

II-25 GMS-IRデータを用いたニューラルネットワークによる降雨量推定

長野県 正会員 池田元栄
山梨大学工学部 正会員 竹内邦良

1. はじめに

全球規模の降雨状況把握のために、衛星観測によるIR輝度温度と地上降雨量の関係を示すものとして、これまでにArkin(1979)、Arkin and Meisner(1987)らは、アフリカ・セネガル沖約800kmの洋上で行われたGATE実験の結果を用い、 $GPI=3Fc^t$ なる関係式を提案している。GPIはt時間(hr)の総雨量、Fcは当該メッシュ領域内IR放射輝度温度の閾値235K以下の部分の占める割合(冷雲量割合)である。本研究においてもまずタイ国チャオプラヤ流域において、1985.1.1~12.31のデータを用いてこのFcと降雨量の対応関係を調べた。その結果1°メッシュスケールにおいて10日単位のFcと降雨量の対応は決定係数で0.513とかなり良好なのに対して、日単位では決定係数が0.228と低く、回帰分析により日降雨量を推定することは困難であることが分かった。そこで本研究では日単位での降雨推定の精度向上を試みた。

上のFcによる回帰分析では、地上観測による降雨量データの最小単位が日であるため、衛星データは3時間単位で得られているにもかかわらず、これを日平均化して用いた。しかし降雨現象を判断するためには、1日8シーンあるヒストグラムの時系列変化を把握することが重要であると考えられる。そこで1つ1つのヒストグラムの情報をパターン認識して、推定降雨量を導き出すニューラルネットワークの導入を試み、1°メッシュ・日降雨量推定の精度の向上を目指した。

2. 地上降雨量及び衛星データ

本研究の対象領域であるタイ国チャオプラヤ流域は、北緯13.5°~20°、東経98°~101.5°に位置する。この流域内にあるRID(タイ王立灌漑局)管理の121降雨観測所の日雨量データを用いた。また衛星データは、気象衛星センターが作成した、3時間単位の0.25°メッシュGMS-IR基本ヒストグラムを用いた。このヒストグラムを1°メッシュスケールのヒストグラムに直し、各時間毎に冷雲量割合(Fc)、平均輝度温度(AV)、輝度温度の標準偏差(SD)を導出し説明変数とした。

ニューラルネットワークの適用にあたっては、検討期間を7~8月とし、検討メッシュについては1°メッシュ内の降雨観測地点が多く、回帰分析で対応の良かったメッシュ1つ(Nakhon Sawan下流地域)に限った。

3. ニューラルネットワークによる降雨量推定

62日のデータを1日おきに2つに分け、一方はネットワークを構築する学習用データ、もう一方は構築されたネットワークの精度を調べる検証用データとした。ここである日の降雨量を推定するに当たり、その日の衛星観測による8シーンと、前日半日分4シーンをあわせた12シーン(現地時間では前日の19時から翌日の4時まで)のIRヒストグラム、計36データを基準化して入力側のデータとした。またネットワークには3層の階層型ネットワークを用い、誤差逆伝播法によりそれを構築する。教師信号はメッシュ内平均日降雨量である。

誤差逆伝播法による学習経過を、中間層の数をパラメータとして示したのが図-1である。どの中間層の数に対してもかなり振動しているのが分かる。1万回の繰り返し計算によって得られたネットワークの精度を調べるために、検証用データを入力して得られた推定降雨量と実測降雨量との対応を示したのが図-2である。かなりばらつきが大きく有用なネットワークとはいえない。この理由の一つとして、ある入力に対して教師信号に合うように




図-1 36変数入力による学習経過

ネットワークを作り上げることはできるが、入力パターンが複雑すぎるため、ある値に近い値を出力してほしいとき、その近傍を出力するような柔軟なネットワークになっていないことが考えられる。

4. 成因分析法の導入

上述の問題点を解決する方法として、成因分析法を用いて36種類の観測変数間の内部従属性を解明し、入力情報の集約を試みた。36変数の相関行列の固有値 λ が1以上の6成分に加え、0.86以上の2成分を加えて、8成分を入力として選んだ。この8次元の変数は元の36次元の変数のうち、76%を説明し得るものである。この8成分の持つ意味は重要で、雲の時系列変化と密接な関係があると考えられる。1例として各時間毎のFcを主成分から第4成分までの座標に変換するベクトル(固有ベクトル)を図-3に示す。主成分ベクトルはどの時間のFcに対しても正の重みをつけるのに対し、第2成分ベクトルは36時間のうち前半の、前日の19時から当日の13時までのFcに対しては負、期間の後半の当日の16時から翌日の4時までのFcに対しては正の重みをつけるようなベクトルである。また第3成分ベクトルはFcに対して夕方から夜(16～19時)にかけて、第4成分ベクトルは日中(7～19時)にかけて正の重みをつけている。

この8成分を入力として降雨推定ネットワークを構築するわけだが、まず学習経過を図-4に示す。図-1と比べると、最終誤差は大きいが安定した学習状態であることが分かる。このネットワークを用いて検証期間の降雨推定を行った結果、中間層の数を11としたときの精度が最も高く、決定係数は0.507であった。

5. まとめ

ヒストグラムの時系列変化が重要であると考え、多変数による降雨量推定を行うためにニューラルネットワークを用いた。12シーンのFc、AV、SDを入力としてネットワークを構築し、推定降雨量を求め実測降雨量との




図-4 成因分析データ入力による学習経過




図-2 推定値と実測値の対応




図-3 Fcに対する4成分ベクトル




図-5 推定値と実測値の対応

対応を調べた結果、学習状態は良好であったのに対して、検証期間の実測値との対応は悪く、決定係数は0.383であった。そこで成因分析法を用いて入力情報の改良した結果、学習状態は悪いものの推定結果は向上がみられ、決定係数は0.507となった。

<参考文献>

1)Arkin, PA(1979): Monthly Weather Review, **107**, 1382-1387. 2)Arkin, PA and BN Meisner(1987): Monthly Weather Review, **115**, 51-74. 3)Takeuchi and Ikeda(1995): Proc. 2nd Conf. GEWEX/GAME, Pattaya, Thailand