

ニューラルネットワークによる
GMSデータを用いた降雨域の推定
Rainfall Estimation from GMS Imagery Data Using Neural Networks

井形 淳*・藤間 聰**
By Sunao IGATA and Satoshi TOHMA

The forecasting approaches based on Remote-Sensing techniques have been developed. But there are difficulties in these approaches because of computational performance which is calculated in time and capacity of computer. This work is the method of forecasting the variation of clouds with Neural Network. Neural Network is defined as that application of the model of brain and neuron systems to engineering and is useful to analyze the infrared and visible images of GMS. Many characteristics of GMS images such as ground data, temperature and wind are stored in a Neural Network for forecasting rainfall. The range of imagery data was revealed through the comparison between infrared and visible imagery data to estimate rainfall.

Keywords: GMS, Infrared and Visible cloud images, Neural Network

1. はじめに

本研究では陸上、海上を問わず一様な精度でデータが得られるリモートセンシングの利点を生かし、気象衛星ひまわりのデータを用いた降雨予測を行った。この手法では、降雨域の推定及び降水雲の時間変化の予測を目的としている。まず、寒冷前線通過に伴う積乱雲の発達に着目し、室蘭工業大学地域共同研究開発センターで受信した可視画像、赤外画像の2種類のひまわり雲画像を用いて降雨域を推定した。これらの中規模気象現象の予測には膨大な量の情報を処理する必要があり、スーパーコンピュータのような大容量の計算機を用いなければ、予測計算の実行は一般に不可能である。そこで、各種気象データを用いて予測計算をするのではなく、衛星雲画像から雲の変化パターンを学習する方法を考えた。このパターンの学習には生物の脳神経系の仕組みを工学的に応用したニューラルネットワークを用いた。ニューラルネットワークには画像データの階調度を直接情報として与え、雲の変化パターンに含まれている変化の特性を学習させて、降水雲の変化を予測した。

* 学生員 工修 室蘭工業大学大学院 建設工学専攻
(〒050 北海道室蘭市水元町27-1)

** 正会員 工博 室蘭工業大学助教授 工学部建設システム工学科
(〒050 北海道室蘭市水元町27-1)

2. 降雨域の推定

降雨域の推定は図-1に示す、苫小牧、登別、室蘭を含む北海道胆振地方西部の 60×60 kmの領域で行った。この地域は年平均降水量が2000mmを越える北海道有数の豪雨地帯であるが、山岳地域のため気象観測体制が整っておらず、防災上水文観測データの早急な整備が望まれている。現行の観測体制の不備を考慮し、ここではデータの量と質に地域差のない気象衛星ひまわりの画像データを利用して降雨域を推定する。

本研究で用いるひまわり画像データは、写真-1に示す可視画像と写真-2に示す赤外画像の2種類がある。1日の観測時間は可視画像が7時～17時(夏期は18時)の11時間、赤外画像は24時間で、それぞれ1時間ごとにデータを受信できる。これらの画像データは5 kmの距離分解能を有し、画像全体は 800×800 ピクセルで構成されている。それぞれのピクセルデータは64階調で表示され、反射率、雲頂温度など、雲画像の特性は全て階調度で表示される。可視画像は反射率で表した画像であり、雲の厚い部分ほど反射率が大きく、階調度は高く表示される。また、赤外画像は温度で表した画像であり、雲頂の高度が高いほど温度が低く、階調度は高く表示される。この両画像の特性を考慮すれば、階調度が共に高い領域は雲が厚く雲頂高度が高い、積乱雲が発達した領域であり、降雨の可能性が高いものと考えられる^{1) 2)}。

可視・赤外の両階調度が共に高い領域が実際に降雨域を形成し得るのかを調査する。北海道全域において室蘭を含む22観測地点の降水量データを調査し、寒冷前線が北海道を通過し、1mm以上の雨が降っている同日時の可視画像及び赤外画像の階調度を調べた。この結果を縦軸に可視階調度から求めた反射率、横軸に赤外階調度から求めた雲頂温度を採って表したのが図-2、図-3である。図-2は室蘭において1992年7月～1993年8月の13ヵ月間に寒冷前線が原因で1mm以上雨が降った場合の可視・赤外データ、図-3は室蘭

