

ニューラルネットワークによる残留塩素濃度の年間モデルに関する一考察

東京都立大学大学院	正会員	稲員とよの
東京都立大学大学院	フェロー	小泉 明
東京都立大学大学院	学生員	杉本 互
(株)日水コン	正会員	沼田 篤男

1. はじめに

上水道は高普及率の時代を迎え、需要者からのニーズは高水準化、多様化しており、「安全でおいしい水」を供給するためのきめ細やかなサービスが求められている。なかでも、残留塩素（以下残塩）は嗜好面・安全面への影響が大きく、配水地域内なるべく一様な濃度に低減するための残塩濃度管理が重要となるが、送配水過程において残塩は種々の物質と反応するため、時間的・空間的な濃度変化を把握することが難しい。筆者らは、これまでに ANN（Artificial Neural Network）を用いた残塩濃度シミュレーションモデルを提案し、数日の短期的推定と予測検証において高い精度を得ている^{1,2)}。本研究では、年間を通した残塩濃度管理に供するため、配水池・水質管理点間の濃度変化を記述可能な年間モデルの開発を試みるものである。

2. 対象地域とモデル化の手順

対象地域である H 市送配水管網は、市中心部に位置するループ状の送水管を中心に複雑な送配水ネットワークを形成している。配水池である T 地点と、送配水管網中間点として水質管理データを測定している H 地点の間に追塩設備はなく、水温 15 以上の夏期（6～10 月）と、水温 15 未満の冬期（11～5 月）で、配水池出口における目標残塩濃度の設定を変更する経験的な管理方法を採用している。

そこで、この 2 地点間の送配水管網による影響をブラックボックスとして捉え、T 地点における残塩濃度（以下残塩入力）と H 地点における残塩濃度（以下残塩出力）の入出力関係を記述する ANN モデルについて検討を行った。モデル化の手順を図 1 に示す。なお、使用データは 2002 年 7 月～2003 年 5 月における時間測定フィールドデータを用いた。

3. 学習日の選択と入力要因の設定

まず、年間を通した残塩変動をシミュレートするため、ANN の特性を考慮し、水需要や自然環境における種々の条件を代表するように離散的に学習日を選択した。また、平日と平日以外では水需要の変動が異なっており残塩消費もこの影響を受けるものと考えられるため、平日と平日以外について、それぞれ配水量、残塩濃度、水温の最大日及び最小日を検索し、表 1 に示す計 16 日を選出した。

次に、相互相関分析を行った。管網内の物理的現象として、入力残塩は T 地点から H 地点に滞留時間分の時間遅れを伴うが、水需要量の季節変動より時間遅れの程度も月によって異なると考えられることから、残塩入力と残塩出力の相互相関分析を毎月と年間で行うこととした。この結果得られた相互相関コログラムを図 2 に示す。平均的遅れ時間として、図中の相互相関係数が最大となるラグを表 2 に示す。これらの結果より夏季から冬季に移行するにつれて滞留時間の増加が確認され、平均 16 時間の遅れがあると考えられる。また、7～10 月でコログラムの形状が類似していることに対し、11～5 月では形状が異なっており、夏期と冬期では残塩消費の傾向に差異があると考えられる。とくに、1 月と 2 月においては、

表 1 学習日の選択結果

		平日(月～金)	平日以外
低区配水量 (日総量)	max	53630 (8/21)	43460 (7/21)
	min	16640 (11/9)	16140 (11/23)
八太郎配水量 (日総量)	max	2010 (7/26)	1166 (11/4)
	min	928 (1/3)	721 (5/25)
低区残塩 (日平均)	max	0.85 (8/14)	0.80 (8/18)
	min	0.47 (3/24)	0.51 (3/21)
八太郎水温 (日平均)	max	21.7 (8/10)	20.9 (8/4)
	min	1.7 (1/16)	1.8 (1/12)




