

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

黄 康錫*・青木一郎*・小松輝久*・石崎博美**・柴田勇夫**

Forecasting for the catch of jack mackerel in the Komekami set net by a neural network.

Kangseok HWANG*, Ichiro AOKI*, Teruhisa KOMATSU*,
Hiromi ISHIZAKI** and Isao SHIBATA**

Abstract

We study forecasting the catches of jack mackerel in the Komekami set net in the Sagami Bay, central Japan, using an artificial neural network. The supervised learning paradigm, three-layer network and back-propagation algorithm was used. For the forecasting, CPUE of jack mackerel in six set nets, temperature of sea surface and 50-meter depth in the Sagami Bay are used as input vectors.

The CPUE of jack mackerel in the Komekami set net can be predicted from those of the preceding month and temperature in the Sagami Bay. The CPUE of jack mackerel of the neighboring set nets gave little information for the forecasting. The synapse weights showed that except for April, the CPUE of jack mackerel were expected to be higher when temperature deviations were higher in the west of the Sagami Bay and lower in the east. The forecasted results by the neural network were more accurate than those by a multiple regression analysis.

1. はじめに

相模湾沿岸の定置網における漁獲量は時期と地域によって不規則に変動していることが報告されている(木幡, 1990)。多くの定置網漁場は周年操業しており、全体で約200種類の魚種が漁獲されるが10種前後の魚種で総漁獲量の9割以上を占め、主漁獲対象魚種は回遊性の浮魚類になっている。

湾内には反時計回りの循環流が存在し、その消長は、黒潮分枝流の変動とよく対応している(岩田・木幡, 1987)。そして黒潮分枝流は黒潮流軸の離接岸と密接に関係しており、湾内の海況は沖を流れている黒潮の影響を強く受けている。

本研究はニューラルネットワークを用いた漁海況の

予測手法に関する研究の一環として、相模湾の米神定置漁場のマアジ漁獲量の予測法を検討した。

米神漁場は相模湾の大型定置網の中でも最も大きい規模の定置網で西湘地区の定置網漁場の代表的な漁場である。漁獲種の中で、近年マアジは、西湘地区の定置網の第1優占種となっており、3月から米神漁場を中心として漁獲され始める。

岸(1981)は米神定置漁場における日々のマアジ漁獲量を相模湾沿岸の水温と潮位からGMDH法による予測を行い、6月に水温変化が漁獲量に敏感に影響しており、春季(4~6月)の漁獲量は大島西水道の海況に影響されていることを示した。しかし、その予測精度は良いとはいえず、まだ、実用には使いにくいと思われる。そして、予報としてはせめて週単位、月単位の予測値が必要であると述べている。

本研究では、米神定置漁場における3~6月の月別のマアジ漁獲量を過去の定置網漁況と相模湾の水温から予測することを試みた。

1996年2月19日受理

* 東京大学海洋研究所 Ocean Research Institute, University of Tokyo, Nakano, Tokyo 164, Japan

** 神奈川県水産総合研究所相模湾試験場 Kanagawa Prefectural Fishery Sagamiwan Experimental Station, Odahara, Kanagawa 250, Japan

2. 資料及び方法

2.1 入出力項目とネットワークの構造

漁況データ：本研究では、相模湾の米神定置漁場のマアジ漁獲量（単位努力当たり漁獲量）を予測する上で、漁況資料としては神奈川県水産総合研究所相模湾試験場で収集・蓄積されている相模湾定置網漁獲量データベースを用いた。その資料の中から、米神定置漁場およびその近傍の5つの定置網漁場（真鶴沖網，真鶴改良網，岩1号，前川，石橋）の月別マアジ漁獲量を使用した（Fig. 1）。ただし、各々の漁場におけるの作




Fig. 1. Map of the Sagami Bay. The numeric and alphabetic characters show positions of set nets and stations of temperature observations, respectively. (1,2: Manazuru; 3: Iwa; 4: Komekami; 5: Ishibashi; 6: Maekawa)




Fig. 2. Monthly variations in the catch per unit effort (CPUE) of jack mackerel in Komekami set net during the period 1970-1991.