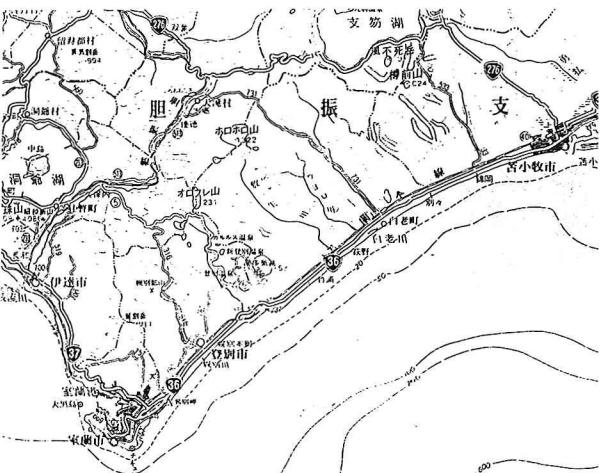


図-1 解析対象領域

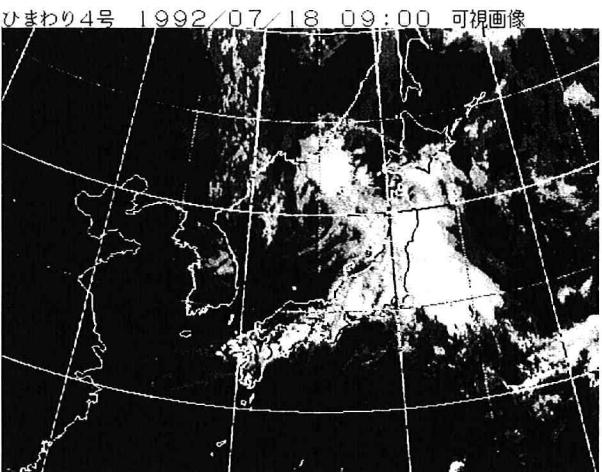


写真-1 ひまわり可視画像

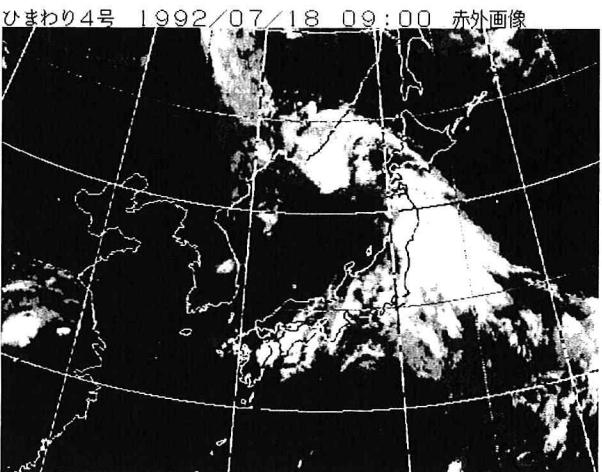


写真-2 ひまわり赤外画像

以外の他の21地点において1993年7月～8月の2カ月間の可視・赤外データを表示したものである。ここで、太陽高度変化に伴い、反射率が大きく変動することから、可視画像の階調度は次式に示す補正を行い、真反射率Aを求めた¹⁾³⁾。

$$A = a / \cos z \quad (1)$$

$$\cos z = \sin \phi \sin \delta + \cos \phi \cos \delta \cos T \quad (2)$$

ここに、aは画像から読み取った反射率、zは真天頂距離、 ϕ は観測点の緯度、 δ は太陽の赤緯、Tは太陽時角を表す。また赤緯 δ は理科年表の暦部から世界時0時の視赤緯を読み、日本標準時に変換して求めた。

この結果から降雨をもたらす雲画像階調度は図-2及び図-3に示すように、およそ反射率30%以上、雲頂温度-10°C以下という閾値を持つことが分かった。階調度がこの範囲に存在するデータは降雨の可能性が高く、画像中から閾値以上の範囲にある地域を抜き出すと、およそ降雨域の推定が可能である。また図-2及び図-3において階調度の変動幅を比較すると赤外階調度の変動幅は可視階調度より大きいことが分かる。特に室蘭の観測データは他の地域に比べて変動が激しく、山岳地域であることから地形による影響も考えられる⁴⁾。この結果から階調度が比較的安定している可視画像の方が降水雲を表現しやすく、また、降雨域の推定に有効であると考えられる。ただし、可視画像は夜間の観測データが得られず、情報が不足する欠点がある。従って降雨予測を行うには、夜間の観測が可能でデータ量の豊富な赤外画像の利用が望ましい。

