

ニューラルネットワークと衛星画像による バングラデシュ北東部の雨量推定

ESTIMATION OF RAINFALL INTENSITY IN NORTH EASTERN BANGLADESH USING ARTIFICIAL NEURAL NETWORKS AND GMS IMAGES

石井将幸¹・岡 太郎²

¹ 正会員 農博 島根大学講師 生物資源科学部 (〒690-8504 松江市西川津町1060)

² フェロー 農博 京都大学教授 防災研究所 (〒611-0011 京都府宇治市五ヶ庄)

This paper describes the method and the result of estimation of rainfall intensity in north eastern Bangladesh using artificial neural networks and GMS images. Based on the observed intensity of rainfall and the temperature of the top of cloud recorded in GMS images, artificial networks are trained. With trained networks, the rainfall intensity is estimated in good accuracy for the data used for the trainings. However, the accuracy is not so good in the estimations for the data not used for trainings.

Key Words : Rainfall estimation, GMS image, Artificial neural networks, Bangladesh

1. はじめに

流出解析を行うためには、その手法に応じた様々なデータが必要となる。その中でも降雨量は、全ての手法において不可欠であり、最も重要な資料の一つである。しかし現実には、降雨観測網が整備されておらず、十分な観測資料のない地域を対象として流出解析を行う場合も少なくない。バングラデシュでは現在、詳細な資料が不足しているために、精度の高い解析を行えない状況にある。

そのような地域に対して雨量を観測、推定する際には、人工衛星や航空機を用いたりリモートセンシングが有効である。特に人工衛星から得られる資料は地球の広い範囲をカバーしており、比較的安価な機材で受信できるものもある。

そこで本研究ではニューラルネットワークを用いて、気象衛星ひまわりが撮影した赤外画像から、バングラデシュ東北部における雨量の推定を試みる。まず、対象地点周囲のピクセルにおける雲頂温度から降雨の有無を推定し、ネットワークの学習に用いたデータに対する推定精度と、学習に用いなかったデータに対する想起精度について議論する。次にその発展形として、降雨量を指数分布に当てはめてランク分けし、どのランクに属する雨量となっているかを推定する。そしてランク的中率と、推定雨量の精度について考える。最後に、降雨がある場合のデータのみを対象として、ネットワークの出力値と降雨量の対応関係を定めて降雨量を直接推定し、その精度について検討する。

2. 対象地区と使用した衛星画像の概要

(1) 対象地区の概要

今回対象としたのは、Fig.1に示すバングラデシュ国のジャフロンである。インドとの国境近く、北緯 $25^{\circ}10'$ 、東経 $92^{\circ}03'$ に位置している。北側には山地が控えており、南から吹きこむ風によって大量の降雨が発生する。




Fig. 1 対象地区の位置

(2) 用いた衛星画像

今回使用した衛星画像の例をFig.2に示す。現地での使用を考え、安価な機材で受信が可能な低解像度の画像を用いることとした。この画像では、各ピクセルの




Fig. 2 使用した衛星画像

位置における雲頂温度が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。対象とする地域付近では、1ピクセルは縦約10.0km、横約15.3kmに相当する。

図に示すように、画像中には緯線と経線が描き込まれている。対象地区に対応するピクセルは、これらの線を基準にして判断した。本研究では、緯線・経線と推定に必要なピクセルは重ならなかったが、重なってしまう場合には別の種類の画像を用いる必要がある。

3. 降雨有無の推定

(1) 1ピクセルの雲頂温度と降雨量の関係

雲頂温度は雲頂の高さに対応し、降雨とも関連があると考えられる。そこで、対象とする地点を含む1ピクセルの雲頂温度と、雨量との関係を調べた。ジャフロンにおける雲頂温度と時間雨量の関係を、Fig.3に表す。明瞭な対応関係を見出すことは難しく、1ピクセルのみの雲頂温度からの推定は、かなり困難であると言える。

