

ニューラルネットワークによる配水管網の水質モデル

Water Quality Model for Distribution Systems by Neural Networks

稲員 とよの* ・ ○ 小幡 晋*** ・ 小泉 明** ・ 榊原 康***

Toyono INAKAZU*, Shin OBATA***, Akira KOIZUMI**, Yasuyuki SAKAKIBARA***

ABSTRACT; Recently, managing water quality in distribution pipes has become an important subject for water supply systems. However, it is very difficult to grasp the spatial and hourly fluctuation of residual chlorine concentration which is important for water quality. This paper presents the modeling process for determining residual chlorine concentration in a water distribution network. First, the modeling methodology which we propose in this paper is presented. Regarding a water distribution network as a black box system, we make a water quality simulation model by neural networks. Our model includes the time lag between the input point and the output point. Second, we show the modeling process. This process consists of choosing input points and output points, pre-analysis for neural network structure, modeling, and estimation for results of the model. Third, we apply the modeling process to the actual distribution network as a case study, which proved that our model worked well. Our proposed modeling process can be applied in all seasons and at various places. Therefore, it will be a very useful tool for water quality management.

KEYWORDS; water quality management, neural networks, simulation model, residual chlorine concentration, water distribution network

1. はじめに

近年、安全でおいしい水への要望が高まっている。水道システムにおける水質問題は、原水の水質監視と浄水場での水質管理が中心であったが、最近では送配水管路内における水質管理が注目されている。特に、給水サービスの公平性の視点より、配水管網内の残留塩素濃度をなるべく均一にするための様々な対応策が試みられている。塩素は安価で簡易な消毒剤として広く利用されているが、比較的不安定な化学物質であり、有機物質、鉄やマンガンなど様々な物質と反応するため、滞留とともに管内の残留塩素は消費される。また、水使用量の減少や水圧低下により停滞水が発生したり、配水管が老朽化している場合にも、残留塩素濃度は低下する。一方、過剰な残留塩素は、水道管の腐食の原因となり、味や臭いの点でも問題となる。このため、配水管網内各所において、消毒の効果を維持可能な範囲で残留塩素濃度を低く管理することが、日常的な運転における重要な課題となっている。

一般に、配水管網はループを含むネットワークを形成しており、管網内の流況は水需要の変動に応じて絶えず変化しているといえる。さらに塩素反応の多様性が加わり、残留塩素濃度の空間的及び時間的な変化を把握することは非常に複雑な問題となる。一方、配水管網内における残留塩素濃度の日常的な測定は、まだ

* 東京都立大学大学院工学研究科助教授

Associate Professor, Tokyo Metropolitan University

** 東京都立大学大学院工学研究科教授

Professor, Tokyo Metropolitan University

*** 東京都立大学大学院工学研究科

Graduate Student, Tokyo Metropolitan University

十分とは言えず、消火栓に濃度センサーを設置して測定可能なものの、毎日のメンテナンスが必要であり、多大な労力と費用を要することとなる。

そこで本論文では、配水管網をブラックボックスの水輸送・水質変換システムとして捉え、残留塩素濃度の動的挙動を記述するため、ニューラルネットワークの適用を提案する。すなわち、水質管理上のキーポイントとなる地点における残留塩素濃度時系列を出力とし、配水池出口あるいはそれに代わる点のデータ時系列を入力とするモデルの作成を試みる。実用的には、管網内の水圧を逐次制御する際のような厳密な定量モデルというよりは、水質の向上・安定化のために運転管理方法を変更（例えば、後塩素処理施設の追加や配水池での滞留時間の管理等）する際に、計画代替案を評価するための残留塩素濃度予測シミュレーションモデルを想定している。

以下、2. では、配水管網水質シミュレーションについて本論文におけるモデル化の基本的な考え方を明らかにし、ニューラルネットワークを用いたモデル化プロセスを提案する。3. ではケーススタディとして、対象とする配水管網の入出力関係を反映するニューラルネットワーク構造の予備分析を行う。さらに、4. では、残留塩素濃度の時間変化を学習及び検証して、得られた予測シミュレーションモデルを評価する。