ここで赤外階調と降雨量の関係を調査した。解析対象

地は室蘭とし、降雨量データは室蘭工業大学校内に設置した転倒マス式雨量計の観測値を使用した。1992年～1993年の期間に寒冷前線による降雨20例を調査し、同時刻における赤外階調度と比較した。この結果、室蘭の降雨時雲画像は、下記の4つに分類できることが分かった。

タイプI：降雨のピークと赤外階調度のピークが一致するタイプ。

タイプII：降雨ピーク出現の数時間前に赤外階調度がピークに達し、降雨時に急激に階調が低下するタイプ。

タイプIII：降雨が比較的長時間継続し、タイプIとタイプIIの混在するタイプ。

タイプIV：降雨量は比較的多いが、赤外階調度が極端に低く、降雨期間中殆ど変化しないタイプ。

タイプIは図-4に示すとおり、赤外階調度と降雨のピークが一致しており、閾値処理によって赤外階調データのみで容易に降雨域を推定できると考えられる。タイプIIの降雨は、図-5に示すとおり、降雨ピーク以前に階調度のピークが現れるもので、数時間前の情報から降雨域を推定することも可能である。これは観測データの中で最も頻度が高いタイプで、観測降雨データのほぼ半数がこれに分類される。このタイプでは降雨のピークが過ぎてから階調度が再び高まり、降雨が継続したり、低下したまま階調度が回復せず降雨が終了するなど様々な傾向のものが得られた。これに対し、タイプIII及びタイプIVは降雨と赤外階調度の関