時間雨量との対応が悪くても、1ピクセルの長期間にわたる雲頂温度と長期間雨量が、良い対応関係となる




Fig. 3 雲頂温度と降水量の関係

ことも考えられる。しかし本研究の雨量推定は、流出解析や洪水解析への適用を目的としているため、時間雨量のような短時間降雨の推定を行わなければならない。

そこで対象地点を含むピクセルを中心とした、3×3の計9ピクセルと、5×5の計25ピクセルの雲頂温度に基づき、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こととした。さらに、9ピクセルの場合に対しては、当該時刻、3時間前、6時間前の3枚の画像を用い、合計27ピクセルによる推定も実施する。

(2) 用いたネットワークと入力値

推定に用いるニューラルネットワークとして、Fig.4に示すような3層のPerceptron型ネットワークを採用した。フィードバック結合を持たないPerceptronは、様々な問題の推定やパターン認識に広く用いられている¹⁾。




Fig. 4 ニューラルネットワークの形状

本研究では、入力層、隠れ層、出力層の3層からなるPerceptronを用いた。入力層のユニット数は雨量推定に用いるピクセル数と等しいものとし、一つ一つのユニットを一つ一つのピクセルに対応させた。雲頂温度 T が0から15までで表されることから、ユニットへの入力値 I については

$$I = \frac{T}{7.5} - 1 \quad (1)$$

という変換を行ない、 $-1 \leq I \leq 1$ となるように定めた。これは、次に述べるユニット入出力関数の値域に、入力の定義域を合わせるためである。隠れ層のユニット数は4とした。

ニューラルネットワークに用いられるユニット入出力関数には様々なものがあるが、本研究では次式に示すHyperbolic tangentを用いた²⁾。

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

-1 と 1 を極値とするこの関数では、 0 と 1 を極値とする一般的な入出力関数よりも学習効率が低い。

(3) 学習と想起

Perceptronに用いる学習アルゴリズムとしては、誤差逆伝播法が広く利用されている。ネットワークの出

力値と理想値との誤差の二乗和を評価関数とし、最急降下法で結合重みを変化させ、誤差の最小化を行って出力を理想値に近づける。

学習に先立って結合重みの初期値を与える必要があるが、その決定には乱数が用いられることが多い。最急降下法は局所解に陥りやすく、パラメータの初期値に解が依存するという欠点を持つため、誤差逆伝播法でも初期結合値を定める乱数が推定結果に影響を与える。

学習を繰り返し行うことによって、学習に用いたデータに対するニューラルネットワークの推定精度は向上する。しかし、実用を目的とした推定では、学習に用いたデータ以外についても高精度の推定が可能でなければならない。学習に用いなかったデータについて推定させ、その精度を検証する手法は想起と呼ばれており、ニューラルネットワークによる推定手法の検討には欠かせない手順である。

本研究で学習に用いたデータは、1995年5月5日から6月17日までの3時間ごとの雲頂温度と、ジャフロンでその時刻に観測された時間雨量である。また、想起には同年6月18日から24日までのデータを用いた。

(4) 乱数の影響の除去

先に述べたように、誤差逆伝播法によるネットワークの学習では、初期結合重みを決定する乱数が学習結果に大きな影響を及ぼす。推定手法の優劣を議論するためには、乱数が推定精度に与える影響をできるだけ除去しなければならない。そこで、異なる乱数の底に基づくネットワークを2,000個作成し、それらの推定誤差の平均値を用いて精度を評価することとした。

(5) 学習結果と想起精度

Table 1は、学習を行った後における降雨有無の推定結果と、学習に用いなかったデータに対する想起の結果を示している。

学習用データに対する結果より、3つの手法によって非常に高い精度が得られていることがわかる。観測降雨のある場合よりも、降雨のない場合の推定精度が高くなっているが、これはデータ件数の違いを反映していると考えられる。また、25ピクセルと27ピクセルによる精度はほぼ同程度であるが、9ピクセルのものは若干劣っている。これらより、学習に用いたデータに関しては、ニューラルネットワークで雲頂温度と降雨有無の関係を見出すことが可能であり、9ピクセル程度の情報量からでもかなりの精度が得られると言える。

一方、想起の精度については、学習に用いたデータに対する推定精度よりかなり低い結果となっており、ピクセル数による精度の差に特別な傾向はみられない。特に、降雨がある場合についての精度が低くなっている。

