

II-18

## ニューロンモデルを用いた 気象衛星ひまわりの雲画像解析（その2）

室蘭工業大学 学生員 井形 淳  
室蘭工業大学 正員 藤間 聰

### 1. はじめに

著者らは、北海道における最大の降雨成因の1つである、寒冷前線通過に伴う降雨の予測について検討してきた<sup>1)</sup>。ここでは、寒冷前線上で発達する積乱雲に着目し、これが原因となる降雨域を推定し、降水雲の時間変化を予測することを目的としている。データには空間的に一定の精度を保持できるリモートセンシング観測による気象情報を用いた。本研究では、室蘭工業大学地域共同研究開発センターにおいて受信した気象衛星ひまわりの可視画像、赤外画像を用い、両画像の特性を生かして降雨域を推定する。本来このような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るが、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い限り、予測計算の実行は不可能である。このような欠点を補うために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は生物の脳神経系の仕組みを工学的に応用しており、衛星雲画像の変化パターンを、画像を構成する階調度のまま記憶できる。ここでは各種気象データを用いて予測計算をするのではなく、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。

### 2. 可視・赤外画像解析

本研究で用いたひまわり画像は、写真-1に示す可視画像、写真-2に示す赤外画像の2種類がある。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、各画像は1時間ごとに受信できる。画像の距離分解能は5kmで、画像全体は800×800画素で構成されている。それぞれの画素は64階調で表示され、可視画像は反射率、赤外画像は雲頂温度を全て階調度で表示している。可視画像は反射率から雲の厚さを特徴づける画像であり、また赤外画像は雲頂温度から雲の高度を特徴づける画像である。この画像特性を考慮すれば、両画像の階調度が共に高い領域では、雲が高高度まで厚く発達した積乱雲が発生し、降雨に寄与する可能性が高いと考えられる<sup>2)3)</sup>。

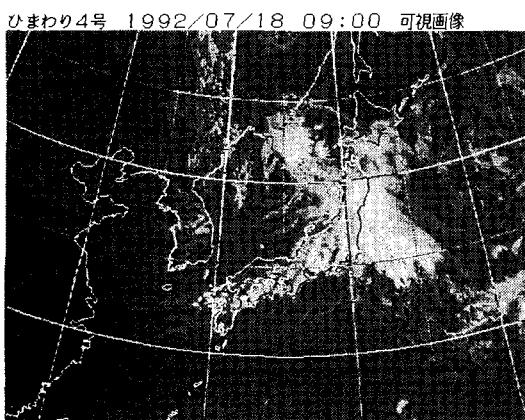


写真-1 ひまわり可視画像

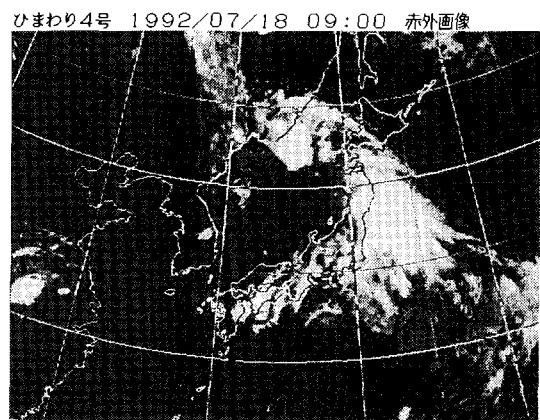


写真-2 ひまわり赤外画像

降雨域の推定に用いたデータの範囲は、図-1に示す苫小牧、登別、室蘭など7点のアメダス降雨観測地点を含む、胆振地方西部の $60 \times 60$ kmの領域である。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、またビネシリ山を中心とする気象レーダーの定量観測範囲からも外れているため、防災上水文観測データの整備が急務である。現行の観測体制の不備から判断して、本研究には空間的精度格差のない、リモートセンシング観測データの利用が適している。

全体画像から上記に示す領域の画像を抽出した後、各画素データを、可視画像は反射率で5%ごとに、赤外画像は温度で5°Cごとの16段階に分別した。これはニューラルネットワークが記憶できるパターン数を多くするためである。このデータはニューラルネットワークに記憶できるように0~1の範囲に変換した。また可視画像の階調度については、太陽高度変化に伴って反射率が大きく変動するため、次式に示す補正を行い、真の反射率Aを求めた<sup>2) 4)</sup>。