業日数が異なったので、揚網日当たりの漁獲量，すなわち単位努力当たり漁獲量（CPUE）を計算し使用した。

海況データ：相模湾内の毎月の定点観測点のうち、9つの定点における表面水温と50m水温の季節変動を除いた平年偏差値を使った。

以上の漁海況資料は、それぞれ1970年から1991年までの22カ年の資料を利用した。

米神漁場におけるマアジの年別・月別 CPUE 変動は、1970年から1976年の間には春に漁期が集中して漁獲量も多かったが、1977年から1985年にかけてはその量が激減し、低い水準で推移していた。その後1986年からは年に1度づつ秋と春に好漁期が繰り返して現れ、再び漁獲量が増加していた（Fig. 2）。このようなマアジ漁獲量の季節的な変動をみると、春（3～6月）と秋（10～11月）の2つの漁期として1年の漁獲パターンを考察することができる。

そこで、ニューラルネットワークの出力値は米神定置漁場のマアジ CPUE に固定して、入力変数として時間的に3つのケースを考えた。すなわち、ケース1：予測する月の前の月の海況と漁況を入力変数とする。ケース2：前年の秋の漁海況と前の月の海況を入力変数とする。ケース3：前年同期の漁海況と前の月の海況を入力変数とする。

2.2 ニューラルネットワーク

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（backpropagation network，誤差逆伝播法）ニューラルネットワークの原理を概略すると、まずネットワークの構成は多数の入力信号を受け取る入力層，出力信号を出す出力層，その間に中間層がある構造になっている。またそれぞれの層は多数の細胞（unit）を持つ構造になっている。ここで入力信号を X_i とすると、この入力信号は(1)式のようにそれぞれ W_i の重み（シナプス荷重）を付けた入力信号の総和（ U ）が出力関数（ f ）によって処理，出力される。

$$U = \sum W_i X_i \quad (1)$$

$$f(U) = \frac{1}{1 + \exp(-U + \theta)} \quad (2)$$

それは同時に次の層の細胞へ入力される。ここで出力関数 f は(2)式のように非線形関数であるシグモイド状の関数になっている。ここで θ はしきい値である。ニューラルネットワークの学習では、出力層から出た結果は正解である教師信号と比較され、全ての入力パ

ターンから得られる出力値と教師信号との誤差の二乗の総和を最小にな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過程を繰り返す。計算が終了すると、このシナプス荷重の強さによって出力値に対する入力ベクトルの寄与強度を知ることができる。