Table 1 降雨有無の推定結果

(a) 9ピクセルからの推定結果

		推定 降雨有	推定 降雨無	的中率
学習用 データ	観測降雨有	68	7	91%
	観測降雨無	5	226	98%
想起用 データ	観測降雨有	8	17	32%
	観測降雨無	2	27	93%

(b) 25ピクセルからの推定結果

		推定 降雨有	推定 降雨無	的中率
学習用 データ	観測降雨有	72	3	96%
	観測降雨無	1	230	100%
想起用 データ	観測降雨有	9	16	36%
	観測降雨無	2	27	93%

(c) 27ピクセルからの推定結果

		推定 降雨有	推定 降雨無	的中率
学習用 データ	観測降雨有	67	4	94%
	観測降雨無	0	207	100%
想起用 データ	観測降雨有	5	19	21%
	観測降雨無	0	28	100%

想起精度が低い理由としては、学習に用いるデータ、特に降雨がある場合のデータが少なく、複雑な降雨現象のごく一面に対する学習しか行われていない、という点が挙げられる。これについては、データをさらに収集し、より多くの状況に対する学習と想起を行って、今後さらに検討したいと考えている。

4. ランク分けを用いた降雨量推定

(1) ランク分けを用いた推定

推定結果を流出解析などに利用するためには、降雨の有無のみではなく、降雨量を推定することが必要となる。そこで降雨量をいくつかのランクに分け、どのランクに該当する降雨が生じているかを推定して、降雨量を間接的に推定する手法について検討する。

(2) 指数分布を用いたランク分け

学習と想起に用いている全ての雨量データを指数分布にあてはめ、0を除いた雨量に対して生起確率が等しくなるようにランク分けを行なった。例えば6分割の場合では、Table 2に示すようなランク分けとなる。

ニューラルネットワークの出力層には、各ランクに対応する節点を配置した。6分割の場合には、ランク0のものを加えた7つの節点が配置される。ネットワーク

Table 2 6分割における時間雨量 $R[\text{mm}]$ のランク分け

ランク	時間雨量の範囲	ランク	時間雨量の範囲
ランク0	0	ランク1	$0 < R \leq 1.3$
ランク2	$1.3 < R \leq 2.8$	ランク3	$2.8 < R \leq 4.8$
ランク4	$4.8 < R \leq 7.6$	ランク5	$7.6 < R \leq 12.5$
ランク6	$12.5 < R$		

の理想出力値は、観測雨量が該当するランクの節点で1、その他全て節点で-1となるように定めた。

(3) ランク推定の結果

分割数を6から16まで変化させ、それぞれについて乱数の底を変えた2,000個のネットワークを作成した。Fig.5は、分割数と推定精度の関係を示している。90%前後で推移しているのが学習用データに対する精度、50%前後のものが想起精度である。

降雨有無の推定と同様に、9ピクセルからの推定による精度が最も低くなった。また、分割数が増えるにつれて推定が困難になると予想されたが、大きな精度低下は生じていない。25ピクセルと27ピクセルによる推定では、6分割の推定精度が最高となったが、9ピクセルの場合は12分割で最高の的中率となっている。

想起精度については、降雨有無推定の場合と同様、低い精度にとどまっている。分割数が多くなると的中率が低下する傾向がみられるが、学習用データに対する推定と同様、低下の度合いはかなり小さい。




Fig. 5 ランク推定の的中率

(4) 降雨量の推定精度

続いて、この手法による降雨量の推定精度について調べる。降雨量の推定値としては、推定結果がランク0の場合は0を、その他のランクについては各ランクの期待値を採用した。

推定精度の指標としては、次式に示す平均誤差 E_m を用いる。 N はデータの件数、 R_e と R_o はそれぞれ降雨

量の推定値と実測値である。

$$E_m = \frac{1}{N} \sum |R_e - R_o| \tag{3}$$

また長期流出解析など、ある期間の総雨量が精度良く予測できれば十分な場合もあるため、

$$E_r = \frac{\sum R_e}{\sum R_o} \tag{4}$$

で表される推定雨量比 E_r についても検討する。

平均誤差の値を Fig.6に示した。1mm 前後のものが学習用データに対する値、3mm を越えているものが想起における誤差である。

学習用データにおける誤差は9ピクセルによるものが最も大きい、他の2手法との差は小さくなっている。分割数による大きな精度差は見られないが、9と25ピクセルからの推定では16分割、27ピクセルの場合では10分割の場合が最良となった。ランクの的中率では、分割数が少ない方が精度が高いという傾向があったが、雨量の推定では逆の結果となっている。雨量の推定を視野に入れてランク推定を行う際には、分割数のある程度大きくすることが有効であると考えられる。

