漁船モニタリングデータを用いた ニューラルネットワークによる魚類密度分布推定

正会員 岩 場 公 利*
正会員 濱 田 孝 治***

正会員 多部田 茂**
正会員 水 野 勝 紀**

Estimation of fish distribution by means of neural network using monitoring data by fishing boats

by Kimitoshi Iwaba, *Member* Shigeru Tabeta, *Member*
Takaharu Hamada, *Member* Katsunori Mizuno, *Member*

Summary

It is important to understand and predict fish behavior to assess the impacts of coastal development on ecosystem or to conduct appropriate fishery management. In order to collect information for understanding fish behavior, we measured the environmental factors and the distribution of fish simultaneously by using fishing boats. The memory-type sensors were attached to the fishing gear of the small trawling boats in Ise Bay, through which the water temperature, dissolved oxygen, and depth were measured as well as position information by GPS. At the same time, fish catch of each haul by trawling were recorded to grasp the fish distribution. The obtained data provides much more information for temporal and spatial distribution of water qualities than conventional monitoring. We tried to predict resource distributions by artificial neural network using the obtained data. It is found that the environmental factor affecting the behavior of conger eel varies with respect to the months. The developed neural network could predict the horizontal distribution of the conger eel fairly well.

1. 結 言

海洋開発の生態系への影響評価や、適切な漁業管理のためには、魚類の動態を把握することは重要である。著者らは、マアナゴやマダイを対象として、移動・成長・個体数変動を考慮した魚類動態モデルを開発してきた¹⁾³⁾。これらのモデルは、水温や溶存酸素などの環境因子に基づいて魚類の行動をモデル化しており、漁獲を考慮した個体群動態や資源の空間分布を解析することができる。一方、魚類の行動のモデル化の際に、現場での定性的な情報や室内実験データによって環境因子への応答を決めているため、実海域での魚類の行動特性に関してより詳細な検討が必要である。著者らは、モデルの高精度化のための情報を収集するため、実海域において漁船を用いて水温や溶存酸素等の環境因子と魚類の分布を同時に計測する方法を提案し、その有効性を示している⁴⁾。具体的には、伊勢湾における小型底びき網漁業を対象として、

漁具に記録式の測定機器を取り付け水温、溶存酸素等を計測すると同時に、漁獲量等を記録している。この方法により、従来の調査船やブイ・観測ステーションによるモニタリングと比較して、時空間的に密なデータを取得することが可能になった。沿岸海域における生物分布は水質などの様々な環境因子の影響を受けていると考えられるが、多量のデータが取得できれば、環境因子と生物分布の関係性を機械学習によって効果的に推定できる可能性がある。

本研究では、漁船によるモニタリングで取得した水質データと漁獲量データを組み合わせて、機械学習の一種であるニューラルネットワークを用いて海域環境と生物密度分布の関係を推定するモデルを構築した。

2. 方法

2.1 漁船によるデータの取得

2015 年から有滝地区（伊勢市）の小型底びき網漁船 3 隻に操業記録野帳の記載を依頼すると同時に、GPS ロガーを搭載した。また、Fig.1 に示すように、漁具に水質等のロガーを設置した。漁船や漁具に設置したロガー付きセンサを Table 1 に示す。操業記録野帳には、各曳網ごとにマアナゴを含む 6 魚種の入網量を記録した。データは毎月回収し、曳網ごとの船速、曳網時間、漁獲量、水温、DO、水深の履歴

* 東京大学新領域創成科学研究科（研究当時）

** 東京大学新領域創成科学研究科

*** シャトー海洋調査

を抽出した。

Fig. 1 Sensors on fishing gears of trawling boat

Table 1 Sensors with logger on the fishing boats and gears

項目	機器	計測頻度	設置場所
GPS	Transystem 747Pro	1 分	船上
水温	Onset HoBo U-22	2 分	胴網
溶存酸素 (DO)	Onset HoBo U-26-001	3 分	開口板
圧力 (水深)	Onset HoBo U-20-001-03-TI	3 分	開口板

2.2 データセットの作成

各センサによって得られたデータを結合することによって統合データセットを作成した。各漁船の航跡、船速、および曳網時間は GPS から抽出した。漁網の深さが海面から 5 m 以上である時間を探索することによって、曳網時間を自動的に抽出した。各漁船は 1 日に約 10 回曳網し、1 回あたりの曳網時間は 30～90 分であった。GPS データと組み合わせることで、漁船のすべての軌跡をマッピング可能である。なお、機器不良などにより出漁した全ての日でデータが揃っている訳ではないこと、手作業で記録された操業記録に欠けている情報があったことから、GPS・水温・DO・深度及び操業記録による漁獲量が揃っている曳網の統合データセットを作成した。これらについて、対象魚種の分布密度の指標として、CPUE（単位曳網距離当たりの漁獲量、単位: kg mile⁻¹）を曳網ごとに計算した。

