

II-94 ニューラルネットワークによる 干潟環境評価モデルに関する研究

松原雄平（鳥取大学工学部）・木村賢史（東京都環境科学研究所）
市村 康（日本ミクニヤ（株））・野田英明（鳥取大学工学部）
佐野史幸（鳥取大学大学院）

1. はじめに

東京湾では大規模開発にともなう埋立造成が進み、自然干潟は減少の一途をたどっている。現在、残された干潟としては小櫃川三角州前面の盤州干潟、江戸川（江戸川放水路）河口の三番瀬、旧江戸川河口の三角州に限られている。また東京湾に流入する河川流域でも河川改修や流路変更あるいは生活雑排水の流入など物理環境が大きく変化している。こうした河川および沿岸域での複合的な環境変化から湾内水の水質や物質循環系ならびに生態系も変化しつつある。一般に、このような環境要因の変化と水産動植物の生息環境を総合的に評価する方法としては重回帰分析や環境要因評価法など、いくつか提案されているがニューラルネットワークによる環境評価手法もその一つであろう。この評価手法は信頼しうる環境調査データが十分そろっていれば、環境要因と環境変化の関係を、迅速かつ定量的に関連づけることができるという利点を持つ。そこで本研究では、東京湾での環境調査データをもとにニューラルネットワークを用いた干潟環境評価モデルについて検討するものである。

2. 東京湾での干潟環境調査概要

東京都では、東京湾の水質、低質調査と生物調査を並行して行う水産生物調査を毎年的に実施してきており、貴重なデータが長年にわたって蓄積されている。図-1は調査地点を示したもので、東京都内湾、運河、河口、干潟の計16地点において、各種の調査が行われている。なお、平成元年度まで調査地点であった13号地の干潟は、臨海副都心建設工事に伴って消滅したため、これに代わり平成2年度から御台場海浜公園が調査地点になっている。

底生動物の採取は、最も出現種数が多いと考えられる5月と、夏期底層の低酸素化の影響で出現種数が減少する9月の2回実施されている。また以下のような項目が調査されている。

- 底生動物に関するデータ：種別固体数、種別湿重量
- 底質データ：COD、強熱減量、硫化物、銅、酸化還元電位、水分含有率、粒度組成、土粒子の比重
- 水質データ：透明度（干潟は透明度）、水色、水温、塩分、pH上・下層、DO上・下層、COD（上層）

3. ニューラルネットワークの構築の手順

ネットワークに入力する要因は前述の調査項目の固体数を除く26の調査項目（説明変数）とし、出力（目的変数）は固体数とした。ネットワークの精度の検定については、未学習データに対するネットワークの推定値と実測値との差で検証した。また使用したネットワークは階層型ネットワークであり、学習アルゴリズムはバックプロパゲーション法である。

ニューラルネットワークは同じ説明変数や目的変数を用いてもその学習環境、例えば中間層、細胞数、学習回数、学習パラメータを変化させることによって認識精度が良くも悪くもなる。一般に認識精度の良いネットワークを作るためにはなるべく単純なネットワークにすることや過度の学習回数を避ける方が良いとされている。そこで本研究では以下の手順によって最適なネットワークを作り出した。

- (1) 入力データを平成4年度分のデータ、教師データをそれ以外のデータとし、中間層、中間層細胞数をそれぞれ変えていくつものネットワークを作る。
- (2) 上で得られた各ネットワークのうち最も認識が