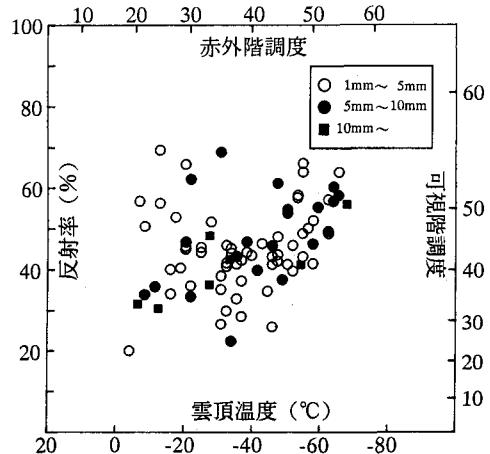


図-2 室蘭の降雨時画像階調度

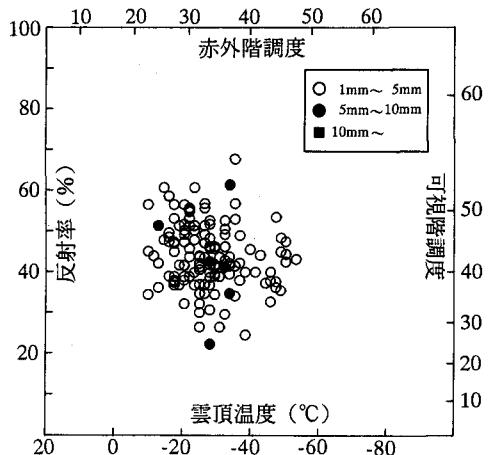


図-3 北海道の降雨時画像階調度

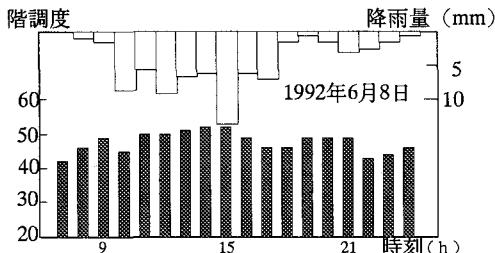


図-4 分類Iの降雨と赤外階調の関係

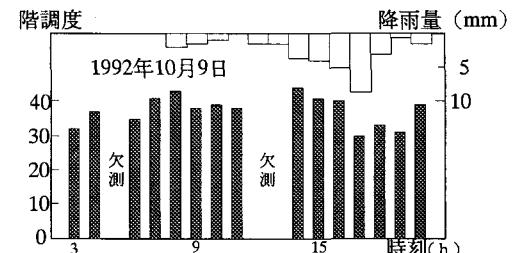


図-5 分類IIの降雨と赤外階調の関係

係に相関がなく、また観測事例も少ない。本研究ではタイプIとIIを変化パターンとして取扱い、降雨域予測を行うこととする。

3. ニューラルネットワークの構築

降水雲の時・空間変化のパターンを予測するため、本研究ではニューラルネットワークを用いる。ニューラルネットワークは生物の脳神経系の仕組みを工学的に模倣しており、画像など通常の計算方法では困難なイメージ的情報の処理に適している。計算機に雲画像情報を蓄積させ、過去の情報と類似した雲画像が与えられた時、そのパターンを記憶の中から呼び出して、数時間後にどのように変化するかを予測する。

本研究では図-6に示す3層構造のニューラルネットワークを用いる。これを雲画像の解析に利用する場合、入力層には数時間前の画像が入力パターンとして与えられ、各素子にはその一つ一つの階調度が入力値 S_i として与えられる。この画像情報はネットワーク中を複雑な経路で伝達されて出力層にある画像パターンを出現させる。このような入出力の情報処理はブラックボックス的に行われ、入力パターンと出力パターンの相互関係を利用して、画像の予測を行っている。入出力層の素子数は123個とし、解析対象領域内の画素 (12×12 ピクセル) から地形表示画素21ピクセルを除いた123ピクセルに一致させた。各層の素子は他層の全素子と結合し、その全てに結合荷重 W が設定されている。各素子は図-7に示すように、(3)式によって内部で荷重と入力値の積の総和量 x を計算し、その量に応じて次層に伝達する出力の大きさを求める。出力値の計算には図-8及び(4)式に示すシグモイド関数を用いた^{5) 6)}。

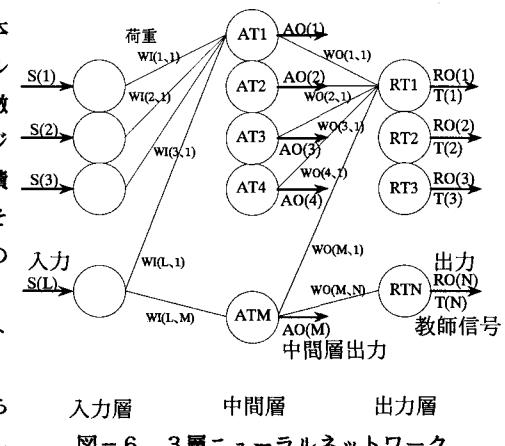


図-6 3層ニューラルネットワーク

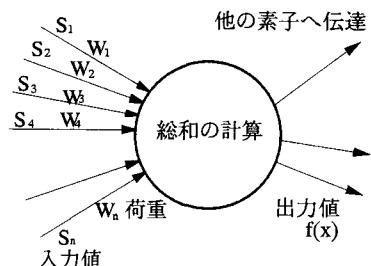


図-7 ニューロンモデル

$$x = \sum_{i=1}^n S_i W_i + \theta \quad (3)$$

$$f(x) = 1 / \{1 + e^{-x/u}\} \quad (4)$$

ここに(3)式中の θ は中間、出力層に与える出力量制御値、(4)式中の u は関数の傾きを与える係数である。1つのニューラルネットワークには数十パターンの画像情報を記憶することができる。どのパターンにも対応できる荷重を決定するためには、まず覚えさせたい教師入出力パターンを数組用意し、全てのパター

ンにおいて、入力に対して正しい出力が得られるよう学習を行って荷重を修正する。ニューラルネットワークの学習にはバックプロパゲーション則を用いた⁶⁾。バックプロパゲーション則は最急降下法により、教師出力パターンと実出力パターンの誤差量に応じて最適の荷重修正量を計算するものである。学習は荷重の初期値を $-1 \sim 1$ の乱数で割り当て、最初の出力を計算する。次にバックプロパゲーション則に従って荷重の修正し、出力値を計算し直す。これを全パターンについて数千回繰り返してニューラルネットワークにパターンを学習させる。ただし、ニューラルネットワークの学習には、下記に示す諸パラメータを設定する必要がある。