このような学習特性を持っているニューラルネット

ワークの1つの長所としては入力ベクトル、すなわち説明変数の数に制限がないため計算に用いるときに考えられる変数を全て使えることである。

本研究では入力層と出力層の間の中層が1層である3層構造のバックプロパゲーションネットワークを使った。入力ユニットはケース1で24個、ケース2と

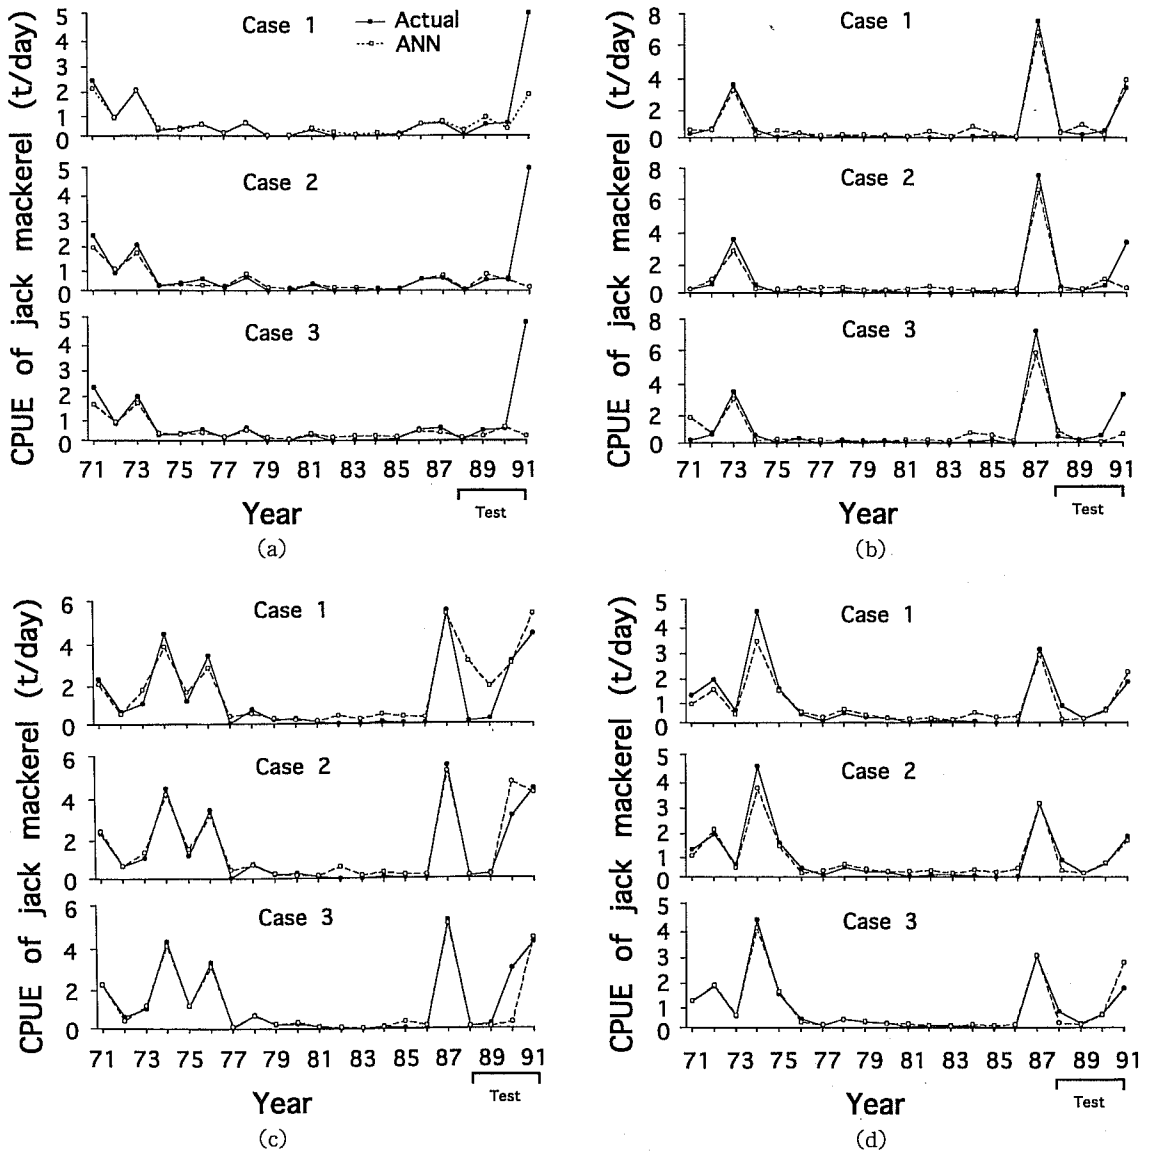


Fig. 3. Comparison between the actual CPUE (solid line and circle) of jack mackerel and the outputs (dashed line and open circle) forecasted by neural networks of three cases in March (a), April (b), May (c) and June (d). The neural networks were trained by input data for one month before (Case 1), six months before (Case 2) and one year before (Case 3) the months to be forecasted. Prediction was tested by the data from 1988 to 1991, where data from 1970 to the preceding year of each prediction test were used for the training.