図 1 モデル作成手順

キーワード 送配水系、ニューラルネットワーク、残留塩素消費、時間変動、相互相関分析

連絡先 〒192-0397 東京都八王子市南大沢 1-1 TEL 0426-77-2789

夏期と比較して残塩濃度の変動が小さいことから、コレログラムは緩やかな形状を示している。

以上より、入出力残塩間の時間遅れが 11~20 時間であることから、この 10 要因を入力要因として採用する。さらに、年間平均で 16 時間の時間遅れがあると推定されるため、16 時間前の T 地点流量、同時刻での H 地点流量及び同時刻での H 地点水温の 3 データを入力要因として追加した。以上より、中間層 2 層階層型 ANN により、13-6-6-1 の構造で学習を行うこととした。

4. 学習と検証結果

ここでは、過学習を避けるために許容誤差を 2% 程度と設定した上で学習を行った。得られた学習経過 (10 回毎) を用い、日単位の誤差平方和及び日単位の絶対誤差平均値を求め、学習日内で各々の指標の最大値をもって対応する学習回数を代表する指標値とした。さらに、学習回数毎の最大誤差も求めた。そして、許容誤差を満足する学習回数の中で、各指標について最小となる学習回数に対応する ANN モデル (3 ケース) をそれぞれ選択することで、各日における学習精度の偏りを最小とした。これにより選ばれた 3 ケースのモデルを用いて検証を行い、各々の検証時系列図から判断して最良のモデルを選択することとする。検証は、学習に用いていない月の中から水温が高く、残塩消費の大きい 9 月 8 日~9 月 14 日の 1 週間とした。

3 ケースの検証結果より、最大誤差が最小となるモデルを選択し、学習及び検証精度を表 3 に示す。学習精度については平均絶対誤差 0.009mg/L、平均相対誤差 2.01%、重相関係数 0.98 と高い精度を示しており、離散データを用いても学習に影響しないことが分かる。つぎに、検証精度については多少学習結果より劣るものの平均的には十分な再現精度が得られている。図 3 の検証時系列図より、9 月 9 日において早朝の残塩濃度の低下に対して ANN モデルが追従できていない部分があるが、この理由は前日の日曜日が平日より流量が低下しているためであると判断している。全体としては、年間で 16 日の学習データを用いたモデルにより、未学習の入出力関係を再現可能なモデルを得ることができたと考えている。

5. おわりに

本稿では、複雑なネットワークにおける水質管理点の残塩濃度を把握するため、入力データの最大日及び最小日を離散的に選択して学習に取り入れることで、年間モデルの作成を試みた。まず、相互相関分析を行って、時間遅れを考慮した入力要因を設定した。そして、ANN の学習過程を検討し、学習精度の偏りが小さいモデルを選択して、連続データによる検証を試みた。その結果、平均絶対誤差 0.014mg/L、平均相対誤差 3.18%、最大誤差 0.070mg/L と再現性の良いモデルを得ることができた。提案したモデルは、学習日の選択において平日と休日を考慮したものであるが、さらに入力要因について精査した上で、配水池における残塩管理方法について検討して行きたい。

【参考文献】

- 1) 稲員とよの・小泉明：配水管網における残留塩素濃度推定に関するニューラルネットワークの応用、水道協会雑誌、Vol71, No.8, pp.1~10 (2002)
- 2) 稲員とよの・小泉明・杉本互・沼田篤男・坂本宗陽：ANN モデルによる残留塩素濃度の推定に関する一考察、土木学会第 59 回年次学術講演会、第 部門、pp31~32. (2004)




図2 相互相関コレログラム

表2 相互相関分析結果

月	年間	7月	8月	9月	10月	11月	12月	1月	2月	3月	4月	5月
ラグ	16	16	16	17	20	19	19	13	19	16	11	15

表3 学習及び検証精度

指標	学習精度	検証精度
残差平方和	0.0488	0.0590
残差分散	0.0001	0.0004
重相関係数 R	0.98	0.83
平均相対誤差 (%)	2.01	3.18
平均絶対誤差 (mg/L)	0.0089	0.014
最大誤差 (mg/L)	0.0348	0.070




図3 検証結果