

# ニューラルネットワークによる瀬戸内海東部の イカナゴ加入量予測

日下部敬之\*・小松輝久\*\*・玉木哲也\*\*\*

中嶋昌紀\*・青木一郎\*\*\*\*

## Prediction of the Recruit of Sand Eel in the Eastern Seto Inland Sea Using a Neural Network

Takayuki KUSAKABE\*, Teruhisa KOMATSU\*\*, Tetsuya TAMAKI\*\*\*,  
Masaki NAKAJIMA\* and Ichiro AOKI\*\*\*\*

### Abstract

We attempted to predict the recruit of sand eel *Ammodytes personatus* in the eastern part of the Seto Inland Sea, including Kii Channel, Osaka Bay, and Harima-Nada Sea in February, using a neural network. In the predicting system, three-layered network (input, output and intermediate layers) and back propagation algorithm were used. Water temperature and salinity, strength of west wind, spawning date, and catch number of sand eel larvae obtained by surveys were used as input variables.

The recruit predicted by the neural network agreed well with the actual recruit. The synapse weights in the trained neural network showed that the recruit was expected to be higher when water temperature was low in the preceding September, west wind was strong in late December and early January, and catch number of sand eel larvae was high in Osaka Bay in February. The influence of variation of training data on accuracy of the prediction was also examined.

### 1. はじめに

イカナゴ *Ammodytes personatus* は瀬戸内海では冬季に産卵し(浜田, 1985), 生まれた稚魚は2月下

旬から5月頃にかけて, 主として機船船びき網漁業によって漁獲される(中国四国農政局統計情報部, 1996). 本種は瀬戸内海の東部に面する大阪府や兵庫県において, 漁獲量の多さから最も重要な漁獲対象種の一つとなっている. 近年, 大阪府と兵庫県では漁業者がイカナゴの資源管理に取り組み, 解禁日や操業時間などに関して自主規制を行っているが, この資源管理を有効なものにするためには, 漁期前にその年の加入量を予測することが不可欠である. 瀬戸内海東部海域のイカナゴの漁況予測はこれまでに, 幾組かの単相関を用いて判断する方法(浜田, 1972), 重回帰式による方法(土井, 1971, 俵, 1984), 構造モデルを使用する方法(中田・平野, 1984)などにより試みられている. いっぽう最近になって, ニューラルネットワークモデルをマイワシ *Sardinops melanostictus* やマアジ *Trachurus japonicus* の漁況予測に適用する試みがなさ

1997年4月7日受付 1997年8月1日受理

\*大阪府立水産試験場  
Osaka Prefectural Fisheries Experimental Station  
2926-1, Tanigawa Misaki, Sennan, Osaka 599-03,  
Japan

\*\*東京大学海洋研究所  
Ocean Research Institute, University of Tokyo 1-15  
-1, Minamidai, Nakano-ku, Tokyo 164, Japan

\*\*\*兵庫県立水産試験場  
Hyogo Prefectural Fisheries Experimental Station  
Minami-Futami, Akashi 674, Japan

\*\*\*\*東京大学大学院農学生命科学研究所  
Graduate School of Agricultural and Life Sciences,  
University of Tokyo 1-1-1, Yayoi, Bunkyo-ku, Tokyo  
113, Japan

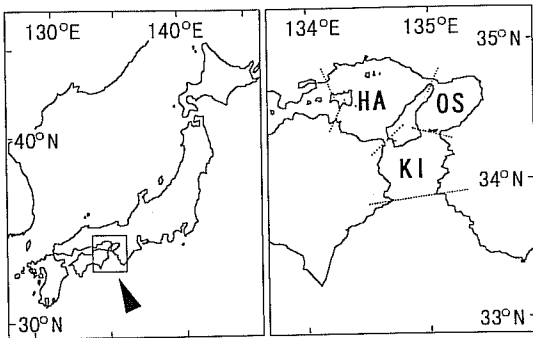


Fig. 1. Map showing the eastern Seto Inland Sea. KI: Kii Channel, OS: Osaka Bay, HA: Harima-Nada Sea.

