

II-46

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

室蘭工業大学大学院 学生員 井形 淳

室蘭工業大学 正 員 藤間 聡

1. はじめに

降雨は我々の生活に大きな関わりを持っている。それは生物が生きるために必要なものを、自然の恵として様々な形で与えてくれる。他方、多過ぎる雨は人間の生活を脅かす自然の脅威となり、これを防ぐために人間は多くの努力を払ってきた。降雨の予測もその一つであり、人間が昔から試みて、未だに成しえない技術である。近年土木分野でも独自に降雨の予測を行おうという風潮が高まっている。それは悪天候による工事の中止や延期が予測できると、規模が大きいためかなりの損害減少を見込めるからである。

現在降雨の予測には、衛星やレーダーを利用したリモートセンシング技術が多く使われている。この方法は集中豪雨などの中規模気象現象を捕らえるのに非常に優れている。本研究では気象衛星ひまわりの画像データを用い、降雨域を推定する方法について検討する。大雨をもたらす要因としては台風、寒冷前線、梅雨前線、低気圧など様々であるが、中でも台風と寒冷前線は高高度まで積乱雲が発達して短時間に強い雨を降らせるので、特に被害が大きい。本研究では寒冷前線の移動に伴う降雨域の変化に注目し、この変化をパターン化することを考える。本来この手法のパターン化には膨大なデータ量を必要とするため、生物の脳神経細胞の働きを工学に応用したニューロ理論を用いることにする。

2 研究内容

本学地域共同研究開発センターでは気象衛星ひまわりの画像受信装置及び気象ファックス受信装置を設置し、昨年7月からデータ収集を継続している。これにより気象衛星ひまわり（GMS）の赤外画像、可視画像データ、地上と高層の天気図データを得ることができる。1画像は、64階調で表現された5km×5kmのピクセルを、全体で800×800ピクセルで構成している。可視画像は反射率によって階調を表現し、階調が高い地点は雲が厚いと考えられる。また赤外画像は雲頂温度により階調を表現しており、階調が高い地点は雲が高高度まで発達していると考えられる。このことから2枚の画像を組み合わせることで雲の種類を推定できる。本研究で対象とする積乱雲のような降雨強度が高い雲では、赤外と可視の両画像とも階調が高く、積乱雲が発達している可能性が高い。そこでこれらの画像を重ね合わせ、その時間の各地点降雨量との関係を調べた。降雨強度の高い雲の範囲を調べ、この情報から降雨域がどのように変化するか、ニューロンモデルを用いてパターン化した。

ひまわり4号 1992/07/18 09:00 赤外画像




写真1 ひまわり赤外画像

Cloud Analysis of GMS Infrared and Visible Images by Neural Networks

by Sunao IGATA and Satoshi TOHMA.

またモデルの同定を行なって、よりスムーズなパターン化を目指した。

3. 降雨域の推定

本研究では1992年5月から9月の間に発生した寒冷前線21個を調査し、降雨をもたらす雲について推定を行った。前述のようにGM Sの2種類の画像から、どの種類の雲が降雨をもたらすのかある程度推定できるので、降雨域を区切るための階調を特定した。まず図2-1に示す北海道の降雨観測地点を19地点設定し、この時の赤外画像、可視画像、及び観測点の降雨量をまとめた。ここで可視画像については夜間の観測が不可能なので、日中のデータの内、赤外、可視両画像が存在する8時間分を対象とした。また太陽高度によって反射率が変化するため、可視画像は次式を用いて反射率を変換した¹⁾。

$$A=a/\cos z \tag{1}$$

$$\cos z=\sin \phi \sin \delta +\cos \phi \cos \delta \cos T \tag{2}$$

ここでTは太陽時角、φは観測点の緯度、δは太陽の赤緯を表しており、赤緯は理科年表の暦部から世界時0時の視赤緯を調べ、日本標準時に変換して求めた。また本研究では、全対象地域の観測点緯度φは全て北緯43度として反射率の変換を行った。

このようにして求めた階調の中から、1mm以上の降雨があった時の赤外階調と可視階調データを図2-2に示す。この図によると降雨時の可視階調は殆どが35を超えているのに対して、赤外階調ではかなりのばらつきが見られる。これは降雨が雲厚に大きく影響されることが考えられる。また本研究では5km四方の領域を1点の降雨観測データで表すため誤差が大きく、地形によっては同じ階調でも降雨に差が生まれると考えられる。

使用した全データの中には、雲域と思われる範囲でも降雨がない場合があり、現状では画像のみでの降雨域あるいは雲の種類の予測は難しい。今のところ可視画像で階調度35以上の雲が存在する




写真2 ひまわり可視画像




図2-1 降雨観測地点図




図2-2 降雨強度赤外可視階調図

範囲を降雨確率の高い領域と仮定できる。この領域がどのように変化するかをニューロンモデルを用いてパターン化を行った。

4. ニューロンモデルの同定

ニューロ理論は、生物の脳神経の仕組みや働きを工学的に利用する目的で考え出された理論で、人間の五感のような、多量の情報を並列的に処理する仕組みを真似ている。一つ一つの神経細胞は、他の神経細胞からの情報量に応じて他の神経細胞に伝達する、伝達しない、という簡単な機能しか持っていない。それが、数億という神経細胞が複雑に結合し、そのネットワーク中を様々なパターンで伝達する間に多数の複雑な出力を得ることができる。また1つのネットワークの細胞間に分散的に多種類の記憶を蓄積できる。このような並列処理機構は、認知情報処理、即ち記