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

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

ここに、 $a$ は画像から読み取った反射率、 $z$ は真天頂距離、 $\phi$ は観測点の緯度、 $\delta$ は太陽の赤緯、 $T$ は太陽時角を表す。また赤緯 $\delta$ 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。

以上のように画像データを処理し、ニューラルネットワークに記憶させるために、教師入力画像と教師出力画像の組を用意する。この時、教師入力画像と教師出力画像の関係は、それぞれ予測先行時間前後の画像であり、記憶させたい雲画像の変化パターンを一組として、必要な変化パターンの種類の数だけ用意する。

### 3. ニューラルネットワークの構築

本研究では図-2に示す3層構造のニューラルネットワークを用いる。入力層には学習用に用意した、教師入力画像を構成する一つ一つの階調度が、入力値 $S_i$ として入力層素子に与えられる。同様に出力層には教師出力画像の階調度が、教師信号 $T_j$ として出力層素子に与えられる。尚、入力層と出力層の素子数は、教師画像の素子から地形表示用の21画素を取り除いた123とした。また中間層は任意の素子数が設置できるようになっており、目的に応じて最適な素子数を選択している。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 $W_I$ 、 $W_O$ が設定されている。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が、この出力画像パターンを教師出力画像に一致させるために、学習を行って結合加重 $W_I$ 、 $W_O$ を調節する。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ており、本研究では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。

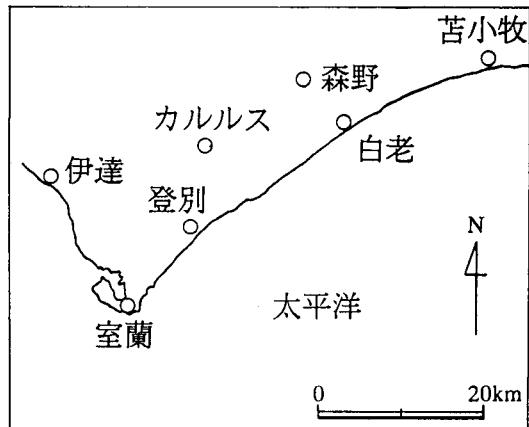


図-1 解析対象領域図

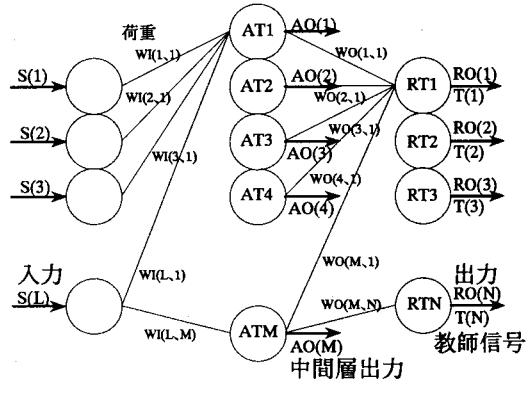


図-2 3層 ニューラルネットワーク

各素子は図-3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-4及び(4)式に示すシグモイド関数を用いた<sup>6) 7)</sup>。

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

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

ここに(3)式中の $\theta$ は中間層、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。

ニューラルネットワークの学習はバックプロパゲーション則を用いて行った<sup>6)</sup>。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な荷重修正量を計算する。学習はまず $-1 \sim 1$ の乱数で荷重の初期値を決定し、初期出力を計算する。次にバックプロパゲーション則に従って荷重を修正し、出力値を計算し直す。これを全パターンについて、正しい出力されるまで数千回繰り返してパターンを学習させる。これには、①学習回数、②中間層素子数、③関数形係数、④荷重修正量など諸パラメータを設定する必要がある。