れ、予測に用いる変数の選定や扱いが容易であることが報告されている (KOMATSU *et al.*, 1994, 黄ほか, 1996)。そこで著者らは瀬戸内海東部海域のイカナゴについて、漁期前に得られる気象、海象、生物に関するデータを説明変数として、ニューラルネットワークモデルを用いた当歳魚加入尾数予測を試みた。

#### 方法

瀬戸内海東部に位置する紀伊水道、大阪湾、および播磨灘の3海域 (Fig. 1) では、漁獲努力量と自然死亡を考慮したコホート解析法によって、1985~1993年の各年のイカナゴ当歳魚加入尾数が推定されている (瀬戸内海東区資源管理型漁業推進協議会, 印刷中)。さらに今回同じ方法で1994年についても推定を行い、それらを合わせた1985~1994年の10年間の当歳魚加入尾数推定値を実績値として使用した。つぎにイカナゴの加入量を左右すると考えられる要因として、前年9月の大阪湾底層水温、産卵日指数、西風平均風速 (12月下旬と1月上旬)、1月の大阪湾底層の水温と塩分、および仔魚採集調査の結果 (1月と2月の播磨灘と大阪湾それぞれの1調査点あたり平均採集尾数) の10項目を選び、説明変数とした。各変数の詳細について以下に記す。また、各変数と当歳魚加入尾数実績値の、対象期間中の年変動を Fig. 2 に示す。

前年9月の大阪湾底層水温 (T9)、1月の大阪湾底層水温 (T1)、および1月の大阪湾底層塩分 (S1) については、大阪府立水産試験場が月の上旬に実施している海洋観測で得られた、湾内20点の平均値を用いた。産卵日指数 (SD) については、水温の推移や仔魚の出現時期などから兵庫県立水産試験場が推定した産卵盛期を、12月15日を0として、それより早い場合




Fig. 2. Annual variations of actual recruit and input variables from 1985 to 1994.

AR: Actual recruit, T9: Water temperature in the preceding September, WL12: Strength of west wind in late December, WE1: Strength of west wind in early January, T1: Water temperature in January, S1: Water salinity in January, SD: Index of spawning date, H1, O1: Catch number of sand eel larvae obtained by surveys in Harima-Nada Sea and Osaka Bay in January, H2, O2: Catch number of sand eel larvae obtained by surveys in Harima-Nada Sea and Osaka Bay in February.

はマイナスの、遅い場合にはプラスの日数で表した。12月下旬の西風平均風速 (WL12)、および1月上旬西風平均風速 (WE1) については、大阪府立水産試験場が実施している風向風速観測の結果から東西成分だけを取り出し、西風をプラス、東風をマイナスとして、旬の平均値を使用した。1月の播磨灘仔魚採集数 (H1)、1月の大阪湾仔魚採集数 (O1)、2月の播磨灘仔魚採集数 (H2)、および2月の大阪湾仔魚採集数 (O2) については、兵庫県立水産試験場が月の上旬に実施しているプランクトンネットを用いた採集調査による、調査点1点あたりの平均採集尾数を用いた。

本研究で用いた教師信号付きの階層型バックプロパゲーション型ニューラルネットワークの原理を簡単に述べる。ネットワークは説明変数の値を受け取り中間層へ出力する入力層、最終的な出力値を出す出力層、および両者の間に介在する中間層から構成される。中間層の数は1層とした。それぞれの層には「細胞 (ニューロン)」と呼ばれる計算単位が存在する。各細胞は、一つ下の層の  $i$  番目の細胞の出力値  $X_i$  と重み  $W_i$  (シナプス荷重) の積和  $U$  を出力関数  $f$  によって処理し、上位の層に出力する。

$$U = \sum W_i X_i$$

$$f(U) = \frac{1}{1 + \exp(-U + \theta)}$$

出力関数  $f$  は 0 から 1 の範囲の値を出力するシグモイド関数で、 $\theta$  はしきい値である。変数はモデル内では 0 ~ 1 の範囲の値に基準化されて使われる。出力層から出た結果は正解である教師信号 (実績値) と比較され、すべての学習年から得られる出力値と教師信号の誤差の平方和を最小にするように、各細胞のシナプス荷重としきい値を調節する計算を繰り返す。これが学習と呼ばれる過程である。今回はこれらの計算をパーソナルコンピュータ上で行うソフト (CRC製、ニューロコンピューティングソフト RHINE) を用い、各ケースとも学習回数を3,000回として計算を実行した。入力値としては、上に述べた10個の説明変数を用い、教師値として、当歳魚加入量推定値を用いた。したがって入力層細胞数は10、出力層細胞数は1である。中間層の細胞数は3とした。