2.3 ニューラルネットワークの構築

漁船によって計測した環境因子と漁獲データを用いて小

型底びき網漁業の主要な漁獲対象種であるマアナゴについて資源分布の予測を試みた。予測には、機械学習の一種であるニューラルネットワークを用いた。ニューラルネットワークの構築にはプログラミング言語「R」を用い、単一中間層ニューラルネットワークパッケージ *nnet* を使用した。ニューラルネットワークは、入力層、中間層、出力層から構成され、一つ一つのニューロンは単純な仕組みだが、それを多数組み合わせる事で複雑な関数近似を行うことができるのが特徴である。Rumelhar ら⁵⁾によって提案されたバックプロパゲーション（誤差逆伝播学習）は、階層型ニューラルネットワークの教師あり学習モデルとして現在最もよく用いられている。学習は（入力信号から出力信号を求める）前向き演算と（誤差が小さくなるように結合係数を修正する）後向き演算によって行われる。本研究では、Venables ら⁶⁾を参考にして結合係数の更新幅を 0.001、学習回数の上限を 10000 回とした。

まず、3.2、3.3 節ではマアナゴの分布がどのような因子に影響されているのかを調べるために、マアナゴの漁獲が確認されている 2016 年 6 月～9 月のデータについて、各月毎にモデルを構築した。マアナゴの CPUE を出力とし、水温、DO、深度、シャコの CPUE の 4 項目を入力とした。水温、DO、深度については、1 曳網間の平均値を用いた。環境因子のデータに加えてシャコの CPUE も入力とした理由は、シャコはマアナゴのエサの一種であり、漁獲データの整理においてマアナゴとシャコは似通った環境条件で多く漁獲されていたためである。日比野⁷⁾は、伊勢・三河湾のマアナゴは、春季は主に魚類をエサとし、それ以降は相対的にシャコへの依存度を増しながら越冬に備えているとしている。

検証用のデータとして各月の全曳網の中から約 2 割を抜き出し、残りの約 8 割を学習用のデータとして使用した。なお、現状ではデータ数がまだそれほど多くないため、ランダム抽出によって抜き出した際に検証データに極端な偏りが生じにくいように、データの抜き出しは CPUE がその月の最大値に対して 0～20%の間のデータから約 2 割、20～40%から約 2 割、のように抜き出した。また、ニューラルネットワークに使用するデータは全て次式で 0～1 に正規化した。

$$y = (T - T_{min}) / (T_{max} - T_{min}) \quad (1)$$

ここで、 T_{max} は入出力の各項目の月最大値、 T_{min} は月最小値、 T が正規化する前の値、 y が正規化した値である。

ニューラルネットワークの構築にあたっては中間層のユニット数が予測精度に関わってくる。ユニット数が多すぎると描く曲面が不必要に複雑となり、学習データに一致させすぎた結果（過学習）、汎用能力の低下をまねく⁸⁾。中間層のユニット数を決定するため、2016 年 6 月のデータを用いて

ユニット数別に予測精度を調べ比較を行った。6月のデータは漁船3隻全てを合計すると、曳網回数158回分の水質・漁獲のデータが存在している。その中から26回の曳網データを抜き出して検証用データとして利用し、その他のデータは学習用データとした。中間層のユニット数が1から5までの5つのニューラルネットワークを構築し、RMSEによって予測精度を評価した。Fig. 2にその結果を示す。中間層が3か4ユニットの場合の予測精度が高く、中でも4ユニットの方がわずかに精度は高い。5ユニットになると予測精度が悪くなるのは、過学習が要因であると考えられる。この結果から、Fig. 3に示すように中間層4ユニットのニューラルネットワークを採用することとした。

さらに、3.4節では漁業者への情報提供などを想定して、日毎のマアナゴの空間分布推定を行った。実際の分布予測では事前にシャコのCPUEを知ることは困難であり、環境因子のみから予測を行うことになると考えられるため、入力からシャコCPUEは除き、水温、DO、深度の3項目を入力としたニューラルネットワークを用いた。

Fig. 2 RMSE of prediction by the neural network with respect to the number of intermediate layer. x

Fig. 3 A developed neural network for predicting CPUE of conger eel.