2. モデル化の基本的な考え方

配水管網において、水需要量の時々刻々の変動によって生ずる、水道水質の時間変化を記述可能なモデルを動的な水質モデルと呼ぶ¹⁾。一般に、配水管網は主要な配水管をリンクとし、配水管の接合点、配水池、配水ポンプなどをノードとするネットワーク²⁾として表される。このとき、管網内の流況と各リンクにおける流速を記述する水理モデルと、水道水中の着目物質の濃度変化を記述する水質モデルが必要となる。このための既存モデルとしては、米国EPAの配水管網シミュレーションモデル（EPANET）が知られている。EPANETは、指定された微小時間間隔 Δt 内で需要量と流入量が一定であると仮定した擬似動的モデルであり、最初に水理計算を行って流速を求め、サブノード間の滞留時間が各時間ステップ（ Δt ）と等しくなるように各リンクをサブノードにより等分割して、ノード及びサブノードにおける物質濃度を上流側から順次求めていくという水質モデルを用いている。各時間およびサブノード間の水質変化は、移流による濃度変化と反応による濃度変化を考慮した物質収支より、次式[1]となる。

$$\frac{\partial c_i}{\partial t} = -u_i \frac{\partial c_i}{\partial x_i} - R \quad \dots\dots\dots [1]$$

ただし、 c_i ：物質濃度、 t ：時間、 u_i ：管内流速、 x_i ：管方向の距離、

R ：反応による物質濃度減少速度

なお、複数のリンクが合流または分流するノードについては、完全混合を仮定したモデルとなっている¹⁾³⁾。

ところで、配水管網内の反応による塩素消費は、水道水塊中の塩素と有機及び無機物質の反応によるもの、管壁の生物膜による消費、腐食過程での消費、物質濃度差による分子拡散など様々な要因の影響を受けている。例えば、水塊中の塩素消費および管壁面に関する塩素消費を1次反応と考えるモデルの場合、[1]式は、

$$\frac{\partial c_i}{\partial t} = -u_i \frac{\partial c_i}{\partial x_i} - K_i c_i, \quad K_i = k_b + \frac{k_w k_f}{r_{h_i} (k_w + k_f)} \quad \dots\dots\dots [2]$$

ただし、 K_i ：総括減少係数、 k_b ：水塊中の塩素減少係数、 k_w ：管壁面単位長さ当りの塩素減少係数、 k_f ：物質移動係数、 r_{h_i} ：管の水理学的半径

となる⁴⁾。一方、管壁面に関する塩素消費を0次反応と考える場合は、

$$\frac{\partial c_i}{\partial t} = -u_i \frac{\partial c_i}{\partial x_i} - k_b c_i - \min \left(\frac{k_w}{r_{h_i}}, \frac{k_f c_i}{r_{h_i}} \right) \quad \dots\dots\dots [3]$$

となるモデルが提案されている⁵⁾。

これらのモデル中の反応速度定数 k は、通常、室内またはフィールド実験より推定されるが、実際の配水

管網においては、原水水質、管口径、管内面の状態、水温等に依存し、各管路毎に異なる値となり、経時的にも値が変化するものと考えられる。さらに、面的に広がっている配水管網に対し、ネットワークとして簡略化を行っているため、複数管路網の塩素減少を総括的に評価した反応速度定数をモデルに組込む必要がある。このため、実管網にEPANETモデルを同定するには多大な労力と時間が必要となる。

そこで、本論文では日常的な配水管理に利用できる簡易な水質モデルを得るため、配水管網をブラックボックスと見做し、非線形な入出力関係を記述可能なニューラルネットワークモデルを適用して、残留塩素濃度の空間及び経時変化の記述を試みる。ニューラルネットワークは、人間の知能における情報伝達を模範として、神経細胞（ニューロン）をモデル化した「ユニット」を数多く繋ぎ合わせたモデルである。モデルへの入力信号は、各ユニットへの結合・変換出力を繰り返しながら伝達されていき、最終的なモデル出力が得られる。中でも階層型ネットワークは、図1に示すように、入力層から、中間層を経て、出力層へ一方通行で情報が伝達されるモデルである。ユニット間の結合の強さは「シナプス荷重」としてモデル化され、最初ランダムに設定された各荷重が、入力信号と出力信号の対（教師データ）を学習するにつれて、入出力関係を近似的に再現するようになる。教師データには、数値・非数値、連続値・離散値のいずれが含まれていても良く、入出力間の一般的な非線型関係を表現可能とされている^{9),7)}。

先に列挙した塩素減少係数を左右する要因の内、管口径及び管内面は場所による空間的变化が大きい要因である。これに対し、水温と原水水質は、空間的にはほぼ一定と見なせるが、長期タームで経時的に塩素減少係数に影響を与えると考えられる⁹⁾。ここでは、数日程度のフィールド測定によるモデル作成を想定しているため、水温と原水水質については、対象期間中、対象管網内で一定と仮定する。一方、管口径及び管内面の影響については、ニューラルネットワークの学習によりシナプス荷重として推定され则认为^{9),10)}。これより、着目点の残留塩素濃度を出力するため、管網システムへの入力に当たる配水量と入力残留塩素濃度をニューラルネットワークの入力層に用いることとする。