このようなパラメータの決定には決まった方法がないため、経験的な方法により最適な値を決定した。①は多く取るほど2乗誤差量を少なくできるが、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組の画像パターンを用いた小規模の学習を行なって、最適な学習回数を決定した。10000回の試行結果から、2乗誤差量が収束するのはほぼ5000回であり、またあらかじめ数百回程度の学習を行い、この結果を初期荷重として与えることで、3000回程で同様の2乗誤差量の収束が得られた。②は素子数を6、12、18、24、36、60、120と変化させ、学習を試行した。結果は図-5に示すとおり、中間層素子数が多いほど、内部に記憶できる情報量が多くなり、2乗誤差量を少なくできる。この結果、2乗誤差量がほぼ安定するのは中間層素子数が24~36個の場合である。必要以上に素子数を設定すると、荷重総数の増加と共に計算時間と容量がより多く必要となるため、ここでは予測計算に用いるパターン数が多くなることを考慮して48個を採用した。③は大きく取るほど横広の関数形になるが、素子数や入力値の偏りなどにより、総和量の取り得る範囲が変化する。最適な学習を行うために、図-6に示すように係数を2.4、2.0、1.6、1.4、1.2

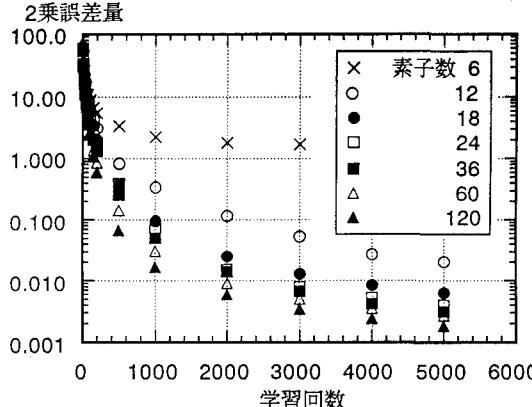


図-5 中間層素子数による学習効率

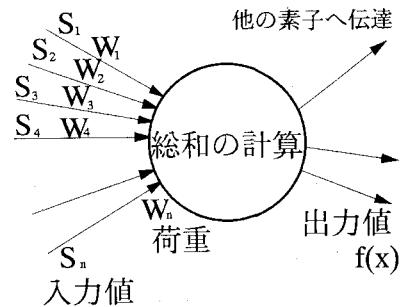


図-3 ニューロンモデル

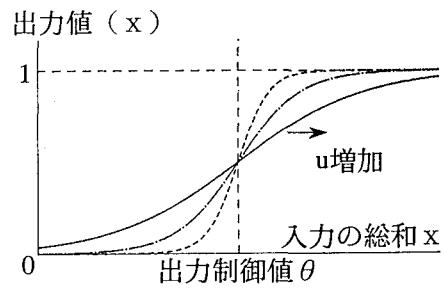


図-4 シグモイド関数

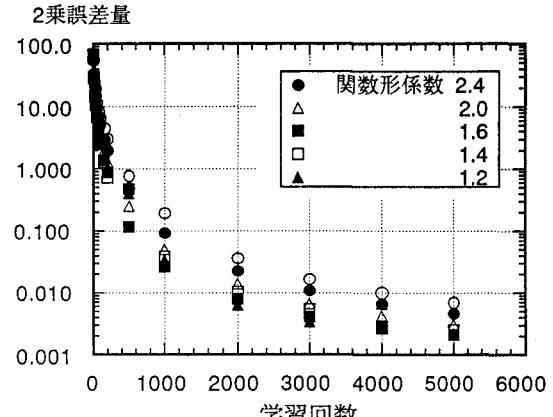


図-6 関数形による学習効率

と値を変えて計算した結果、最適値は1.6であることが分かった。④は大き過ぎれば2乗誤差量が振動して収束せず、小さ過ぎれば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0.7を決定した。更に、この値を計算の過程で徐々に減じることで、より正確な学習が可能になった。また、乱数の種類によって学習の効率が大きく異なるため、①で述べた学習の前処理の段階で数個の乱数を試行して、最適なものを用いた。尚、この段階で荷重修正量を大きめに設定することで、2乗誤差量が極値で収束するのをある程度防ぐことができる。

