

天気図情報を入力として用いたニューラルネットワークによる渇水期流入量の推定

岐阜工業高等専門学校 正員 鈴木正人
岐阜工業高等専門学校 学生 ○寺西寿弘

1. はじめに

近年頻発している渇水に対処するために水を安定かつ効率よく供給するには、既存の貯水池の効率的な運用が不可欠であろう。著者らは貯水池への流入量の推定が貯水池操作に有用な情報を与えるものと考え、ニューラルネットワークを用いた日流入量の推定を行ってきたが、1日先の流入量の推定精度は高いものの、数日先の流入量、特に雨が降った場合の推定精度は著しく劣っていた¹⁾。これは、降雨による流出のピークを推定できないことがその理由であり、改善策として未知である将来の降水量の代わりに、天気予報の情報をを用いて流入量の推定を行うことを試みた²⁾。しかし、天気予報そのものの的中率が低いこともあり、それほど推定精度は向上しなかった。そこで本研究では、天気予報の代わりに天気図から得られる情報をニューラルネットワークの入力に用いることで、その有効性を検証することを目的としている。

2. 対象データ

木曾川水系牧尾ダムの1981年～1990年の台風や梅雨の影響を受けない冬期(10月～翌年3月)の日流入量、日降水量を対象とした。また天気図情報は各日における午前9時の天気図より抽出した。

3. 天気図情報の抽出

用いた天気図は、日本列島を中心に、東経110度から160度、北緯20度から50度内を範囲としたものである。天気図中から低気圧、高気圧に着目し、その位置と大きさを抜き出した。具体的には、東経、北緯共に10度を3等分し、東経110度、北緯50度を(1,1)とする座標で表し、我が国の気象に直接的に影響を与えるであろう、東経160度、北緯20度を表す(15,9)までを対象範囲とし、気圧の位置を座標で表現し、抽出した。

4. 天気図情報と降水量との関係

得られた天気図情報が流入量推定に有効であるためには、天気図情報と牧尾ダム地点の降水量との間に何らかの関係が存在することが必要である。そこで、抜き出した天気図情報と天気図の当日、3日後、5日後の降水量との関係を検討した。具体的な手順としては、当日、3日後、5日後の降水量の大きさにより天気図を分類し、分類した天気図ごとに低気圧の位置、大きさの相対頻度分布を求め、降水量の大きさにより頻度分布の違いが出るか否かを検討した。

例として、当日の降水量と低気圧の位置との関係に対する結果を示す。図-1は無降雨時の低気圧の位置の相対頻度分布をもとに等高線表示したものである。また、図-2は降水量が5mm以上の場合の結果である。図中で色が濃い箇所ほど頻度が高い、つまり低気圧が存在する場合が多いことを表している。図-1から、無降雨時には低気圧が日本列島東側付近に存在する傾向があることが分かる。つまり、低気圧が日本列島東側付近に存在する場合は牧尾ダムでは雨が降りにくいことを表している。また、図-2からは、低気圧が、日本列島上または日本海に存在するときに5mm以上の雨が降る場合が多いことが確認される。なお、自明ではあるが、3日後、5日後、と期間が延びるにしたがって、降雨と気圧配置との関係は不明確になった。これらの結果は、一般にいわれている気圧配置と降雨の定性的な関係と一致するものであり、特に新しい知見が得られたわけではない。しかし、ニューラルネットワークでは天気図情報と降水量や流入量との定量的な対応づけを行うので、その前段階として今回の結果は意味があるものと考えている。なお、気圧の大きさについては、降雨との間にそれほど明確な関係は認められなかった。




図-1 無降雨時の低気圧位置頻度分布




図-2 5mm以上降雨時の低気圧位置頻度分布

5. ニューラルネットワークによる日流入量の推定

(1) 天気図情報の数値化 ニューラルネットワークへ天気図データと日流入量を入力するにあたり、これらを0から1の範囲で数値化する必要がある。本研究では各データの最大値と最小値がそれぞれ 0.9 0.1 となるようにデータの数値化を行った。天気図情報の場合、気圧の位置については、座標(1,1)~(15,9)を(0.1,0.1)~(0.9,0.9)に、また、気圧の大きさは、最低気圧 910hPa を 0.1 に、最高気圧 1056hPa を 0.9 になるように数値化した。なお、高気圧、低気圧のどちらか一方でも天気図中に存在しない場合は解析対象から除外した。このようなケースは全 1822 ケース中 350 ケースであった。