3で42個であり、中間ユニットはいずれも10個に設定した。出力ユニットは1個である。

3. 結果及び考察

3.1 ニューラルネットワークによる予測

3～6月の各月の米神定置漁場におけるマアジのCPUEを予測した。ここで、1988～91年のデータを予測のテストとして用いた。すなわち、1971～1987年まで学習させて1988年のCPUEを予測した。そして、1989年の予測においては前年の1988年まで学習させ、予測値を求めるようにして、1991年まで予測したい年の前年まで学習させて予測テストを行った。すなわち、学習データは18～21組である。そして、学習回数は1000～10000回の範囲で変えて、最も誤差の小さい学習回数の場合を最終結果とした。

3月の予測の結果、3つのケース共に、漁獲量が低かった1988～1990年の予測は実績値に近く予測できたが、漁獲量が非常に高かった1991年の予測は3つのケース共に大きく外れた結果になった (Fig. 3-a)。しかし、ケース1では漁獲量の増加傾向がある程度表しており、予測手法として使用の可能性を見ることができた。このような結果から見ると、3月の予測において、3つのケースの中ではケース1が比較的好かった。

4月の予測では、ケース2と3の場合、1988年の急減はうまく再現できたが、1991年の増加を表すことができなかった (Fig. 3-b)。一方、ケース1では1988年から1991年までよく予測できてほぼ完璧なネットワークが構築された。そこで、これらのケースの結果から考えられるのは、予測あるいは再現部分のデータが急激に変動する場合でもネットワークの設計によって、その値が学習値の範囲以内であれば予測が可能になることである。言い換えると、予測を行う上で、学習データ、すなわち過去のデータがバリエーションとして十分に揃っていれば精度の高い予測ができると考えられる。

平年的に1年の中で一番漁獲量が多かった5月の場合 (Fig. 3-c)。ケース1よりケース2の結果の方が精度が高く得られた。しかし、ケース1の場合、誤差は大きい、変動のパターンはある程度再現されている。ケース3では88年と89年の減少と91年の増加の予測は実績値に近かったが、90年の予測は88～89年の低水準と同じ傾向を示し、実際の増加とは大きく外れた結果になった。

漁期の終わりに当たる6月の場合では3つのケース

共に実績値に極めて近い予測値が得られた (Fig. 3-d)。

以上のように3～6月の漁期中の予測において、ケース1以外のケースの結果が良かった時もあったが、漁期全体をみるとケース1の場合に他のケースより正確な予測結果が得られた (Fig. 4)。このような結果から、予測する月の前の月の漁海況情報を用いることにより、米神定置漁場におけるマアジ漁獲量を予測すること




Fig. 4. Correlation between the forecasted outputs and actual CPUE of jack mackerel in Komekami set net in the three Cases. The regression equations were calculated with an intercept set up zero.

が可能となると考えられる。漁期後半の5、6月の予測ではケース2も良かった。5、6月に漁獲されるマアジは前年秋に漁獲されるものと関連があるように考えられる。

一方、漁期が始まる時期の3月の場合、前の月の漁獲量が低いので、この月の漁獲をどの程度予測できるかということが1つの注目点であった。漁獲量の低いときは予測できたが、1991年の好漁は予測できなかった。この1991年の予測における入力変数の値を見ると、定点Gの表面水温値が -1.6°C であり、1971年～90年の学習データの値の範囲($1.6\sim-1.5^{\circ}\text{C}$)外にあった。他の1991年の入力変数の値は全て学習データの値の範囲内であった。一方、1991年の実績漁獲量4.8トンは学習期間1971年～90年の実績漁獲量の範囲(0.01～2.2トン)を越えていた。

このような予測時期の入力変数の値が学習データの値の範囲内であれば出力値も学習データの値の範囲内になることが期待されるので、1991年の予測は外れたと考えられる。このような場合に予測するためには入力変数を再検討する必要がある。従って、漁期初めの3月の予測には本研究で使った入力変数以外の別の因子を用いる必要があると考えられる。