#### 4. 降雨域の推定

本研究では降雨域を推定するために、降雨時のひまわり画像の階調度を調査した。調査の対象としたのは1992年～1993年に寒冷前線通過が原因で発生した降雨のうち、時間雨量1mm以上の降雨で、この時の可視画像と赤外画像の階調度との関係を調べた。降雨データは5～7月のものと8～10月のものとに分別した。階調度は図-7に示すような北海道全域の24観測地点について調査し、また24観測地点のうち本研究の対象領域である、カルルス、登別、室蘭の3降雨地点と、他の21降雨地点を分けて調査した。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探って表し、更に降雨量について1mmから5mm、5mmから10mm、10mm以上の3つに大別して降雨量と階調度との関係を調べた。

この結果、まず降雨とひまわり画像階調度の関係には、季節格差があることがわかった。胆振地方西部を除く全道での傾向を図-8、図-9に示す。この図から5月から7月での階調度は雲頂温度-20°C～-40°Cと反射率30%以上の領域に集中しており、これに対し8月～10月では雲頂温度-40°C～-60°Cと反射率20%以上の領域に集中していることがわかる。また図-10、図-11に示す胆振地方西部での関係では、この傾向はより顕著である。特に8月から10月での胆振地方西部での階調度は雲頂温度-30°C以上と反射率40%以上の領域に集中しており、太平洋から吹き込む温暖な空気の影響が見られる。