- ①学習回数
- ②中間層素子数
- ③関数形係数
- ④荷重修正量

①を多く取れば2乗誤差を少なくできるが、計算時間が掛かり過ぎるので必要以上の学習回数は望ましくない。そこで10パターンの画像データを用いた小規模の学習を行い、最適な学習回数を決定した。10000回の学習を試行した結果、2乗誤差がほぼ収束する5000回を学習回数として採用した。

②は他の条件を固定し、素子数を6、12、18、24、36、60、120と変化させ、学習を試行した。結果は図-9に示す通り、中間層素子数を多く取るほど2乗誤差は小さくなる。しかし素子数が増えれば荷重の総数が多くなって、計算時間と容量を余分に必要とするので、ここでは2乗誤差がほぼ安定する36個を最適値として採用した。

③は大きく取るほど横方向に広い関数形になるが、素子数や出力方式の違いで素子への入力量が変化したり、総和量の取り得る範囲が変化する。最も効率よく学習を行うために図-10に示すように係数を2.8、2.4、2.0、1.6、1.4、1.2少しづつ値を変えて計算し、最適値を1.6と決定した。

④は学習時に荷重を変化させる割合で大きければ2乗誤差が振動して収束せず、小さいと収束に時間が掛かるので、1.3、1.0、0.7、0.4、0.1と変化させ同様の検討を行い、最適な値を0.07と決定した。