3. 結果と考察

3.1 水温・DOの分布

観測日ごとの水温、DOの水平分布の例として、Fig. 4に2016年7月30日と8月3日の分布を示す。7月30日には対象漁船は有滝沖で操業しており、曳網の軌跡に沿って水温、DOの実測値を示した。操業している範囲においては北東に向かう程DO濃度が小さくなっており、貧酸素水塊の存在が示唆される。8月3日には対象漁船はより広い範囲を動き回って操業しており、日によって漁場を変えていることがわかる。また、この日の漁場範囲には強い貧酸素は見られず、数日の間に貧酸素水塊の領域が変動している様子が捉えられている。

3.2 ニューラルネットワークによるCPUEの推定

各月のテストデータについて、水温、DO、深度、シャコCPUEの4因子を入力としたニューラルネットワークによるマアナゴCPUEの推定値と実測値を比較した。Fig. 5に最も推定精度が低かった6月と最も高かった9月の結果を示す。6月は最大CPUEの値に対して30%以下のCPUEであった曳網がほとんどを占めており、CPUEが高い時の学習データが非常に少なかった。そのため、CPUEが0~0.2の時は比較的精度が高いが、CPUEが高い時の推定は大きく外れる結果になったと考えられる。9月は、RMSEが0.033で近似直線の傾きも1.02であり、高い精度で推定が出来ていた。9月に高精度な推定が行えた要因としては、学習データの偏りが少なかったことが考えられる。

3.3 マアナゴの動態に寄与している因子

2016年6月~9月のデータを月別に分けて、マアナゴCPUEの予測、及びマアナゴの動態に寄与している因子を調べた。寄与している因子を特定する手順としては、4つの入力項目、シャコCPUE・深度・水温・DOの内、一項目ずつをそのパラメータの平均値で固定してニューラルネットワークの学習に反映させないようにして、予測値のRMSEを比較する。予測精度が最も悪くなった際に固定していた入力項目が最も予測に寄与していると考えられる。

Fig. 6に6-9月のマアナゴの動態に寄与している因子を調べた結果を示す。6月はDOの値を一定に固定した場合が最もRMSEが大きく、予測精度が悪い結果となった。このことから、6月のマアナゴの動態にはDOが最も寄与していると考えられる。7月および8月のマアナゴの動態にはシャコのCPUE（エサ環境）が、9月には水温が最も寄与していると考えられる。このように、マアナゴの動態に最も寄与している因子は月によって異なっていた。

田島ら⁹⁾は東京湾のマアナゴの月別肥満度について、7月から8月にかけて大きく低下するとしている。このことから、7月・8月のマアナゴはエサ環境が悪く、少ないエサを

(a) 30 Jul.

(b) 3 Aug.

Fig. 4 Horizontal distribution of water temperature(left) and dissolved oxygen(right) obtained by fishing boats.

Fig. 5 Comparison of predicted CPUE of conger eel by neural network with actual values

求めたためにエサの一種であるシャコと同じような場所で多く漁獲されていたと考えられる。また、黒木¹⁰⁾はマアナゴの漁獲量と水温の関係について、水温が低いほど漁獲量が多かったことを示しており、本研究の実測結果でも低水温の場

所で多く漁獲がみられた。6月にDOの寄与が大きかった理由としては、6月の水温とDOには相関が高かったことから、マアナゴは低水温を好みながらも低水温側の貧酸素に移動を阻まれ、低DOの場所に蟄集したと考えられる。

Fig. 6 Contributions of each factors to the behavior of conger eel obtained by sensitivity analysis of neural network

3.4 CPUE 水平分布の予測

ニューラルネットワークによる予測結果が水平分布的にどの程度適合しているかを調べた。水平分布が予測できれば、対象魚種が多く獲れる場所を推測することができ、漁業者に有益な情報を提供することができる。ここではマアナゴの漁獲が見られた2016年6月～9月までの全てのデータセットを用いて水温、DO、深度の3因子を入力としたニューラルネットワークを構築した。ただし、予測を行った日のデータは、学習データから取り除いている。なお、Fig. 6に示したように、シャコのCPUEを考慮せず水温、DO、深度から予測する場合には、4項目全てを考慮する場合と比較すると予測精度は低下するものの、RMSEは0.11程度に収まっている。水質の変化が顕著にみられた2016年7月30日～8月17日の期間について毎日にマアナゴの分布予測を行った。ニューラルネットワークは曳網毎に予測値を出力するので、それをGPSデータと対応させることで水平分布を得た。