号や言葉の情報処理を基にしたノイマン型のコンピュータでは困難な、画像のようなイメージ的な情報処理を可能にしている。

ニューロ理論ではこのような神経細胞の働きは、閾値と荷重を用いてモデル化されている。荷重とはある神経細胞に対する入力があった場合、この入力が及ぼす影響度で、このような入力がある一定値、閾値を越えると細胞が活性化して次の細胞へ情報が出力される。このような神経細胞のモデルの中で、代表的なものは図4-1に示すような閾素子モデルと準線形素子モデルの2つが考えられている。閾素子モデルは入力情報の総和が閾値を越えるか越えないかで1、0のどちらかを出力するモデルである。また準線形素子モデルは入力、出力共に連続値で表した、現在最も良く使われているモデルである。このモデルでは次式のようなロジスティック関数を用いている。式中のXは入力の総和を表していて、これが大きいほど出力値は1に近い値を取る²⁾。

$$f(x) = \frac{1}{1 + \exp(-x/U)} \tag{3}$$

このような働きをする1つの素子を多数組合わせてニューラルネットワークが形成され、これらはある入力に対し、決まった出力が得られるように学習を通して閾値、荷重が決定される。本研究で用いた学習方法はバックプロパゲーション法である。この方法は図4-2のように入力層、中間層、出力層と素子が階層的に素子が結合され、各層の素子是他層の全ての素子と結合している。各結合及び素子は、-1～1の間の乱数によって荷重と閾値の初期値が与えられる。この荷重と閾値は全て可変で、ある入




図4-1 a 閾素子モデル




図4-1 b 準線形素子モデル




図4-2 バックプロパゲーション正方向学習




図4-3 バックプロパゲーション逆方向学習

力に対して必要な出力が得られるよう変化させる。

入力値は、荷重の積の総和 $\sum S(I) \cdot WI(I)$ と閾値 $AT(I)$ によって中間層素子からの出力値が0～1の間で決定される(図4-2)。出力値は式(3)のようなシグモイド関数を用いる。また出力層でも同様の出力を行い、それが必要とする出力値(教師信号)と異なっている場合、その誤差を求め、それを逆方向に伝播しながら各荷重を修正する(図4-3)。次に修正された荷重を使い、再度出力を求める。これを学習回数分繰り返す、また必要な全パターンについて行う。なお本研究では学習の計算時間短縮のためモーメント法を用いた³⁾。学習されたネットワークは、記憶したパターンに似た入力に対応して出力するようになる。

ニューラルネットワークは全素子の閾値と全素子間の荷重が必要のため情報量が膨大になる。現在ニューラルネットワークの大きさや形を決める方法がないため、本研究では実際に学習させて、最も学習しやすいニューロンモデルの構造を決定することにした。ここで対象にしたのは次の3つで中間層数は計算機の容量、処理速度から判断して単層とした。

- ① 荷重変化量
- ② 素子モデルの関数形
- ③ 中間層素子数

荷重変化量は学習時の荷重修正量で、大き過ぎると、目的の荷重付近で振動して値が収束せず、小さ過ぎても収束が遅くなると考えられる。そこで最も適切な修正量を実際の学習で判断した。上記の手順で初期荷重を設定し、北海道周辺から7月のGMS赤外画像を12組の入出力データとして用意し、各200回の学習を行って全出力の最小二乗誤差を計算した。ここで素子数は中間層15、入力層14、出力値は0～1の範囲であるため64階調を表現できないので、出力値を2進数表示して84とした。修正量を0.7、0.5、0.3、0.2、0.1、0.05と変化させた結果を図4-4に示す。この結果から、修正量が大きいと誤差は早めに収束し、一定値以上変化しなくなるため大きな修正量は学習に不向きでなことが分かる。変化量が小さいほど最終的な誤差量は小さくなると考えられるが、本研究では500回以下の学習回数を考えているので修正量は0.1～0.3が望ましい。

素子モデルの関数形は式(3)のU値を0.4、0.8、1.2、2.0と変化させて学習の変化を調べた。U値が大きいと図4-1bのグラフは横長になって荷重変化が鈍くなり、またグラフが縦長になればその逆が考えられる。また本研究では、出力値を2進数化したため縦長の関数形が適当だと思われる。この学習の結果は図4-5に示す通り、低学習回数を考慮にいと、 $U = 0.8 \sim 1.2$ が適当である。

中間層素子数は多ければ学習時間及び計算容量が増大し、少なければパターンを十分に記憶できない。ここでは素子数とパターン数を変えて学習を行った。素子数を5、15、30と変化させ、またパターン数を6、12、18、24、48と変化させてそれぞれ計算を行った。この結果からはあまり有義的な解答は得られなかったが素子数がパターン数とほぼ同数存在すれば、低学習回数で十分な学習を得ることができた。ここでは素子