また分割数によっては、25ピクセルと27ピクセルの間の精度差が、9と25の差と同程度に開いている。推定に用いているパラメータ数はほとんど変わらないことから、精度の差は推定に用いたパラメータの良否を反映していると考えられる。したがって、広範囲の雲頂温度よりも、対象地点周囲における雲頂温度の時間変化を根拠とした方が、高精度の推定を行えるものと期待される。





Fig. 6 推定雨量の平均誤差

想起については、ピクセル数ごとの有意な精度差はみられなく、また分割数を多くするほど精度が低下する結果となった。ランク推定の的中率を、そのまま反映していると考えられる。

次に、推定雨量比と分割数の関係を Fig.7に示す。0.7 前後のものが学習用データに対する結果、0.2 前後のものが想起用データについて得られた結果である。



+ : 9ピクセル x : 25ピクセル o : 27ピクセル

Fig. 7 推定雨量比

学習用、想起用の両方で推定雨量比が1.0を下回っており、観測雨量よりも少ない雨量が推定されている。これは、降雨のない場合のデータ数が、ある場合のデータ数を大幅に上回っており、降雨のない場合を中心に学習が行われていることが原因であると考えられる。

学習用データについては、概して分割数が増えるほど精度が向上するという結果が得られた。9ピクセルによる精度が最も劣る点是不変だが、25と27ピクセルの優劣は分割数によって逆転している。25と27ピクセルによる推定の精度は12分割のときに最高となったが、9ピクセルによる精度は逆に最低となった。

想起用データに対する推定雨量は、観測雨量の1/3にも満たない。とくに9ピクセルからの推定では、1/5以下という結果となった。想起用データの中に時間雨量68.5mmというものがあるが、これに対して低いランクが推定されていることが原因の一つとして挙げられる。しかし、それ以外の多くの想起用データに対しても、過少の雨量が推定されてしまっている。

5. 降雨量の直接推定

(1) 降雨がある場合のみを対象とした推定

ランク分けを用いた降雨量の推定では、想起において観測雨量よりもはるかに少ない推定結果となった。先ほど述べたように、データの多くが時間雨量0mmの場合のものであり、学習が無降雨状態を中心に行われていることが原因の一つとして挙げられる。

降雨の推定では、降雨有無の予測と降雨量の予測を分離した方が高い精度が得られる、という報告がある³⁾。そこで、降雨有無については十分な推定精度が得られたものと考え、降雨がある場合のデータのみを対象とし、降雨量の具体的な推定を行った。

(2) 出力値と降雨量の対応

降雨有無の推定に用いたデータ組の中から、降雨がある場合のものを選び出して学習と想起に用いた。デー

タ数は、9ピクセルと25ピクセルからの推定では100件であり、75件を学習に、25件を想起に用いた。27ピクセルからの推定では、95件のデータのうち71件を用いて学習を行い、残る24件で想起を行った。降雨有無の推定と同様に、異なる乱数の底に基づくネットワークを2,000個作成した。

本研究で用いたユニット入出力関数の値域は-1から1であるため、出力値と雨量の対応関係を定める必要がある。そこで出力値-1を降雨量0、出力値1を R_{MAX} と対応させるために、次式で表す関係を用いた。 R_e は降雨量の推定値、 O はネットワークの出力値である。

$$R_e = \frac{2O}{R_{MAX}} - 1 \quad (5)$$

この手法では、 R_{MAX} を越える雨量は推定されないため、その値を慎重に定める必要がある。本研究では、データ中で最大の時間雨量である68.5mmを用いた。

(3) 降雨量の推定結果

Fig.8は、学習終了時における推定の結果を示している。図の横軸は実測値、縦軸はそれぞれのデータ組に対する推定結果2,000個の平均値である。

学習に用いたデータについては、9ピクセルによる精度はさほど高くないものの、推定に用いるピクセル数が増えるにつれて精度が向上している。25、27ピクセルを用いた推定では、降雨量が大きい場合において特に高精度となった。洪水解析を行うためには、豪雨時における雨量を正確に推定する必要があるが、その目的に合った結果となっている。