## 結果

### 1. 予測結果と各入力細胞のシナプス荷重値

まずケース1として1985年から1991年までの7年間




Fig. 3. The predicted (dotted line) and actual (solid line) recruit of sand eel in the eastern Seto Inland Sea in Case 1 (learning period: 1985-1991, testing period: 1992-1994).




Fig. 4. The synapse weights of the connections from each input unit to three intermediate units in the supervised learning in Case 1. See Fig. 2 for symbols of input variables.

を学習期間としてモデルを構築し、1992年から1994年までの3年間を予測検証年として、実績値との当てはまりを調べた。その結果、Fig. 3に示すように実績値に対する誤差は1992年で2.7%、1993年で16.4%、1994年で1.2%と、全体として当てはまりは良好で、実用上十分と思われる予測が行われた。

つぎにどのような要因がイカナゴの加入量に影響を与えているのかを探るために、使用した10個の説明変数が3つの中間層細胞に伝達される際の、シナプス荷重の大きさを Fig. 4に示す。シナプス荷重は、重回帰分析における標準偏回帰係数と類似のもので、正の荷重は出力層からの出力値を増加させる方向に働くもの、負は減少させる方向に働くものである (青木・小松, 1995)。なお中間層の3つの細胞の、出力層細胞に対するシナプス荷重の絶対値は2.894, 3.478, 2.332であり、出力層細胞に対する結合強度はどの中間層細胞も大差はなかった。説明変数のうち、西風平均風速と産卵日指数、および2月の仔魚採集数の各変数は、




Fig. 5. The predicted (dotted line) and actual (solid line) recruit of sand eel in the eastern Seto Inland Sea in Case 2 (learning period: 1988-1994, testing period: 1985-1987).




Fig. 6. The predicted (dotted line) and actual (solid line) recruit of sand eel in the eastern Seto Inland Sea in Case 3 (learning period: 1985-1989 and 1993-1994, testing period: 1990-1992).

値の増加によって出力値を増加させる正の要因として働いていた。いっぽう前年9月底層水温、1月底層水温、1月底層塩分および1月の仔魚採集数の増加は負の要因となっていた。それらの中でも荷重値が大きいのは、正の要因の西風平均風速（12月下旬、1月上旬とも）と大阪湾の2月の仔魚採集数、負の要因の前年9月大阪湾底層水温であった。

## 2. 学習期間の変更が予測精度に与える影響

10年間の実績値のうちの最小値は1987年の1,072億尾であるが、これは Fig. 2 からわかるように突出した値ではない。それに対して最大値の1991年の2,369億尾は、他の値から突出している。ケース1ではこれらはともに学習期間に含まれていたが、片方ずつ学習期間から除外し、予測精度の変化を調べた。まずケース2として、1988~1994年の7年間で学習期間とし、最小の実績値を示した1987年を含む1985~1987年の3年間で予測検証年としてみた。その結果、Fig. 5 に示すように実績値との誤差が1985年で4.9%、1986年で19.2%、1987年で16.2%となり、ケース1よりはやや精度が低下したが、3年とも20%以下の誤差に収まっていた。ところがケース3として、実績値が最大を示した1991年を含めて1990~1992年の3年間で検証年とし、残りの7年間で学習期間として当てはまりを調べたところ、実績値との誤差は1990年では0.2%、1991年で29.0%、1992年で10.5%となり、1991年の突出値を再現できず、実際よりもかなり小さい値を予測してしまった (Fig. 6)。

## 考 察

今回のモデルでは、西風平均風速がイカナゴ当歳魚加入量を増大させる大きな正の要因となっていたが、これまでの報告でも、西からの季節風による吹送流はふ化した仔魚の拡散を助長し、仔魚期の生残率を高め、さらには隣接する備讃瀬戸からの仔魚の添加も助長することで加入量を増加させる方向に働くと考えられており (土井, 1971, 中田・平野, 1984, 浜田, 1966, FUJIWARA *et al.*, 1990), 本報告もこれらの考えを追認した。