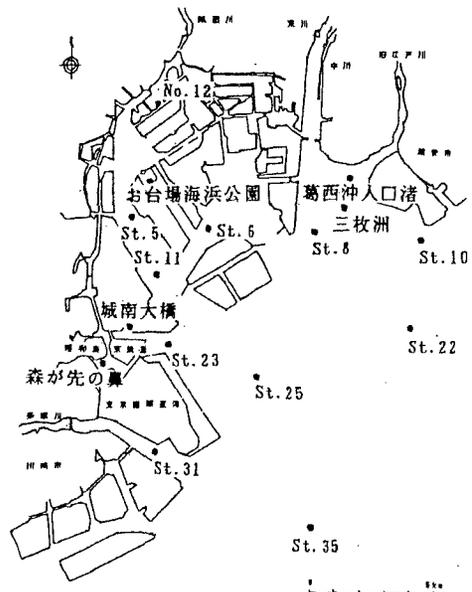


図-1 観測値点の位置

高いものについて、教師データを各年ごとに替えていき、いくつかのネットワークを作り検証する。

(3) 上のネットワークで最も認識率の高いものでネットワークの学習回数を変えた場合のネットワークを作り検証する。

4. ニューラルネットワークによる環境評価

1) 中間層、細胞数について

ネットワークの認識結果に及ぼす中間層、細胞数の影響を見るために階層型のネットワーク9種(3層モデル3種、4層モデル3種、5層モデル3種)のネットワークを構築した。各ネットワークの学習回数は5万回とした。まずもっとも層数の多い5層ネットワークでは、認識率がきわめて低かった。比較的高い認識率を示したのは4層モデルであった。その結果を図-2に示す。図の大部分の結果で実測個体数が認識結果よりも大きく現れた。そこで、この4層モデルで中間層を変えた場合の認識率の検証を行った。図-3は、その4層モデルの中でもっとも認識率が高くなった結果を示したもので、第2層の中間層細胞を24、第3層を8とした場合の結果である。これより、認識結果と観測結果には、若干ばらつきもあるが、ほぼ一定の対応関係が見られる。そこで、以下の認識率の検討ではこの4層モデルを採用することとした。

2) 学習回数の影響について

一番精度の高かったモデルの学習回数を5万回、10万回、15万回と変化させ、認識率の変化を調べた。5万回から学習回数を増やすにつれて、認識率が向上する傾向が認められたが、10万回以上になると有意な差は認められなかった。

3) 全観測点における年度毎の認識結果

図-4は、昭和61年から平成4年の期間に各観測点において調査されたデータを用いてニューラルネットワークで推定させた個体数と実測個体数の差を誤差として示したものである。この結果から、(1) 全体的傾向として昭和62年5月および63年5月は認識誤差が大きく、一方、昭和62年9月、平成1年5月、平成2年5月、平成3年5月では、比較的誤差

が小さいこと。(2) St.6, St.11, St.35, St.22などの個体数が小さい観測点については、認識誤差が小さい。しかし、三枚洲、城南大橋、葛西沖人工渚などの個体数の大きい箇所ではいずれも誤差が大きいこと。などがわかる。上記の認識誤差が大きい原因としては、ここで対象とした環境要因とは別の要因(たとえば人為的要因)によって個体数の変動が生じたことが考えられるが明確ではない。むしろ学習データとなる物理環境調査や生物調査が年2回と限られているため、干潟環境と個体数の間の因果関係の認識が出来ていないこともその要因であろう。

5. おわりに

本研究では、ニューラルネットワークを用いて干潟環境評価モデルの開発を試みたが、必ずしも十分な推定を行うまでには至らなかった。ここでは、個体数のみを認識項目としたが、干潟生物の生息環境という意味からは、種類数をも考慮した多様性指数等で評価すべきであろう。今後、さらに多くのデータを元に干潟環境評価について検討する予定である。

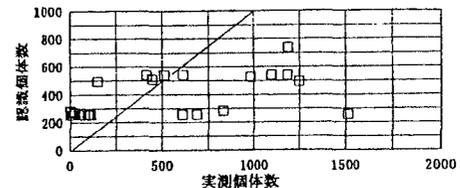


図-2 4層モデルの認識テスト

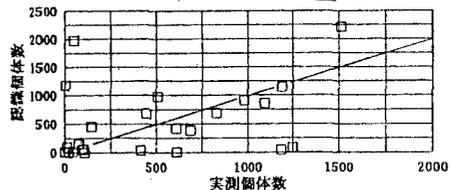


図-3 最終4層モデルの認識結果

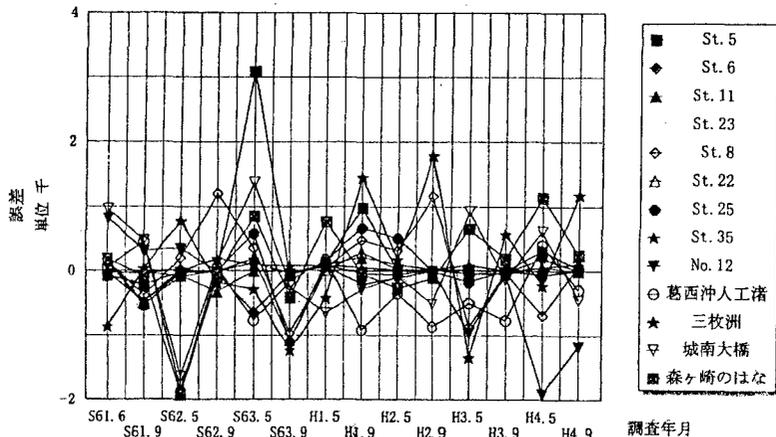


図-4 各観測点での認識誤差の変化