図4-4 荷重変化量による学習効率の変化




図4-5 関数形による学習効率の変化

数を少なめに設定し必要に応じて増やすことにした。

以上の結果から本研究に用いるニューロンモデルは、①荷重変化量を0.2、②関数のU値を0.8、③中間層素子数を30個とした。なおこれらの値は全て、対象とするデータや出力形式が違えば新しく設定し直す必要がある。


5. 降雨域のパターン化

降雨域のパターン化に用いた画像データは1992年5月から9月の間に発生した寒冷前線のうち、特に降雨の激しかった日時の可視画像データから、北海道中部の20×20ピクセルの領域を20データ用意した。データは入力画像の一時間後の画像を教師画像とし、前述のようなニューロンモデルを用いて計算した。本研究では降雨域パターン化の第一段階として、最も簡単なネットワークを用い、500回の学習を行ってその学習能力を確かめた。

図5-1は学習時の入力用に用意した画像の1つで、色の濃い領域は降水雲を示している。図5-1で降水の可能性が高い領域にある沼田町では、この時間帯に5.5mmの降雨があった。図5-2は学習時の教師画像用のデータで、これらを元にしてネットワークが正しい画像を出力するように学習した。500回の学習を済ませたネットワークから出力される画像が図5-3であるが、かなりの精度でパターンを記憶していることが確認された。

今回はこのような最も小さい規模での雲のパターン化を行ったが、今後はもっと大きな規模での雲のパターン化を考えているので、このように画像自体を入出力に取り込む方法では、大きな規模のネットワークを用いるほど情報量が増大し、容量、計算速度だけではなく予測精度への影響が懸念される。

そこで風や気圧の気象情報を加えたネットワークを用いてパターン化を行う必要があると考えられる。また可視画像はデータ観測が日中に限られてしまうため、1日を通して観測ができる赤外画像をもっと利用する方法が必要である。



6. フラクタル解析

前説で述べた降雨域のパターン化に伴い、予測した降雨域の信頼性を検証するために、フラクタルを用いて雲の発達、衰退過程を調査した。雲を空気の流動の場とすると、乱流の拡散現象として考えることができる。リチャードソンの4/3乗則によると、乱流中の2点間の距離Yが時間tに関して式(4)を満足するので、乱流場における面積Y²が時間tの経過とともに直径の4/3乗で増加することで、雲の面積は直径Yの4/3乗に比例すると推察される。

$$\frac{\partial Y^2}{\partial t} \propto Y^{4/3} \quad (4)$$

Mandelbrotはフラクタル的な図形の周辺長と面積の比が式(5)で表せることを示した⁴⁾。

$$\rho_D = [L(\delta)]^{1/D} [A(\delta)]^{1/2} \quad (5)$$

また、HentschelとProcaccia(1984) はリチャードソンの4/3乗則に基づいて、雲の周辺のフラクタル次元Dが $1.37 < D < 1.41$ の範囲にあることを算出した。これによって雲がその形を変化させる過程には、このような一定の関係が存在することを示した。

本研究では、この雲面積と周辺長の関係を降雨域に適用して、降雨域の発達、衰退の過程を

調べることにする。対象としたのは92年7月から8月の間、寒冷前線が通過した時の北海道周辺の赤外画像である。この時の雲の階調の高い部分の周辺長Lと雲面積Aを、キルビメーターとプランิเมータを用いて計測した。画像は階調で35以上、雲頂温度にして -30°C 以上の領域を閾値とした。この時画像の分解能から判別して、読み取り可能な最低距離は10 kmであった。このようにして計測したデータ 172個を縦軸に面積、横軸に周辺長をとって両対数表示すると図6のようなグラフが得られる。この結果に対して最小二乗法を用いて直線回帰を行い、直線の傾きからフラクタル次元は $D=1.32$ となり、Hentschel と Procacciaの算出した値にほぼ等しい。

この結果から今後ニューロンモデルを用いて予測された画像は、以上のようにフラクタル解析による検証を行い、予測したパターンの信頼性を検証していく予定である。

7. 結論と今後の予定

今回はニューロンモデルを用いた降雨域予測の第一段階として、降雨域変化のパターン化を行ったが、本研究で行った降雨域の推定法は、空間的な誤差が大きかったことが分かった。また雲のパターンも、気象観測情報による予測の変動性を考慮できなければ、複雑なパターンの予測は難しいと考えられる。今後は観測データとフラクタル解析を用いて、予測データの信頼性を確認するとともに、地形を加味したデータの処理を行い、また気象情報を考慮できる複雑なニューロンモデルを開発する予定である。

本論文の遂行にあたり、降雨データの提供を頂いた室蘭開発建設部治水課の中田満洋氏、また図表作成に協力を頂いた本学学部学生の村井雄太、武知伸幸両君に、謝意を表します。

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) 菊地豊彦：入門ニューロコンピュータ、オーム社、pp. 17-67、1990。
- 3) 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。
- 4) J. フェダー（松下貢訳）：フラクタル、啓学出版、pp. 211-220、1991。




図6 フラクタル図