3.2 線形回帰分析との比較

ニューラルネットワークによる予測と、一般に予測によく使われている線形回帰分析方法による予測の精度を比較するため、ケース1の前の月の漁海況から予測する場合で、両手法を比べてみた。ただし、単回帰分析では水温データは使わずに、後述するようにシナプス荷

重が最も大きかった米神定置における1カ月前の漁獲量データを独立変数にして回帰させた。一方、重回帰分析の場合には、データの数よりも入力変数の数が多いのでニューラルネットワークと同じ数の入力変数を用いると重回帰分析では計算できない。そこで、ニューラルネットワークの場合より入力変数の数を減らして計算する必要がある。しかし、ここで用いた漁海況データから事前に変数を選ぶことは大変難しいと考えられる。ここでは、ニューラルネットワークによる計算によって得られたシナプス荷重の分析に従って重回帰分析に使う独立変数12個を選んだ。

1988～1991年のデータで予測テストをした結果、単回帰分析による予測ではいずれの年も1トン以下の低い値を示し、実際の漁獲量が少なかった1988、89年にはその誤差が小さく、漁獲量が多かった1990、91年には大きな誤差を示した(Fig. 5)。そして重回帰分析では1989、90年はニューラルネットワークの予測と類似した傾向を示したが、誤差はニューラルネットワークの予測値よりも大きかった。また、1991年は実際の変動の傾向をうまく表すことができなかった。そこでFig. 4と同様に、この3つの手法による予測値を実績値と回帰させて決定係数(r^2)を比べて予測精度を評価すると、ニューラルネットワーク(0.685)、単回帰分析(0.561)そして重回帰分析(0.457)の順番で、3つの手法の中ではニューラルネットワークが最も誤差が小さかった。なおかつ、その時の回帰式の傾きはニューラルネットワーク(0.853)重回帰分析(0.702)そして単回帰分析(0.501)の順番になっており、傾き1の理想的な回帰




Fig. 5. Comparison between the actual CPUE of jack mackerel (Actual) and forecasted CPUE by neural network (ANN), multiple regression analysis (MRA) and single regression analysis (SRA). The figure represents test periods only from 1988 to 1991.

式を考えてもニューラルネットを用いた方が最も良い結果であった。

もちろん重回帰分析を用いる時に、変数の設定をうまく工夫すれば、もっと良い結果を得ることができると思われるが、ニューラルネットに比べると、適切な説明変数の数や種類などを選定することに手間がかかることが予想される。このように、変数の選定や数に制限もないニューラルネットは重回帰分析を包括した、適用の範囲が広く、かつ容易な予測手法と考えられる。

3.3 シナプス荷重

ケース1において、出力層と強く結合した中間層細胞との結合の強さが絶対値1以上の入力変数をFig. 6に示した。横軸は入力項目として左の方(A0~I50)が水温項目、右の方が漁獲量の項目(S2~S6)でS4が前月の米神定置漁場の漁獲量である。縦軸はシナプス荷重の強さを示し、正は興奮性の結合、負は抑制性の結合を示している。入力項目の中で、漁況に関しては、漁期初めの3月では荷重は1以下であったが、他の月では米神定置の漁獲量が強い興奮性を表している。一方、他の漁場の漁獲量はあまり関係がないような結合を示した。例えば隣接するS5(石橋)では荷重はいずれの時期も1以下で、S3(岩)でも5月のみ1以