2月の仔魚採集数が多ければ加入量も多いのは当然と思われるが、興味深いのは1月の仔魚採集数が負の要因となっていたことである。イカナゴの産卵は12月後半~1月上旬であるが、山田 (1994) によれば産卵からふ化までには10日前後を要するので、産卵期が遅めの年は1月上旬の調査時にはまだ仔魚がふ化していない。したがって1月の仔魚採集数は、その年の発生量の指標としてよりも、むしろ産卵期が早いか遅いかということの指標として見るべきであろう。今回のモデルで用いた産卵日指数も、産卵期の遅れが加入量を増加させる方向に働いており、上記の考えと矛盾しない。しかしながら、なぜ産卵期が遅れると加入量が増加するのか、その理由は明らかではない。産卵期が遅れた年に共通した特徴を探して、加入量を増加させている要因が何なのかを検討する必要があるだろう。

モデルの中で強い負の要因として働いていたのは、夏季に親魚が経験した最高水温の指標として使用した前年9月の底層水温であり、夏眠中の親魚に高水温が悪影響を与える可能性が示唆された。イカナゴはもと




Fig. 7. The predicted (dotted line) and actual (solid line) recruit of sand eel in the eastern Seto Inland Sea in Case 4 (learning period: 1985-1991, testing period: 1992-1994).

もと冷水性の魚種であり(浜田, 1985), 飼育実験でも夏眠期の水温が $26^{\circ}\text{C}$ を越えると斃死する個体が出現する(山田, 私信). 前年夏季の高水温は, 夏眠中のイカナゴ親魚に生理的にストレスを与え, 卵数や卵質を低下させることによって次世代の加入量を減少させているのであろう.

産卵期前後の水温が高いと加入量が減少する点については, 浜田(1966, 1972)や土井(1971)が指摘している. 前述のように冷水性の魚種であるイカナゴにとって, 低水温の方が産卵および仔魚の生残に好適なのであろう. しかし塩分については, 浜田(1966, 1972)や土井(1971)は高塩分(塩素量)のほうが加入量が増加するとしており, 今回の結果と異なっている. そこで試みに今回の入力項目から塩分値を取り除き, ケース1と同様の学習年, 検証年を設定して予測の当てはまりを調べたところ(ケース4), 1992年と1994年について誤差がやや大きくなり(Fig. 7), また説明変数の中間層細胞に対するシナプス荷重の符号も, 出力値に対する一貫性に乱れが生じた. このことは, 今回の予測モデルでは塩分値が負の要因として必要であることを示している. 浜田(1966, 1972)や土井(1971)と本報告とで塩分値が加入に与える影響の符号が異なったのは, 彼らが播磨灘の1~3月の塩素量を使用したのに対して, 本報告では大阪湾の1月の底層塩分を使用したのが原因ではないかと考えられる. 浜田(1966)が播磨灘の1~3月の塩素量は西風による吹送流の強さを示す指標であるとしているのに対し, 今回用いた大阪湾の1月の底層塩分は, むしろ紀伊水道からの外海系水の入り込みの強弱や, 降水量の指標と

見るべきである(森安, 1985). 外海系水には内湾系水に比べて餌料プランクトンが少なく, イカナゴ仔魚の捕食者であるフクラヤムシ *Sagitta enflata* が多いので(浜田, 1969, 1974), 外海系水の湾内への入り込みはイカナゴの加入量に悪影響を与える可能性がある. しかし降水量と加入量との関係は不明であり, この点については今後詳しい解析が必要である.

ケース3で, 実績値が学習期間の範囲からかけ離れた年の予測精度が低かったが, これは学習期間のデータの最小値と最大値の範囲内で事象を予測するニューラルネットワークのアルゴリズムの特性によるものと考えられる. ニューラルネットワークモデルは人間の脳細胞の構造を模倣して作られたものであるが(SMITH, 1996), 過去に経験した範囲から逸脱した予測値が出力できないという点でも, 非常に人間の脳に似たモデルであるといえる. ニューラルネットワークモデルの資源量予測への適用にあたっては, この点を考慮し, なるべく極端な不漁年や豊漁年を学習期間に含めるように留意すべきであろう.

