

CS-151

ニューラルネットワークによる流速係数の推定問題

東京都立大学工学部 正会員 稲 貝 とよの
東京都立大学工学部 正会員 小 泉 明

1. はじめに

水道の普及率が90%を越えた今日、都市に於ける配水管網は大規模で複雑化しており、水量と水質の両面について安定した水供給を行うために、日々の配水コントロールが重要な課題となっている。一般に配水管網における流況の把握は、面的に分布する実際の管網施設を集約・簡略化し、ノードとリンクから成るネットワークグラフに置き換えた上で、節点エネルギー位法等を用いた管網解析により求めている。しかし、管網施設のデータベース化が十分でない地域も多く、このような管網解析の計算値は、水使用変動を伴う実フィールドでの測定値とは必ずしも一致していない。

そこで本稿では、配水管網を多入力多出力システムと考え、入出力関数の逆問題をニューラルネットワークとして作成し、未知パラメータの推定を試みる。すなわち、一部の管路について流速係数が未知である口型管網を一例として取り上げ、従来の管網計算結果を教師データとして学習を行いニューロモデルを作成する。さらに、仮想測定値を得られたニューラルネットワークに入力し、モデルの精度を検証する。

2. ニューラルネットワークモデルの設定

階層型ニューラルネットワークは写像ネットワークとして工学的に広く利用されており、望ましい入力信号と出力信号の対からなる教師データセットを与えることにより、内在する写像関係を模擬するようシナプス荷重を学習可能であるといわれている。また最近、不静定構造問題、複合材料、欠陥同定等にも適用され、逆問題を直接解析的に解けない場合や入力パラメータの一部が測定不能場合に利用されている。

ここでは配水池1と4つの節点から成る口型配水管網（図-1、表-1）を考える。このとき節点4の有効水頭は、各節点の配水量および各管路の流量特性パラメータ（管路長 L 、管径 D 、流速係数 C ）により決定される。通常、配水管路の流速係数は、管材料および内部のライニングによりある値を有するとされるが、共用開始後は沈殿物の付着等によりその値が変化する。いま、管路25の流速係数が未知であり、節点5の配水量（ q_5 ）以外は常時一定と仮定する。このとき配水池流出水量（ Q ）と節点4の有効水頭（ E_4 ）を入力層、管路25の流速係数（ C_4 ）を出力層とするニューラルネットワークモデルを設定して未知パラメータを推定する。

標準ケースとして、 C_4 を5条件、 $Q(q_5)$ を5条件組み合わせで計25条件について従来法による管網計算を行い、教師データを作成した。本モデルの入出力関係は図-2に示すように非線型な曲面を形成しており、ニューラルネットワークの学習とは25個の格子点（教師データ）から曲面を認識することを意味している。




図-1 口型配水管網

表-1 管路および節点データ

管路番号	管路長 L (m)	管径 D (mm)	流速係数 C	節点番号	配水量 q (ℓ/sec)
23	300	350	100	2	0
34	500	250	100	3	200
45	700	300	100	4	150
25	900	400	未知	5	変化




図-2 教師データにおける入出力関係

3. シナプス荷重の学習

流速係数の推定モデルを作成するため、ユニットの応答関数にシグモイド関数を用い、学習には局所最適の谷に落ち込むことが少ないといわれているカルマン・ニューロ法¹⁾を用いてシナプス荷重を学習する。

まず、ニューラルネットワーク構造を選定するため、入力層（2ユニット）、中間層（2ユニット）、出力層（1ユニット）から成る3層モデルを基本として、中間層のユニット数を増やした場合と、ユニット数はそのまま中間層数を増やした場合について、それぞれ300回の学習を行い学習後の残差平方和を比較する。この結果、中間層3層2ユニットモデルが誤差平方和最小となった（図-3）。

また3層2ユニットモデルの学習過程を検討したところ、70回付近で誤差平方和の急激な減少がみられ、その後微減に転じている。シナプス荷重値は150回以降ほぼ一定となっており、十分な学習が行われていると考えられた。

つぎに教師データ数が学習効果に及ぼす影響を検討するため、上記の25データに加え、教師データが15（Qを3条件）および45（Qを9条件）の場合についてもニューラルネットワークモデルを作成した。学習後の相対誤差を求め、その絶対値の平均値および標準偏差を表-2に示す。3つのモデル間で学習誤差の差異はほとんど現れていない。教師データと学習後のニューラルネットワーク出力との比較からも、得られたモデルは口型管網の入出力関係を十分に近似していると判断された。

4. 流速係数の推定

最後に、3.で得られたニューラルネットワークを用いて流速係数を推定する。本来は、実フィールドでの測定値（ Q 、 E_d ）を学習済みモデルに入力すると、未知の流速係数を推定できることになるわけであるが、本稿では、仮想測定値（従来法による計算値）を用いてニューラルネットワークの精度を検討する。


このため、3つの学習済みニューラルネットワークを用いて、ランダムに設定した入力値15組に対する出力を計算した。得られた流速係数推定値と、従来法による計算値との差（推定誤差）を、図-4に示す。教師データを25および45で学習させたケースでは、流速係数の推定誤差がほぼ±5%以内に収まっているのに対し、教師データが15のケースでは推定誤差が非常にばらついている。これは、教師データが少ない場合、未学習の入力に対し必ずしも十分な出力が保証されないことを意味している。

5. おわりに

本稿では、配水管網内に流速係数が未知の管路を含む場合について、階層型ニューラルネットワークモデルの適用を提案した。すなわち、口型管網を例に学習条件の検討を行い、中間層3層2ユニットモデルを用いて、カルマン・ニューロ法により300回程度の学習を行えば、有効水頭および配水池流出水量と流速係数との非線形な関係をモデル化できることが分った。また、流量の変動域に関する教師データの設定方法が、流速係数の推定精度に影響を及ぼすことを明らかにした。

今後、複雑な配水管網に於いて、複数の管路の流速係数が未知の場合についても、ニューラルネットワークの適用方法を継続研究していきたいと考えている。

【参考文献】 1) 村瀬治比古・小山修平・石田良平：カルマン・ニューロコンピューティング，森北出版，1994



（注）図中のラベルは「中間層数-ユニット数」を示す

図-3 ニューラルネットワーク構造による差異

表-2 学習誤差の比較

ケース	誤差	相対誤差(%)	
		平均値	標準偏差
25 教師データ		2.89	2.14
15 教師データ		3.30	2.05
45 教師データ		2.70	1.72




図-4 教師データ数と推定誤差