ニューラルネットワークによるモデル化のプロセスを図2に示す。まず、水質管理上のキーポイントとなる地点を、フィールド測定または配水管網の静的解析により把握し、ニューラルネットワークの入力層と出力層に含める地点を決定する。追加塩素注入装置の設置や、配水池の滞留時間の管理を検討する場合には、それらの地点も対象となる。次に、入出力間の非線形性を表現するための中間層の構造と、選択された入出力地点間の滞留時間による時間差をどの程度考




図1 階層型ニューラルネットワークモデル




図2 モデル化のプロセス

慮したら良いか（入力要素の候補）を、ニューラルネットワークの学習を用いて検討する。以上の予備分析により、ニューラルネットワークの基本構造が決定するので、さらに、教師データによる学習と検証用データ（未学習データ）による予測シミュレーションを行なって、最終的なモデルを評価する。以上がモデル化の基本的な流れであるが、以下、3. で予備分析、4. で学習と検証について、ケーススタディを通して具体的に示す。

3. ニューラルネットワーク構造の予備分析

(1) 対象地域について

ケーススタディの対象とするのは、給水人口約 20 万人、給水区域約 120 km²、一日平均給水量約 6 万 m³/日という、工業地帯の一画に位置する、周辺の大都市に対するベッドタウン的な特徴も有した、中規模の地方都市である。

図 3 に配水管網の概略図を示す。No.6 が配水池出口であり、管網全体としては、主要管路によりおよそ 3 本のルートで構成されていると捉えることができる。図中に記された数値は、この主要 3 ルートにおける推定最大滞留時間




図 3 対象とする配水管網

であり、先に述べた EPANET を用いて算出された値である。管網末端部に当たる No.1 は対象管網内で残留塩素濃度が最低値を示す地点であり、水質管理の最重要ポイントと考えて選択する。No.1 が基準値を維持していれば、管網内の全区域において、必要な残留塩素濃度が確保されると経験的に判断できる。No.3 は今のところ No.1 より高い値が測定されているが、最長幹線の末端の点であるため分析の対象とする（ルート 3）。また、No.4→No.2（ルート 2）は短い幹線であるが、他のルートとの比較のため、今回はモデル化の対象に追加した。

使用するデータは、各測定地点で測定された残留塩素濃度[mg/L]の時系列データ、及び配水池からの時間配水量[m³/hour]である。測定期間は初夏の 6 日間で、測定間隔は 1 時間である。この 6 日間の内、前半 4 日間をシナプス荷重値の学習に用いる教師データ期間、後半 2 日間を予測シミュレーションのための検証用データ期間とするが、時間遅れの考慮に際して数時間前までのデータを入力ユニットに用いることから、教師出力の対象期間は 2～4 日目の 3 日間で 72 データとなる。

(2) 中間層構造の検討

ニューラルネットワーク構造の予備分析として、まず、中間層構造の検討を行う。中間層は階層型ネットワークの入力層と出力層とを繋ぐ、文字通りネットワークの中間に位置するユニットの集まりである。過去の研究結果^{10),11)}から、中間層が 1 層だけでは複雑な入出力関係に対応できず、少なくとも 2 層以上は必要であることが分かっている。また、逆に過大な中間層構造にした場合も、モデルの未知数であるシナプス荷重の総数が飛躍的に増加するため、学習に要する計算時間が 2 次関数的に増大するが、必ずしも良い精度のモデルとはなり得ない。このような点を踏まえた上で、今回の学習データ数や出力ユニット数等を考慮し、3 層 4 ユニットの中間層を採用した。

(3) 時間遅れの検討

次に、入出力地点間の時間遅れ（時間差）について検討する。配水管網内のある 2 地点間の関係を考えると、その間には必ず水の滞留時間が存在している（図 3）。このため、入力地点の情報は、滞留時間分の時

時間遅れを経て出力地点に影響を及ぼす。今回、モデルには残留塩素濃度と配水量という2種類の入力要因を用いるのであるが、出力地点と同時点のデータのみを入力要素として用いるだけでは、この時間遅れを考慮できないことになり、何らかの方法で過去のデータも入力に組み入れる必要があると思われる。しかし、任意の2地点間の滞留時間を正確に測定することは困難な上に、そもそも滞留時間は、昼間の水使用量の多い時間帯には短く、夜間のように水使用量の少ない時間帯には長くなるというように、管内流量（配水量）に伴って絶えず変動している。従って、たとえ滞留時間の変動を把握できたとしても、ある一定の時間遅れデータのみを入力要素として設定するだけでは不十分であり、数時間前までのデータを複数並列して入力する必要があると思われる。

