

京都大学大学院 学生員 ○大久保 豪
 京都大学防災研究所 正会員 岡 太郎・石井 将幸
 京都大学工学部 学生員 鈴木 秀樹

1. はじめに

バングラデシュ国では洪水災害が頻発し、同国の発展に大きな支障をきたしている。特に北東部は、世界的に見ても最も雨量の多い地域の一つであり、この国における洪水対策として流出解析を行うには、この地域の雨量分布を明らかにすることがきわめて重要である。

本研究では、バングラデシュ北東部の雨量を GMS 赤外画像を用いて推定することを目的とする。GMS 赤外画像はパソコンで受信される低解像度のものを使用し、ニューラルネットワークを用いて雲頂温度から雨量を推定する手法を検討する。

2. 解析に用いた GMS 赤外画像

これまで、衛星画像による降雨量推定は数多くなされてきたが、それらの多くは衛星からの直接受信による高解像度の画像を用いている。しかし、高解像度の画像を用いることは、高性能の受信設備や計算機を必要とするためあまり身近なものとは言えない。本研究では、パソコンで受信可能な低解像度の GMS 赤外画像を使用する(図1)。この画像では、雲頂温度が16階調で表示され、白いピクセルほど雲頂温度が低くなっている。対象とする地域は東経 92°, 北緯 25° 付近で、この地域での1ピクセルは縦約 10.0km, 横約 15.3km に相当する。なお本研究では、1995 年 5 月 5 日から 6 月 24 日までの画像を用いている。

3. 雲頂温度と雨量の関係

雲頂温度は雲頂の高さとはほぼ直接的に対応し、雨量とも関係が深いと考えられる。そこで、対象とする地点を含む1ピクセルの雲頂温度から、雨量を直接推定しようと試みた。図2は、インドとの国境に近い Jaflang における、地上観測雨量と雲頂温度の関係を表している。雲頂温度が低くなるほど雨量は多くなっているが、雲頂温度が低い時に降雨がない場合もあるため、1ピクセルのみの雲頂温度から雨量を推定することは困難であることがわかる。




図1 GMS 画像の一例 (1995 年 5 月 5 日 9 時 JST)




図2 1ピクセルの雲頂温度と雨量の関係

4. ニューラルネットワークを用いた雨量の推定

4.1 perceptron 型ニューラルネットワーク

このような経緯により、対象地点を含むピクセルを中心とした、3×3の計9ピクセルの雲頂温度から、perceptron 型ニューラルネットワークを用いて雨量を推定する。perceptron 型ニューラルネットワークの要件¹⁾を以下に記す。

- 複数の層からなる階層的なもので、層内の結合はない。
- 各層間の結合は、入力層から出力層へ方向のみである。
- 入力層以外の層に属するユニットは、前層のユニットの出力に結合値を乗じて総和をとった値を入力とし、それをある関数で処理した値を出力する。

今回用いたニューラルネットワークは、第1層9ユニット、第2層4ユニット、第3層1ユニットの3層ネットワークである。第1層の各ユニットはGMS画像の9つのピクセルに対応し、それぞれの雲頂温度を入力とする。そして第2層を経て求められる第3層のユニットの出力値を、後に述べるような推定結果として解釈する。

ネットワークの学習法として、誤差逆伝播法を用いた。この方法では、最終層の出力値と理想値の差の2乗和を、ネットワークの評価関数として採用する。そして理想値に近い出力を与えるネットワークを求めるために、最急降下法を用いて結合値を変化させ、評価関数の値を小さくする。

これは広く用いられている手法であるが、学習前に与える初期結合値がネットワークに大きな影響を持つという、最急降下法に起因する欠点を有している。初期結合値は乱数に基づいて与えることが多いが、その値が適切でない場合には、学習を繰り返しても推定精度が向上しない。そのため本研究では、異なる初期結合値に基づくネットワークを数多く構築し、その中で最も推定精度の高いものを採用している。

4.2 降雨の有無の推定

上で述べたニューラルネットワークを用いて、降雨の有無を推定する試みを行った。1995年5月5日から6月18日までにおける3時間ごとの雲頂温度と、Jadlangで観測された3時間雨量に基づき、雲頂温度分布と降雨の有無との関係を学習させた。続いて、学習に用いなかった6月19日以降の雲頂温度から、得られたネットワークに降雨の有無を想起させた。その結果を表1に示す。

降雨のある場合において的中したのは27例中24例で、的中率は89%である。降雨のない場合では、29例中22例、76%の的中率となった。全体で82%の的中率が得られるニューラルネットワークは、この地域における降雨の有無の推定に適していると言える。

4.3 雨量の推定

次に、雨量の定量的な推定をネットワークを用いて行った。先ほどのデータから降雨のある101例を

表1 降雨の有無の推定結果

観測雨量	推定雨量			
		有	無	合計
	有	24	3	27
	無	7	22	29
	合計	31	25	56




図3 推定雨量と観測雨量

抽出し、その中の80例を学習に、残りを想起による検証に用いた。図3は、想起された雨量と観測雨量の関係を表している。

全体的には良く再現できていると思われるが、降雨量が2.5mmに対し推定雨量が46.4mm、降雨量が26.5mmに対し推定雨量が3.5mmなど明らかに誤っているものもあり、改善の余地が残っている。

5. おわりに

ニューラルネットワークを用いて、低分解能のGMS赤外画像から雨量を推定する手法について述べた。降雨の有無については比較的良い結果が得られているが、推定に用いるピクセル数を増やし、さらに雲頂温度の時間変化を考慮することによって、より精度を向上させることができると考えている。一方、雨量の推定については誤差が大きく、さらなる改善が必要である。また初期結合値に依存せず、確実に推定精度の高いネットワークが得られる学習方法の採用も、今後の課題であると言える。

参考文献

- 1) 麻生英樹：ニューラルネットワーク情報処理、産業図書、(1988)