

II-16 ニューラルネットワークを用いたメソスケール降雨系の時・空間分布予測

室蘭工業大学 学生員 安藤雪絵
室蘭工業大学 正員 藤間 聡

1. はじめに

水文現象の解析にはその目的に応じた観測密度、精度及び期間を有する観測データが必要とされる。しかし、観測地点の制限などによって多岐の目的に対応する観測データが得られないのが現状である。本研究は気象衛星雲画像データに基づき降雨発生最小単位である降雨セルを確率的に発生させる降雨パターン発生モデルを構築する。また、流出予測などを行う際、短時間での予測が重要となる。従って、従来のニューラルネットワークに修正モーメント法、ボルツマン・マシーン法を取り入れることにより改善し大幅な計算時間の短縮を図り、前述の降雨発生モデルを用いて降雨の時・空間変化の過程を予測する降雨モデルを構築する。

2. 確率過程に基づく降雨パターン発生モデル

北海道地方で発生する豪雨の大部分は低気圧に伴う寒冷前線性降雨である。この降雨は、前線上でセル構造をもつ積乱雲から発生し、メソβスケールをもつ現象である。従って、解析領域の空間スケールは100km程度のメソβスケールとし、メソγスケールの対流性セルを発生、発達及び集合させて降雨パターン発生モデルを作成する。


降雨セルはポアソン過程に従い確率的に独立した空間に分布し、ランダムなパラメータを含む次式に従って時・空間に降雨を発生するものと仮定する¹⁾。

$$i(t, r) = i_0 i_t(t) i_s(r) \quad \dots (1)$$

$$i_t(t) = \exp(-\alpha t) \quad \dots (2)$$

$$i_s(r) = \exp(-r^2/2D^2) \quad \dots (3)$$

ここに、 i は降雨セル発生時からライフタイム t でのセル中心からの距離 r における降雨強度、 i_0 はセル発生時の降雨強度、 i_t は降雨強度の時間的、 i_s は降雨強度の空間的減衰をそれぞれ表す。また、(2)式の α はセルのライフタイム決定定数で減衰期のみを考慮する。(3)式の D はセルの空間的広がりを示す特性距離を表す。本解析で用いたパラメータは、セル中心の降雨強度 $i_0=10\text{mm/h}$ 、空間特性距離 $D=1.25\text{km}$ 、 α は平均0.3、分散0.1の正規乱数を与えた。



降雨セルの発生位置は、気象衛星ひまわりの雲画像を解析した結果、ポアソン過程に従うことから (4) 式の確率密度関数により決定する²⁾。

$$f_{D_k}(r) = 2\pi\lambda r e^{-\pi\lambda r^2} \frac{(\pi\lambda r^2)^{k-1}}{(k-1)!} \quad \dots (4)$$

ここに、 r は基準点からの距離、 λ は単位面積当たりの降雨セル数、 k は降雨セル数をそれぞれ示す。

上述の降雨発生モデルを用いメソ β スケールで降雨セルを発生し、時・空間的变化の過程を再現するモデルを構築する。本解析は、解析領域90km×90kmの左下を降雨セル群の中心とし降雨セルを確率密度関数(4)式に従って発生させる。図-1は、降雨パターンの1事例として11個の降雨セルを同時に発生させたものである。出力図のモデル中央の60km×60kmの範囲を2.5kmの24×24の円で分割している。時間の経過に伴い降雨セルが減少、消滅、又はクラスター化する様子が認められる。

3. ニューラルネットワークによる降雨の時・空間分布予測モデル

上記で発生させた降雨域の時・空間変化のパターンを、画像認識に適しているニューラルネットワークを用いて数時間先の降雨域予測を行う。本研究では、計算時間を短縮し、効率的に予測を行えるよう従来のニューラルネットワークモデルに修正モーメント法³⁾、ボルツマン・マシンの法⁴⁾を取り入れた。

3.1 ニューラルネットワークの基本構造

本研究では、入力、中間、出力層の3階層型ニューラルネットワークモデルを用いる。各素子は、次層の全ての素子と結合し、結合の強さを表わす荷重が設定されている。このモデルにおいて入力層に与えられた降雨パターン情報は、中間層を通して出力層まで情報が伝達される。入力層の入力と荷重との総和を中間層の入力として、(5)式に示されるシグモイド関数から [0~1] の範囲で中間層の出力が得られる。

$$f(x) = \frac{1}{1 + \exp(-x/u)}, \quad x = \sum I_i W_i + \theta \quad \dots (5)$$

