

GA・ニューラルネットワークによる水中分光反射率を用いた水中物質濃度の推定

外崎 道夫 雨森 道紘
弘前大学理学部情報科学科

あらまし 本研究の目的は、水中分光反射率による水中物質濃度の推定のために、ニューラルネットワークによる水質推定モデルを作成することである。このとき推定に有効な波長帯を決めるのに遺伝的アルゴリズム (GA) を用いる。対象水域を懸濁物質量や溶存有機物量の多い茨城県霞ヶ浦に選び、構成したニューラルネットワーク推定モデルにより良い水質推定結果を得ることができた。このような場所は従来のモデルではクロロフィル a (chl.a) 濃度の推定が困難であった^{[1][2]}。さらに、この水質推定モデルをリモートセンシング画像に適用を試みた。

1. はじめに

近年、湖沼などでの悪臭に対して、アオコの発生予測などの対策が急務である。このためには、プランクトンに含まれるクロロフィルの分布を計測し、その現状を正確に把握することが必要である。そのために近年、広い範囲を定期的に観測できる人工衛星を利用したリモートセンシング手法の活用が、水質分布の計測が試みられるようになってきている。

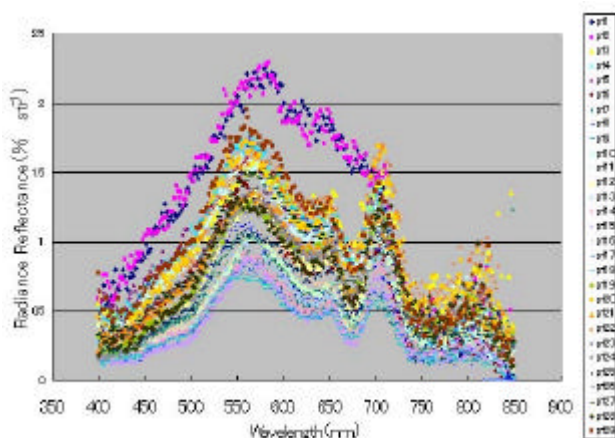
2. 研究の目的

本研究では、水面反射光と大気の影響を無視できる水中で測定されたスペクトルデータをもとに、ニューラルネットワークによる chl.a と SS の推定モデルの作成を行った。対象水域は茨城県霞ヶ浦であり、ここは従来のモデルでは chl.a 濃度の推定が困難であった懸濁物質量や溶存有機物量の多い地域である。このモデルは将来のリモートセンシングによる chl.a や SS (Suspended Solids) の定量を試みるための基礎的知見を得るために有効である。

3. ニューラルネットワーク推定モデル

3.1 使用データについて

今回使用したデータは、国立環境研究所の提供による茨城県霞ヶ浦において日時や場所の異なる 29 地点での水中分光反射率のデータと同じ地点で測定された chl.a と SS の濃度データである。



水中における分光反射率 R は、水中から水面に出てくる光の分光放射輝度 I_w および水面に入射する太陽の分光反射照度を用いて、

$$R_w = \frac{I_w}{E_a} \quad (3.1)$$

として与えられる。

3.2 ネットワークの構造と学習方法

水中物質濃度の推定モデルのために使用するニューラルネットワークは、階層型ニューラルネットワークで、学習法としては BP 法を用い、学習は、水中分光反射率を入力とし、chl.a と SS の濃度を出力として行う。

ネットワークの構造としては、入力層のユニット数 10 個と出力層のユニット数 2 個を固定し、中間層はユニット数を 1 ~ 40 個まで変化させてその最適のユニット数を決める。学習評価の指標として、平均二乗誤差を用い、学習回数を 100 万回とする。また学習を高速化する手段として、Momentum 法、学習率更新法 (delta-bar-delta) や Jacob's hybrid 法^[4]などを行い、その中から最適な方法を選ぶ。

Chl.a の吸収帯 1 は 420 ~ 460nm、吸収帯 2 は 650 ~ 690nm、SS の推定に有効な波長帯 700 ~ 760nm である^[5]。

3.3 様々な学習法と最適な学習法での推定誤差

それぞれの推定に有効な波長帯を適宜に選んで学習した後、最適な学習法として momentum 法が示された。これにより求められた推定結果を以下に示す。

the chosen wavelength(nm)				
442	446	450	672	676
680	700	710	720	730

	chl.a	ss
average estimation error to the learning data (%)	6.28	16.67
average estimation error to the non learning data (%)	26.64	37.13

4. GA による最適波長の選択

より誤差を縮小する最適の波長帯を GA によって求める。

4.1 遺伝子の設定

GA の仮想生物個体には、ある長さをもつ遺伝子に 400 nm ~ 840 nm (2 nm 間隔) の波長帯の値を持たせ、初期生物個体の遺伝子の値は、ランダムに選択される。