(2) ネットワークの構造および学習 ネットワークへは推定日より前5日間の日流入量・日降水量の計 10 個および天気図情報6個（低気圧、高気圧の大きさと位置）の計 16 個を入力として与えた。また出力は日流入量1個であるが、推定日として1日後、2日後、3日後の3通りを対象とした。例えば、12月1~5日の日流入量・日降水量および12月5日の天気図情報を入力とした場合には、12月6日、7日、8日の日流入量を出力させる（推定させる）ことになる。用いたネットワークは3階層型で、ユニット数は入力層が 16 個、出力層が1個、中間層が8個である。

つぎにネットワークの学習だが、既学習データの再現性を検討する場合は、全てのデータ教師信号として与えて学習させ、学習済みのネットワークからの出力値と教師信号との関係を検討した。学習の程度は教師信号とネットワークからの出力値との相対誤差（ $= | \text{教師信号} - \text{出力値} | \div \text{教師信号}$ ）の平均（10,9,8,7,6%の5段階）により判断し、学習の程度と推定精度との関係を調べた。なお、学習を 10 万回行っても所与の相対誤差まで収束しない場合には計算を打ち切った。また、未学習データの推定については、全てのデータを二つのグループに分け、一方のグループを教師信号として与えて学習させたネットワークにより、学習に用いなかったグループの日流入量を推定した。学習の程度は既学習データと同様に教師信号とネットワークからの出力値との相対誤差により判断した。

(3) 推定結果例 まず最初に既学習データについての結果例を示す。図-3 は、3 日後の日流入量についてネットワークからの出力と教師信号との関係を表したものである。図より、相対誤差が 9% まで学習させた場合の出力値は、教師信号にかかわらずいずれも 0.2 前後の値をとっており、ほとんど学習の効果がないことが分かる。一方、相対誤差 8% まで学習させた場合は、出力値と教師信号の関係が傾きが 1 の直線付近に分布するようになり、学習の効果が現れている。つまり、3 日後程度であれば、ニューラルネットワークにより天気図情報と流入量の関係づけが可能であると思われる。試みとして 5 日後の流入量についても計算を行ったが今回用いたネットワークでは学習を収束させることができなかった。

つぎに、未学習データについて、各学習段階における推定値と実データとの相対誤差（ $= | \text{実データ} - \text{推定値} | \div \text{実データ}$ ）の平均値と最大値をそれぞれ表-1、2に示す。表中で値が記入されていない箇所は 10 万回学習させても収束しなかったことを表している。表より、相対誤差の平均については、3 日後の場合には学習が進むほど減少する、すなわち推定精度が上がっているが、1 日後、2 日後の場合は、それほど精度が上がっているわけではない。また、1、2、3 日後とも、学習が進むと相対誤差の最大値は大きくなっている。このような結果が得られた原因として、学習が進むと過学習により推定精度が極端に悪い出力値が出現することが考えられる。本研究では、全データの半分を教師信号として与え、残り半分为未知と仮定して計算を行ったが、より多くのバリエーション豊かな教師信号を与えることにより未学習データの推定に関しても、より精度の高いネットワークを構築することが可能であると思われる。

参考文献

- 鈴木正人・長尾正志：リカレント型ニューラルネットワークによる渇水期日流入量系列の推定精度の研究、水工学論文集第 40 巻、pp.353-358,1996.
- 鈴木正人・長尾正志・福元敦：天気予報を用いたニューラルネットワークによる渇水期流量の推定、土木学会第 52 回年次学術講演会第 II 部、pp.308-309,1997.




図-3 既学習データの再現性

表-1 各学習段階における出力値の相対誤差の平均値

	10%	9%	8%	7%	6%
1日後	0.0688	0.0687	0.0664	0.0678	0.0686
2日後	0.0697	0.0696	0.0696	0.0651	-
3日後	0.4094	0.4094	0.1350	-	-

表-2 各学習段階における出力値の相対誤差の最大値

	10%	9%	8%	7%	6%
1日後	0.7678	0.7676	0.7675	1.3304	1.5996
2日後	0.7533	0.7533	0.7533	1.3754	-
3日後	0.9726	0.9723	2.8989	-	-