ここで、 u はシグモイド関数の勾配を規定するパラメータで、 u が小さくなるに従い勾配が急になる。また、 I は入力データ、 W は荷重、 θ は閾値をそれぞれ示す。

入力層にある入力データを与え対とされる教師データと、ネットワークによる出力データ間の二乗誤差を計算し、その誤差が最小となるようバックプロパゲーション則に従い荷重、閾値の修正を行う⁵⁾。バックプロパゲーションでは、一般的にモーメント法が収束速度を高めるため多用されている⁶⁾。この方法は荷重修正を行う際、モーメント項と呼ばれる前回の荷重修正量を加えて修正が常に同じ方向で行われるようにする。学習回数 t 回目の荷重修正は(6)式のように示される。

$$\Delta W(t) = d + m \Delta W(t-1) \quad \dots (6)$$

ここで、 d は目標値と計算値の誤差からの修正量、 m はモーメント項のモーメント係数で、通常1以下の値が与えられる。本解析では $m = 0.6$ とする。 $\Delta W(t-1)$ は $t-1$ 回目の修正量を示す。閾値も同様の計算過程を経て閾値修正が行われる。ニューラルネットワークの学習は、要求される精度に到達した場合、又は指定された最大繰り返し回数の学習が終了するまで繰り返される。

3.2 ニューラルネットワークモデルの改良

(1) ボルツマン・マシンの法

ニューラルネットワークは、学習過程において関数の最小化と関係している。一般的に非線形系の場合、多くの極小値が存在するため、学習過程が収束したとき、これが最小値であるとは限らず、極小値の場合がある。従って、極小値を乗り越えるような扱いは必要不可欠となる。そこで本研究では、シグモイド関数における傾き u を学習回数に伴い変化させる後述の(7)式で示すボルツマン・マシンの法を取り入れる。この方法は、傾き u を大きくすると定常分布に達するまでの時間は短い、計算過程で最小値をとる確率が低く、逆に小さくすると、定常状態においては最小値をとる確率が高いが、定常状態に達するまでの時間が長くなるという問題を解決しようとするものである。従って、シグモイド関数の勾配は最初に急な状態から出発させ、時間とともに少しずつ勾配を緩やかにする。勾配の変化は(8)式に従う。

$$f(x, t) = \frac{1}{1 + \exp(-x/u(t))} \quad \dots (7)$$

$$u(t) = \frac{c}{\ln(\Delta t \cdot t) + 1} \quad \dots (8)$$

ここで、 $u(t)$ はシグモイド関数の勾配を規定する変数であり、 c は定数、 Δt はシグモイド関数の増加率、 t は繰り返し回数を表わす。また効率的に学習を行うためには、最適な Δt を決定する必要がある。図-2は、 Δt を変化させた場合の二乗誤差曲線を示す。図から Δt が0.1, 0.05の場合、ある学習回数を越えると二乗誤差が振動し、再び増加の傾向を示す。0.001の場合は学習回数100回を越えると、二乗誤差の減少が認められなくなる。本解析では $\Delta t = 0.01$ とする。

(2) 修正モーメント法

収束速度を高める方法として、(9)式に示す修正モーメント法を用いる。この方法は、はじめさまざまな方向の修正を行い、学習が進んだ後は前回の修正方向に近い方向で学習を早める方法である。モーメント法においては、モーメント項のモーメント係数 m が固定値であったのに対し、修正モーメント法の m は変数であり、学習が進むに連れて m の値を(10)式に従って増加させるものである。

$$\Delta W(t) = d + m(t) \Delta W(t-1) \quad \dots (9)$$

$$m(t) = m(1) + \Delta m \cdot t \quad \dots (10)$$

ここで、 $m(1)$ はモーメント係数の初期値、 Δm は増加率を表わす。本解析では、それぞれ0.6、0.02を与える。

(3) 中間ユニット数の決定

中間層のユニット数は、多すぎても少なすぎてもネットワークは収束しないが、中間層のユニット数を決定する有効な方法が存在しないため、試行錯誤によってユニット数を決定する。本解析では、入・出力層のユニット数576個の約4分の1である120個を中間層の初期ユニット数とし、30個ずつ増加させる。図-3は、各ユニット数に対する二乗誤差曲線を示す。図から、ユニット数の増加に伴い誤差が減少していることが認められる。最大の誤差減少率を持つ180個を中間層のユニット数とする。

表-1は誤差が、要求される精度到達に要される学習回数を比較したものである。モーメント法では3000回の学習回数が必要とされるのに対し、修正モーメント法とボルツマン・マシン法を用いた場合は10分の1以下の250回で収束が行われており、大幅に計算時間が短縮されていることが認められる。