漁業者と向き合った水産の現場での漁況予測は, 通常過去のデータ蓄積年数も十分でなく, また説明変数相互の関連も不明である下で行わなければならないことが多い. そのような場合に, 説明変数の個数がデータ年数の規制を受けず, また説明変数相互の独立性も必要ないという点で, ニューラルネットワークモデルは使いやすいモデルであると考えられる. また, 出力項目に影響を与えているのかどうか疑わしい変数をとりあえずすべて含めてモデルを構築し, シナプス荷重値を調べてみれば, 資源量変動に影響を与えていそうな要因の候補を選別することができるので, 漁況予測のために実施すべき調査の項目を考える際の参考にもなるものと思われる.

## 謝辞

本論文を書くにあたって, 各種データを提供してくださった大阪府および兵庫県の関係者各位に深く感謝します. また, 日本NUSの保正竜也氏にはニューラルネットワークモデルについて有益なご教示をいただきました. 厚くお礼を申し上げます. なお本研究は, 東京大学海洋研究所共同利用研究員プログラムの成果であることを付記します.

## 引用文献

青木一郎・小松輝久(1995) マイワシ資源変動解析へのニュー

- ラルネットワークの応用. 月刊海洋, 27, 428-433.
- 中国四国農政局統計情報部 (1996) 平成6年度瀬戸内海地域における漁業動向. 中国四国農林統計協会協議会, 岡山, 91pp.
- 土井長之 (1971) イカナゴの発生量数値予測. 長期漁況予報東海区, 東海区水産研究所, 東京, 23, 37-42.
- FUJIWARA, T., H. NAKATA, M. TANDA and J. KARAKAWA (1990) Biological and physical parameters of sand eel larvae in the eastern Seto Inland Sea. Bull. Japan. Soc. Sci. Fish., 56, 1029-1037.
- 浜田尚雄 (1966) 播磨灘, 大阪湾におけるイカナゴ発生量変動に関する研究-Ⅲ. 産卵期前後の海気象との関係. 日水誌, 32, 579-584.
- 浜田尚雄 (1969) 大阪湾における*Sagitta enflata*の進入条件について. 日水誌, 35, 717-722.
- 浜田尚雄 (1972) 播磨灘, 大阪湾におけるイカナゴ発生量変動に関する研究-Ⅷ. 体長組成と漁況予測について. 兵庫水試試験報告, 12, 7-15.
- 浜田尚雄 (1974) 播磨灘・大阪湾におけるイカナゴ発生量変動に関する研究-Ⅸ. 毛顎類との関係. 兵庫水試試験報告, 14, 1-4.
- 浜田尚雄 (1985) 我が国におけるイカナゴの生態と漁業資源. 水産研究叢書, 36, 日本水産資源保護協会, 東京, 85pp.
- 黄 康錫・青木一郎・小松輝久・石崎博美・柴田勇夫 (1996) ニューラルネットワークを用いた米神定置漁場のマアジ漁獲量予測. 水産海洋研究, 60, 136-142.
- KOMATSU, T., I. AOKI, I. MITANI and T. ISHII (1994) Prediction of the catch of Japanese sardine larvae in Sagami Bay using a neural network. Fisheries Science, 60, 385-391.
- 森安茂雄 (1985) 大阪湾. 日本海洋学会沿岸海洋研究部会編, 日本全国沿岸海洋誌, 東海大学出版会, 東京, 625-629.
- 中田英昭・平野敏行 (1984) 構造モデルによる漁場環境変化予測. 海洋科学, 16, 644-649.
- 瀬戸内海東区資源管理型漁業推進協議会 (印刷中) 平成6年度資源管理型漁業推進総合対策事業報告書 (広域回遊資源).
- SMITH, M. (1996) Neural networks for statistical modeling. International Thomson Computer Press, Boston, 235pp.
- 依 悟 (1984) 重回帰分析法による漁獲量の予測. 海洋科学, 16, 618-623.
- 山田浩且 (1994) 伊勢湾におけるイカナゴ. 田中 克・渡邊良朗編, 魚類の初期減耗研究, 水産学シリーズ, 98, 恒星社厚生閣, 東京, 109-121.