4.2 適応度評価の設定

それぞれの個体は、その遺伝子 (波長帯) の水中分光反射率を入力データとして使い、ニューラルネットワークで水中物質濃度を推定するように学習する。その後、そのネットワークを用いて、その遺伝子の未学習データと既学習データの水中分光反射率から水中物質濃度の推定を行う。それぞれの個体の適応度は、(1) 学習データに対する推定誤差、(2) 未学習データに対する推定誤差、の 2 つの点を考慮して定める。遺伝規則としては、淘汰、セミエリートおよび新種の発生、交差、突然変異の 4 つの遺伝規則に従って世代交代を行う。

- 入力層のユニット数 (遺伝子長) 5,10 個
- 中間層のユニット数 10 個
- 出力層のユニット数 2 個
- 学習方法 BP + momentum 法
- 学習回数 100 万回

以上の条件で GA によるニューラルネットワーク水質推定モデルでの最適な波長帯の探索を行った。その結果、100 回の GA による探索により最適な条件として、(1) 遺伝子長は 5 の場合であり、(2) 適用度と波長帯は以下に示す値である。

fitness	0.893
selected wavelength(nm)	676,716,726,760,814

また、この波長帯を用いたときの推定の平均誤差と未知データとの推定の平均誤差を以下に示す。

	chl.a	ss
average estimation error to the learning data (%)	5.67	8.52
average estimation error to the non learning data (%)	12.2	16.31

4.3 従来のモデルとの比較

このニューラルネットワーク水質推定モデルと従来のモデルとの比較を行った。比較対象としては、(1) 沖^[4]の 2 波長の比を用いた chl.a 濃度推定モデルとの比較と、(2) SS 濃度推定においては 760nm の反射率を用いてモデル構築を行ない比較結果を以下に示す。

	NN	single regression
average estimation error to the learning data (%)	5.67	17.3
average estimation error to the non learning data (%)	12.2	19.7

	NN	single regression
average estimation error to the learning data (%)	8.52	21.1
average estimation error to the non learning data (%)	16.31	33.9

この結果から SS 等では特に従来のモデルよりも推定精度が良いことが言える。また、沖の chl.a 推定モデルでは、chl.a

濃度は SS 濃度に依存することが示されており、複雑な条件を組み合わせた線形推定モデルを考えなければならない。一方、ニューラルネットワークによる水質推定モデルでは、そのような事を考慮せずとも精度の高い推定が可能である。

5. リモートセンシング画像への応用

5.1 CASI 画像

使用した画像データは水質データと同期して同地点を観測されたものを用いた。画像データは 410.74 ~ 957.79nm の波長帯を 96 バンドに区切った航空機によって観測された CASI 画像である。

5.2 画像の前処理

CASI 画像は分光放射輝度によって表されているので、それを、高島^[5]らの方法により水中分光反射率に変換して用いた。

水質データを採取した地点の水中分光反射率を CASI 画像から採取し、それを入力データとしてニューラルネットワークに学習させ、推定を行った。ニューラルネットワークの構造は、4.2 と同一である。以下に学習データに対する平均推定誤差を示す。

	chl.a	ss
average estimation error to the learning data (%)	8.07	11.02

6. 結論

本研究によって水中分光反射率を用いたニューラルネットワークによる水中物質濃度の推定モデルを開発することができた。これは従来のモデルでは推定が困難であった chl.a 量、懸濁物質量そして溶存有機物の多い湖沼でも水質推定ができることを示したものである。また、このモデルは従来の線形推定モデルよりも若干推定精度が良いことが示され、さらには、リモートセンシング画像での水質推定分布を作成することが可能であることを示した。

参考文献

- [1] 水尾寛己：クロロフィルのリモートセンシング，日本リモートセンシング学会，環境とリモートセンシング（第 1 回），53-58，1993.
- [2] 沖一雄，島田道彦，宮武直樹，押尾健一，安岡義文：分光スペクトル計測に基づく水質定量モデルの検証(2) 第 33 回計測自動制御学会学術講演会予稿集，569-570，1982.
- [3] Robert A. Jacobs: "Increased Rates of Convergence Through Learning Rate Adaptation", Neural Networks, Vol.1, pp. 295-307, 1988.
- [4] 沖一雄，安岡義文：高濃度水域における近赤外波長帯を含む二波長によるクロロフィル a 推定モデルの作成、リモートセンシング学会誌 Vol.16, No. 4, 1996, pp.1-9
- [5] 高島勉，増田一彦：多重散乱、海面による乱反射・乱屈折を考慮した大気 海洋系上端からの放射計算アルゴリズム、リモートセンシング学会誌、vol.6, 5-35,1986.