各手法による平均誤差と推定雨量比をTable 3に示した。ランク分けによる結果と比べると、学習、想起の両方で平均誤差は増えているものの、推定雨量比が大きく改善されている。ランク分けによる推定では、雨量が0であるランク0に対する的中率が非常に高く、またランクが的中すれば推定雨量は観測雨量に一致していた。直接雨量推定で平均誤差が大きくなった理由としては、ランク分けによる推定精度の高い無降雨のケースが、推定の対象から外れていることが挙げられる。

また、ランク分けによる推定では、ほとんどの場合において過少の推定が行われていた。一方直接推定では、正確な推定の他に、過大な推定と過少な推定の両方が生じている。そのため、平均誤差が大きいのに関わらず、推定雨量比が1に近づいているものと考えられる。

精度は大幅に劣るが、想起においても同じ傾向となった。しかし、ランク分け推定よりも大きく改善されているものの、推定雨量比は0.5に達していない。降雨有無の推定時よりもさらにデータが少ないため、データ数を大幅に増やしたうえで、さらなる検討と改善が必要であると考えている。

Table 3 雨量の直接推定による精度

	ピクセル数	9	25	27
学習用データ	平均誤差 [mm/h]	2.96	1.61	1.33
	推定雨量比	0.90	0.95	0.99
想起用データ	平均誤差 [mm/h]	6.84	7.36	7.16
	推定雨量比	0.30	0.45	0.49

6. 結論


Perceptron 型ニューラルネットワークを用いて、GMS 画像による雲頂温度から降雨量を推定した。その結果、学習に用いたデータに対しては、高い精度で推定を行うことができた。得られた成果は以下のとおりである。

- バングラデシュ北東部のジャフロンを対象として、雲頂温度分布から降雨の状態をニューラルネットワークで推定した。対象地点を中心とした3×3の9ピクセル、5×5の25ピクセルによる推定の他に、時間的に連続した3枚の画像から9ピクセルずつを用いる、合計27ピクセルに基づく推定を行った。
- 降雨の有無について推定を行ったところ、3手法の全てで非常に高い精度の推定を行うことができた。しかし、学習に用いなかったデータを対象とした想起では、推定精度は低いものとなった。
- 時間雨量の実測値を指数分布に当てはめ、生起確率が等しくなるように降雨量をランク分けした。そして、降雨量がどのランクに該当するかを推定したところ、ランクの分割数によらず、ほぼ等しい的中率となった。
- 各ランクの期待値を推定雨量と定め、観測雨量との誤差を調べた。観測値と比べてかなり少ない雨量が推定されており、特に想起において顕著であった。
- ネットワークの出力値と推定雨量との関係を定め、降雨がある場合のみを対象として雨量を直接推定した。その結果、ランク分けによる雨量推定と比較して、観測値にかなり近い累計雨量が推定された。
- 学習と想起に用いたデータの数が少なく、推定の精度と妥当性について十分な考察を行うことができなかった。さらにデータを収集し、手法の能力と限界についてより深く検討したい。


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。
2) 長谷川高士・工藤庸介・石井将幸：ニューラルネットワークを用いたコンクリートダム景観の定量的評価，農土論集，No.179，pp.31-37，1995。
3) 小田二郎・端野道夫・國方美規義：GMSデータを用いた降雨予測と洪水調節ダムの予備放流操作への適用，水文・水資源学会誌，Vol.9，No.1，pp.57-67，1996。


(1999.9.30受付)



○：学習用データ ×：想起用データ
(a) 9ピクセルからの推定



○：学習用データ ×：想起用データ
(b) 25ピクセルからの推定



○：学習用データ ×：想起用データ
(c) 27ピクセルからの推定

Fig. 8 降雨量の推定結果