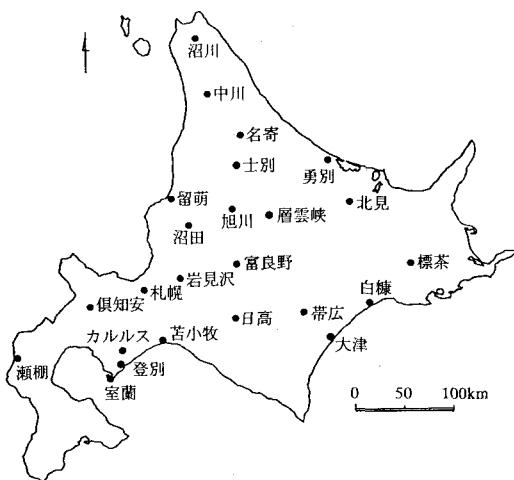


図-7 北海道降雨量観測地点

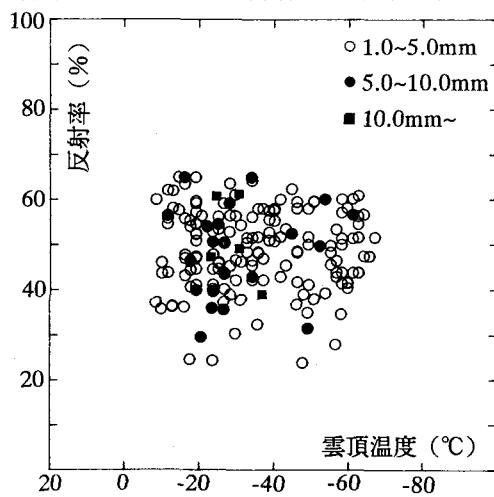


図-8 全道における5月～7月の降雨特性

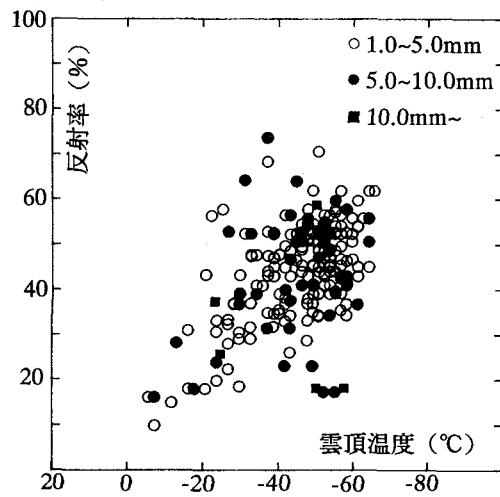


図-9 全道における8月～10月の降雨特性

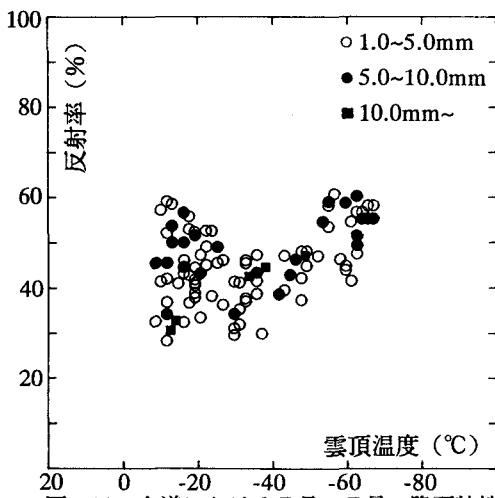


図-10 全道における5月～7月の降雨特性

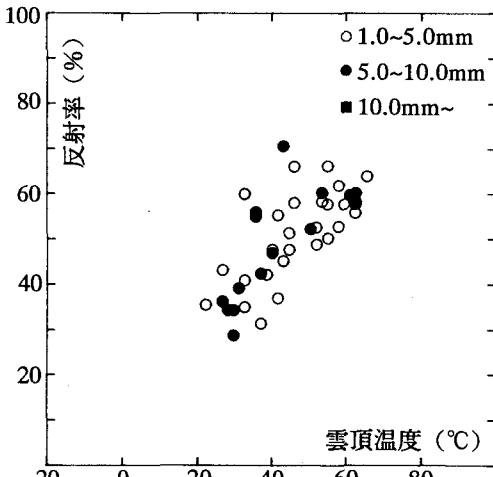


図-11 全道における8月～10月の降雨特性

本研究では降雨量と階調度の関係についても調査しているが、降雨量5mm以上の降雨量の多い点は図の全体に広がっており、降雨量を規定する要因は見られなかった。以上のことから降雨と階調度の関係は1つ1つの降雨においてかなり個別差があり、ニューラルネットワークの学習に用いる画像データはある程度の分類をして記憶させる必要が考えられる。

## 5. 降雨パターンの予測

解析領域の雲画像データをパターン化する。予測先行時間は1時間から2時間とし、予測精度の比較を行う。また、ここに用意した降雨は1992年から1993年の間に寒冷前線が原因で発生した降雨20事例で、上記に示す調査結果から、このうち5月から7月の降雨と8月から10月の降雨について個別に学習を行った。更に降雨は赤外画像の時間変化を調べた結果、階調度が極端に低く、変化の少ない事例と、複数の降雨が重なるなどして長時間持続する事例が存在するが、現段階ではこれらを使用しないことにした。これらの中から適当な6降雨30パターンを選択し、上記に示した学習法を用いてパターン化を行った。ここで学習は可視画像と赤外画像を個別に行い、それぞれが正確にパターンを記憶できることを確認した。また学習に使用しない降雨は予測処理用に用いた。これらの2つのニューラルネットワークにより、予測された雲画像を合成し、先に示した両画像データの閾値を用いて降雨域を推定した。また、ここで本研究で対象とした領域は、図-1に示す7点のアメダス降雨観測所が存在しており、この降雨量データを降雨域の検証に用いた。

推定例を図-13、図-14に示す。図はそれぞれ予測先行時間が1時間と2時間の場合であり、5月から7月の降雨をパターン化した結果である。図中で画素の白い部分ほど重ね合わせた時の階調度が高いことを示している。また太線で囲まれた部分は合成によって推定された降雨域である。両画像の7地点の降雨観測点での降雨量はそれぞれ登別3mm、カルスル1mm、森野1mmであり、室蘭、苫小牧、白老、伊達では0mmとなっており、降雨域をほぼ推定できることがわかった。ただし予測に関しては、全く相関のない雲画像を出力する推定例もあり、特に雲画像の変化の大きなパターンではこの傾向が強いことがわかった。また階調度が大き過ぎる画像を学習させた場合では、これらの画像の特徴が、雲画像の推定に大きな影響を与えることがわかった。これらのこととを解決するためには、降雨の学習例を多くするか、全線との距離や低気圧の中心の位置など、他の気象データを用いてパターン外のデータに対応する方法が不可欠である。また図-13、図-14の時間的な予測精度の変化については、パターンの変化が大きくなる2時間後の推定の方が予測精度は低下しており、これは学習データ量、学習に用いる降雨パターンの種類に起因するものが大きいと考えられる。

