	5.8	16.3
地衡流速 u	12.1	13.1	17.3
地衡流速 v	3.6	8.4	17.8
EKE	0.5	13.4	14.3

謝　辞

本論は，国立研究開発法人宇宙航空研究開発機構平成29年度地球観測データ解析研究業務支援により実施した結果の一部を取りまとめたものである。漁場推定モデルの構築には北海道大学北極域研究センター齊藤誠一研究推進支援教授，株式会社グリーン&ライフ・イノベーションの高橋文宏様にご協力頂いた。ここに感謝申し上げます。

参 考 文 献

1) 馬場真哉・松石隆：ランダムフォレストを用いたサンマ来遊量の予測．日水誌，**81(1)**：2-9，2015.

2) 齊藤誠一：水産海洋学入門　海洋生物資源の持続的利用．水産海洋学会編，講談社，東京，pp.92-102，2014.

3) S.Saitoh, A.Fukaya, K.Saitoh, R.Mugo, S.Matsumura and F.Takahashi：Estimation of number of Pacific Saury Fishing Vessels using Night-time Visible Images. *ISPRS Archives*, Volume XXXVIII, Part 8, 2010.

4) 齊藤誠一：衛星リモートセンシングで海洋空間を知る．情報管理，**60(9)**：641-650，2017.

5) 木村典嗣・岡田喜裕・Kedarnath Mahapatra：本州東方海域におけるサンマ漁場と衛星データから得られる海況との関係．「海－自然と文化」東海大学紀要海洋学部，**2(2)**：1-12，2004.