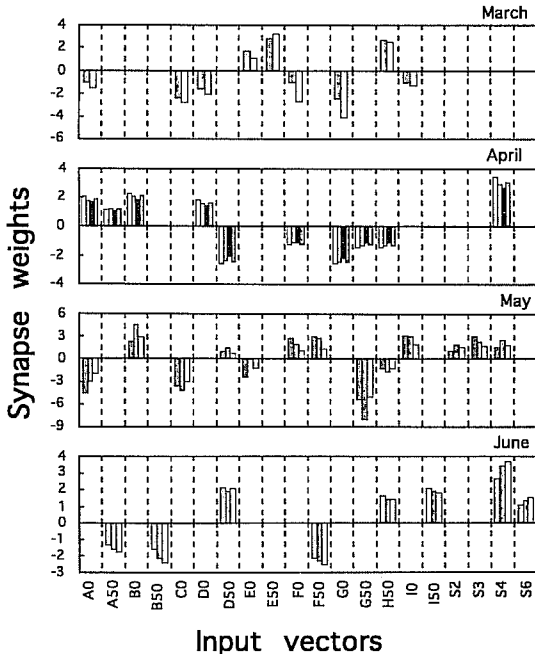


Fig. 6. The synapse weights of the connection from each input units to the active hidden units in the supervised learning in Case 1.

上になった。これから見ると、米神定置漁場のマアジ漁獲量を予測する上で、近隣の他の漁場のマアジ漁獲量は、漁期が進むといくらか役立つが、全体にはあまり情報にならないと考えられる。

海況に関するシナプス荷重の地域的な分布を見ると、4月の東高西低型を除き、3・5・6月は西高東低型として現れた(Fig. 7)。言い換えると3・5・6月の漁獲量はそれぞれの前月、すなわち2・4・5月の水温が平年値より湾の西側は高く東側が低くなるほど多くなると考えられる。

3・5・6月の予測における水温のシナプス荷重の分布は、米神定置のマアジ漁獲量は大島水道から暖水が流入する時には増加し、流入しないときには減少する可能性があるとした為石(1988)の結果と類似していた。

3.4 予測手法としてのニューラルネットワーク

今回使ったニューラルネットワークシミュレーターは学習データの最大値を1、最小値を0に基準化して入力層に入力される。従って予測に使う入力変数の値が学習値の最大値より大きい場合にはその結果をうまく表すことが難しくなる。従って、学習データとしてできるだけ極端な場合を含むようにデータセットを作




Fig. 7. Spatial patterns of synapse weights of temperature deviation vectors of the Case 1 in March, April, May and June. The dashed and dotted areas represent the excited connection and the inhibited connection, respectively. The synapse weights of temperature deviations represented oceanic conditions one month before the time of




Fig. 8. Relation between learning cycles and relative errors of forecasted outputs (Case 1 in April).

ることが望ましい。

もう一点として、ニューラルネットワークを構築し予測を行うときの最適な学習回数に留意する必要がある。

そこで、具体的な個々のネットワークによって最適学習回数は違うと思われるが、本研究で最もよい予測結果が得られた4月のケース1におけるマアジCPUEの予測時の学習回数に対する教師値と予測値との誤差を検討した (Fig. 8)。最初学習が始まる段階では相対誤差が0.7くらいであり、学習が進むと徐々

に誤差が小さくなり、1000回を越えると誤差が急激に減り、1700回くらいで最小になった。1700回以上学習させると3000回くらいまでは誤差が増加し、それ以上の学習ではさらに誤差が大きくなる傾向であった。これから考えられるのは学習回数が少なくても、多すぎても誤差は大きくなることである。

ただし、ここでは学習回数の効果を試すために回数を細かく分けて計算させたが、実用上は学習回数を1000回単位で3回ほどしてみると適当な学習回数を知ることができると考えられる。また、学習回数を増やす再学習の時にはそれまでの学習を継続して行うことができるので計算時間も節約でき、さらにデータを変更したりネットワークの構造を改造したりする必要はない。

4. 参考文献

- 岩田静夫・木幡 孜 (1987) 相模湾の海況と漁況. 水産海洋環境論 (杉本他編), 恒星社厚生閣, 91-106.
- 岸 道郎 (1981) 定置網漁獲量のGMDHによる定量的予測一定置水温から米神定置のマアジ漁獲量を予測する. 水産海洋研究, 38, 1-4.
- 木幡 孜 (1990) 回遊性浮魚魚類相による相模湾沿岸域の海域区分に関する研究. 神水試論文集, 4, 56pp.
- 為石日出生 (1988) 相模湾のマアジ漁況と海況. 水産海洋研究, 52, 319-323.