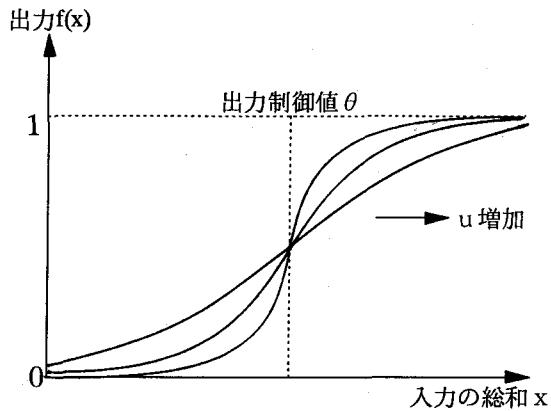


図-8 シグモイド関数

2乗誤差

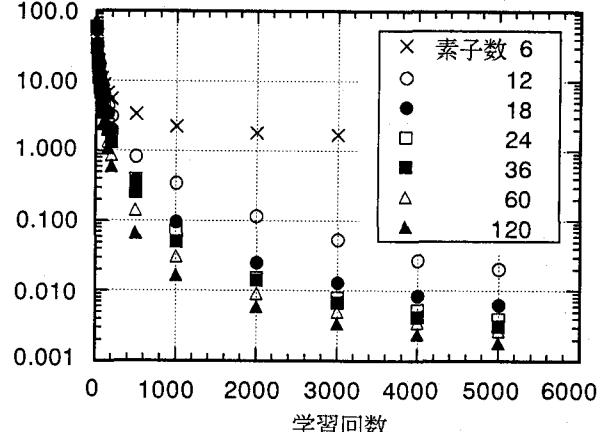


図-9 中間層素子数による学習効率

2乗誤差

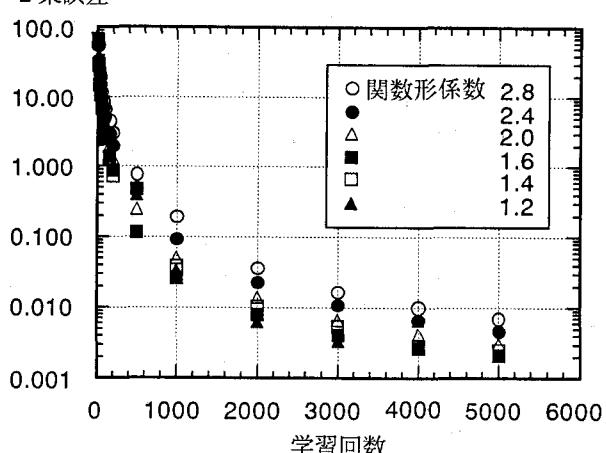


図-10 関数形による学習効率

4. 雲画像データのパターン化

解析領域の雲画像の移動変化をパターン化する。予測先行時間を1時間とし、1993年5月～8月の期間に寒冷前線通過時の可視・赤外画像を入出力教師画像として30組用意した。ここで階調度は64段階を反射率によって16段階に分類し、前処理で求めたパラメータで5000回の学習を行い、両画像パターンを記憶させた。完成したニューラルネットワークに学習に使用しなかった新しい入力データを与え、1時間後の雲の変化を予測した。ニューラルネットワークが output した同時刻の可視及び赤外画像を重ね合わせて、前述の閾値を使用して降雨域を推定した。

図-11に予測結果の一例を示す。図中の白い画素程、合成画像の階調度が高い場所を示し、黒塗りの画素は地形表示画素、図中に線で囲った部分は初めに求めた閾値で推定した降雨域を示す。この時の領域内の7点の降雨観測所において、室蘭、登別で共に5mm、カルルスで4mm、伊達で3mm、白老、森野では2mm、苫小牧では1mmの降雨が観測されており、降雨域をほぼ予測できることが分かった。予測結果全体の傾向として、画像全体ではパターンをよく表現できるが、細部の表現には曖昧な部分が残され、予測として実用するためには学習データを増やしてより多くのパターンに対応できるようにし、そのためには更にニューラルネットワークの学習精度の向上させることが必要である。

5. 結び

以上のことまとめ、次のような結論が得られた。

- 1) 雲の可視、赤外階調度を調査し、降雨をもたらす雲の反射率は30%以上、雲頂温度は-10°C以下の範囲にある。雲画像からおよその降雨域を推定することが可能になった。
- 2) 降雨域推定には可視画像が有効であることが確認された。赤外画像については降雨量との時間的変化によりにより、室蘭の降雨は4つに分類した。このうち事例の多いタイプIとタイプIIは降雨域を予測に用いることが可能と思われる。
- 3) ニューラルネットワークのパラメータは定性的な決定法しか開発されていないが、実験的な学習の前処理を行うことで最適なパラメータの決定が可能である。
- 4) ニューラルネットワークで2種類の雲画像の変化を予測し、1)の範囲を区切ることで、およそ降雨域を推定できた。予測を実用的目的るために、分類を行って学習データに指向性を持たせること、学習データの増加に伴うニューラルネットワーク性能向上が必要である。

参考文献

- 1) 謝平平、光田寧：GMS赤外データを用いた雲の解析について、京大防災研年報32号、pp. 349-359, 1989
- 2) 安藤政雄：新天気予報の手引き、日本気象協会、pp. 167-170, 1983
- 3) 友田好文他：地球観測ハンドブック、東京大学出版会、pp. 57-65, 1985
- 4) 大川 隆：北海道の動気候、北海道大学図書刊行会、pp. 55-146, 1992
- 5) 菊地豊彦：入門ニューロコンピュータ、オーム社、pp. 17-67, 1989
- 6) 中野 馨：入門実習ニューロコンピュータ、技術評論社、pp. 28-84, 1989

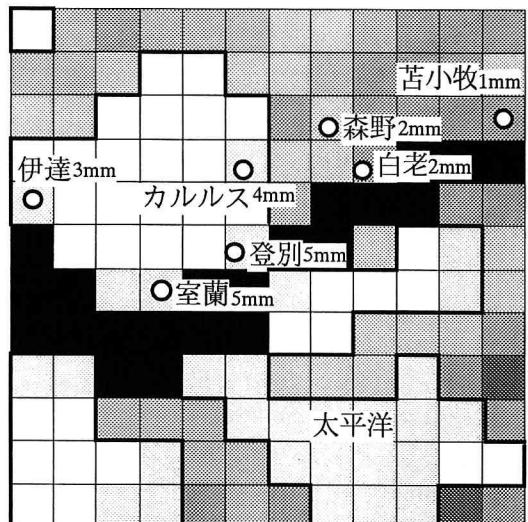


図-11 予測降雨域（黒い画素は地形表示画素）