Fig. 7(a)に7月30日の実測によるマアナゴCPUEの水平分布とニューラルネットワークによる予測結果を示す。実測結果では北東側の水深20m前後の場所においてCPUEが高くなっており、その場所は相対的に低DO・低水温であった。ニューラルネットワークによる予測でも、ほぼ同様の場所においてCPUEが高くなっており、マアナゴの漁獲が多い場所を的確に予測していると言える。Fig. 7(b)に示す8月6日においても、実測値の北西側がCPUEが高く、南側でCPUEが低い傾向が、ニューラルネットワークによって相対的に予測できている。Fig. 7(c)に8月11日のマアナゴCPUE水平分布の実測と予測結果を示す。この日は、広域に低水温、低酸素の水域が広がっており、実測では全体的にマアナゴCPUEが低かった。ニューラルネットワークは、曳網が行わ

れた場所全体でCPUEを実測より大きく予測した。この日は貧酸素水塊が拡大して曳網場所全域が低酸素になっていたために、全体的に漁獲が少なかったと考えられる。一方、ニューラルネットワークは水温やDOの1曳網の平均値を用いるため、それらの傾度に関する情報が学習されないため、曳網場所全体が貧酸素であるという情報は反映されにくい。この日はマアナゴの漁獲量が多い傾向がある貧酸素水塊の縁辺部の条件に近い水温やDOであったため、CPUEが高いと予測したと考えられる。構築したニューラルネットワークは、8月11日のように必ずしも予測が実測と一致しない日もあったが、概ねマアナゴCPUEが高い場所を良好に予測できていた。

4. 結言

漁具に環境測定機器を設置することで、漁場における水温やDOの情報を得ることができた。また、同時に得られた漁獲の情報と合わせて解析することにより、生物の環境への応答に関する有意な情報を得ることができる可能性が示された。機械学習の一種であるニューラルネットワークを用いて、環境因子からマアナゴの分布を予測するモデルを構築し、月によってマアナゴの動態に寄与している因子が異なることを見いだした。マアナゴの水平分布の予測では、漁獲が多かった場所を概ね良好に予測できており、ニューラルネットワークによる分布予測の有用性が示された。なお、学習・検証データの選び方やその質（値の分布等）の影響について、一般的な考察をするためには、より多くのデータが必要であると考えられる。本計測は継続して実施中であり、データの蓄積が期待できるため、今後の課題としたい。

謝辞

データの取得に際し、丸山拓也氏（三重県伊勢農林水産事務所）、館洋氏（三重県水産研究所）、および伊勢湾漁業協同組合には多大なご協力をいただいた。なお、本研究の一部は科学研究費補助金（15H04210）によって実施された。

参考文献

- 1) K. Hakuta, S. Tabeta : Behavioral modelling of *Pagrus major* in the east Seto Inland Sea, *Journal of Marine Science and Technology*, 18(4), 535-546, 2013
- 2) 本宮佑規, 他 : 伊勢湾におけるマアナゴの動態モデルの開発, *水産工学*, 52(2), 83-93, 2015
- 3) 三木皓貴, 多部田茂, 水野勝紀: 魚類動態シミュレーション

(a) 30 July

(b) 6 August

(c) 11 August

Fig. 7 Horizontal distributions of actual CPUE of conger eel (right) and prediction by the neural network (left).

ョンにおける行動モデルの検討, 日本船舶海洋工学会論文集, 28, 155-162, 2018

- 4) S. Tabeta, et al.: Environmental monitoring using small fishing boats in Ise Bay, Proc. 13th International MEDCOAST Congress on Coastal and Marine Sciences, Engineering, Management & Conservation, Vol.2, 765-773, 2017.
- 5) D. E. Rumelhart, G. E. Hinton, R. J. Williams : Learning representations by back propagating errors, Nature, 323, 533-536, 1986.
- 6) W.N. Venables, 他 : S-PLUS による統計解析, シュプリンガー・フェアラーク東京, 589 p., 2001.

- 7) 日比野学 : 伊勢・三河湾におけるマアナゴの食性, マアナゴ資源と漁業の現状, 3, 101-102, 2016.
- 8) 鹿山昌宏, 阿部重夫, 武長寛, 諸岡泰夫 : 多層ニューラルネットの最適中間層ニューロン数決定方法, 電気学会論文誌 D, 112, 1064-1070, 1992.
- 9) 田島良博, 臼井一茂 : 東京湾におけるマアナゴの肥満度及び脂質の季節変動について, マアナゴ資源と漁業の現状, 3, 32-33, 2016.
- 10) 黒木洋明 : マアナゴの産卵場所から沿岸域への仔魚回遊過程 : 水温変化に対する応答, マアナゴ資源と漁業の現状, 3, 8-14, 2016.