図-2 シグモイド関数増加率の二乗誤差比較




図-3 中間素子数の二乗誤差比較

表-1 3手法の学習回数比較

手法	学習回数	二乗誤差
モーメント法	3000	10.6508
修正モーメント法	1000	10.5827
ボルツマン・マシン法 修正モーメント法	250	10.8869

4. 解析結果と考察

図-1に示されるような降雨パターン発生モデルにおいて、0min-60min, 20min-80min, …, 120min-180minを対として7組の降雨パターンを作成する。最初の6組をニューラルネットワークの学習用、最後の1組120min-180min降雨パターンを予測用とする。また、ネットワーク内で使用されるシグモイド関数は0、又は1付近で勾配がなだらかとなり学習が困難となるため、降雨パターンの各データは、最大値で割り[0~1]の値に変換した後さらに、[0.05~0.95]の範囲へ再変換し使用する。同様に、ネットワーク内においても0.05以下を0.05、0.95以上を0.95として出力する

ニューラルネットワークの入・出力素子数は、降雨モデルの1ドットを1データとする $24 \times 24 = 576$ 個とし、中間素子数180個、学習回数300回を経て荷重、閾値の最適同定を行った。この荷重、閾値を用いて120min経過モデルを入力パターンとし、180min経過モデルを目標パターンとして予測を行った。降雨セルをそれぞれ10、11個発生させた降雨パターンモデルを使用したもの予測結果を図-4に示す。各目標パターンと、予測パターンを比較すると強雨域の発生位置、範囲がほぼ一致しているのが認められる。

本研究の結果を以下にまとめる。

- (1) 降雨事象を確率的な数学的シミュレーションによって人工的に発生させた。
- (2) 降雨パターン発生モデルを用いて1時間後の降雨時・空間分布を予測するために従来のニューラルネットワークを改善させた。
- (3) 予測にニューラルネットワークを使用する場合、降雨過程の複雑な機構、多数のパラメータなどをあらかじめ把握する必要はない。
- (4) 修正モーメント法とボルツマン・マシーン法を組み合わせることによりネットワークの収束速度を大幅に速めることができる。

5. 結 び

本研究は、複雑な降雨場の予測に関するニューラルネットワークの有効性について検討する第一段階にすぎない。より精度の良い予測を行うためには多数の事例解析を行う必要がある。

謝辞

本研究を遂行に当たり、資料整理には本学4年目学生杉本幸三君のご協力を得た。記して感謝の意を表します。

参考文献

- 1) 安藤雪絵・藤間聡:ニューラルネットワークを用いたメソ・スケール降雨系の時・空間分布予測,土木学会第50回年次学術講演会,pp22-23,1994
- 2) 安藤雪絵・藤間聡:確率過程によるメソ・スケール降雨系のモデル化,土木学会北海道支部論文報告集,PP18-21,1995
- 3) 桐谷滋:ニューロコンピュータ,技術評論社,pp.63-84,1989
- 4) 合原一幸:ニューロ・ファジィ・カオス,オーム社,pp.41-46,1993
- 5) J. デイホフ,桂井浩訳:ニューラルネットワークアーキテクチャ入門,森北出版,pp62-80,1992
- 6) 前出5),pp81-82,1992

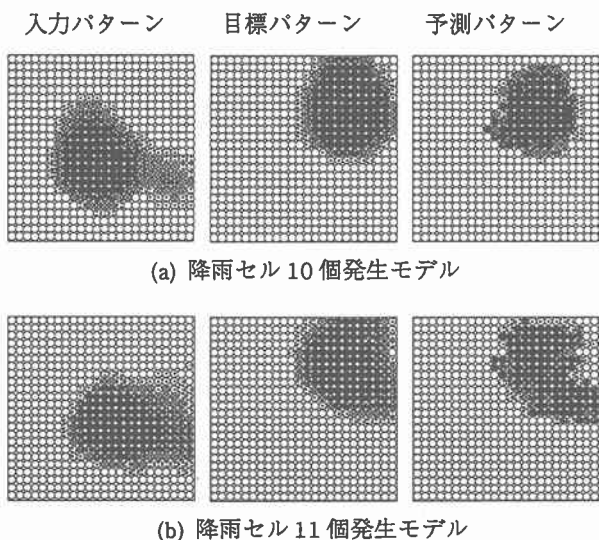


図-4 降雨域の時・空間予測モデル