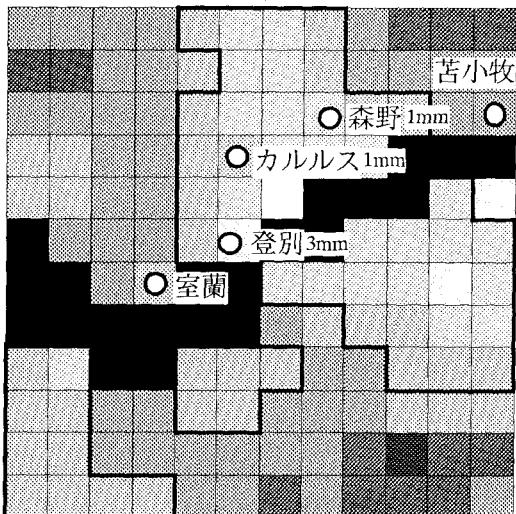


図-13 1時間後の降雨域の推定

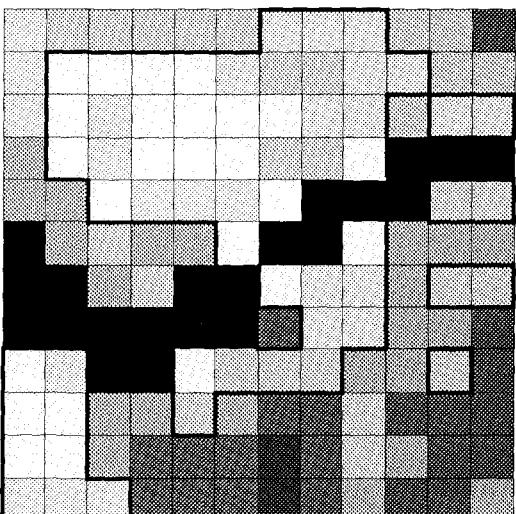


図-14 2時間後の降雨域の推定

## 6. 結 び

以上のことから、次のような結論が得られた。

- ① 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が開発されていないが、実験的に学習を行うことで最適なパラメータの決定が可能であり、前処理により学習の高速化が実現できた。
- ② 雲の可視・赤外階調度を調査し、降雨をもたらす雲には季節差があり、5月から7月では反射率30%以上、雲頂温度-10°C以下の範囲、8月から10月では反射率40%以上、雲頂温度-20°C以下の範囲であり、これは太平洋から吹き込む温暖な大気の影響が考えられる。
- ③ ①②の結果より、画像パターンをニューラルネットワークに学習させ、およその降雨域を推定することが可能である。また精度向上のため、降雨パターン数、種類との関係を調査する必要である。
- ④ ネットワークの予測精度は雲画像変化の度合いに影響を受けるので、長期予測の精度は低下すると考えられる。また、データとして可視画像を用いるとデータ量が制限されるため、学習が十分にできなくなることも原因のひとつである。現在のところ、予測先行時間は1時間が最適である。
- ⑤ 降雨をある程度分類しておくことで、雲画像パターンが指向性を持つので、今後学習データの増加させるためにも、このようなデータの分別が必要である。

最後に、本論文作成にあたり降雨量データを提供して頂いた、室蘭開発建設部治水課の船木淳悟氏に感謝いたします。

## 参考文献

- 1) 井形 淳、藤間 聰：ニューロンモデルを用いた気象衛星ひまわりの雲画像解析、  
北海道支部論文49号、pp. 553-558, 1992
- 2) 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
- 3) 安藤政雄：新天気予報の手引き、日本気象協会、pp. 167-170, 1983
- 4) 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
- 5) 大川 隆：北海道の動気候、北海道大学図書刊行会、pp. 55-146, 1992
- 6) 菊地豊彦：入門ニューロコンピュータ、オーム社、pp. 17-67, 1989
- 7) 中野 鑿：入門実習ニューロコンピュータ、技術評論社、pp. 28-84, 1989