そこで、まずルート1を対象として、残留塩素濃度($X_{4,j}$)と配水量($Q_{t,j}$)の同時点から12時間前まで($j=0,1,2,\dots,12$)のデータを単独1入力として入力層に用い、出力地点(No.1)の残留塩素濃度($Y_{1,j}$)を出力層とするニューラルネットワークの学習を全26ケースについて行った。学習精度の高いモデルの入力要素は、出力に対して強く影響しているものと考え、300回学習の後、実測値とモデル出力値との相関係数である重相関係数 R を求めた結果が図4である。 R は次式[4]によって定義される。




図4 時間遅れの検討結果

$$R = \frac{\sum_{i=1}^n (Y_i - \bar{Y})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad \dots\dots\dots [4]$$

ただし、 Y_i : 実測値、 $\bar{Y}$: Y の平均値、 y_i : モデル出力値、 $\bar{y}$: y の平均値、 n : データ数

図4より残留塩素濃度、配水量のどちらも、1～3時間前を入力要素として用いたモデルは、同時点の値を入力としたモデルより R 値が高く、出力への時間遅れを伴った影響が現れている。これは図3で示した、2.4時間というルート1のEPANETによる推定最大滞留時間と、概ね合致した結果となっている。

4. 残留塩素濃度モデルの学習と検証

(1) モデルの作成と評価

3. で行った時間遅れの検討結果を参考に、入力要素を組み合わせた計5ケースを表1のように設定した。いずれのケースでも同時点残留塩素濃度を入力要素に採用していないが、これは物質としての残留塩素が瞬間的に移動することはないという、物理的な意味合いを考慮したことによるものである。

表1 モデル入力要素の設定

出力: $Y_{1,t}$	入力		入力数
	配水量(Q)	残留塩素濃度(X_4)	
Case 1.1	Q_t		1入力
Case 1.2	Q_t, Q_{t-1}	$X_{4,t-1}$	3入力
Case 1.3	Q_t, Q_{t-1}, Q_{t-2}	$X_{4,t-1}, X_{4,t-2}$	5入力
Case 1.4	$Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3}$	$X_{4,t-1}, X_{4,t-2}, X_{4,t-3}$	7入力
Case 1.5	$Q_t, Q_{t-1}, Q_{t-2}, Q_{t-3}, Q_{t-4}$	$X_{4,t-1}, X_{4,t-2}, X_{4,t-3}, X_{4,t-4}$	9入力

全5ケースに対して学習用データを用いた1000回の学習を行い、得られた学習済みニューラルネットワークモデルに検証用データを入力して、残留塩素濃度の予測シミュレーションを行った。各モデルの出力結果から、実測値とモデル出力値との残差絶対値の最大値である最大誤差[mg/L]をそれぞれ求め、この値の大小によってモデルの精度を定量的に評価する。ここで平均誤差（残差絶対値の平均値）ではなく最大誤差を用

いるのは、モデルの最もクリティカルな側を重視するためである。

全ケースの学習及び検証精度を最大誤差で示したものが表2である。一般に、ニューラルネットワークモデルは、学習に用いた教師データの入出力関係を記述する点では十分な推定精度を示し得るものの、未学習データに関する再現性については同様な精度が保証されるとは限らず、学習精度の高いモデルが一概に優れているとは言い切れない^{9),10)}。今回のケースについても、学習精度は入力数の増加とともにほぼ確実に向上するのに対し、検証精度では、そのような特性は必ずしも認められない。そこで、モデルによる再現性を重視し、基本的には検証精度の最も良いモデルを選択する。表2から各モデルを比較すると、Case 1.2～Case 1.4が検証精度において同程度に優れているので、中央のCase 1.3（5入力）のモデルをルート1における最良モデルとして選択した。そのCase 1.3の学習結果及び検証結果時系列を図5に示す。時系列としての実測値とモデル出力値との適合性は高く、選択した最良モデルは定性的に見ても、残留塩素濃度の変動を高い精度で予測可能なモデルであるといえる。

表2 ルート1の各モデル精度

出力:Y1 _t	入力数	学習結果	検証結果
Case 1.1	1入力	0.09	0.15
Case 1.2	3入力	0.06	0.11
Case 1.3	5入力	0.06	0.11
Case 1.4	7入力	0.05	0.11
Case 1.5	9入力	0.04	0.18

(単位:mg/L)





図5 ルート1の学習・検証結果時系列

(2) 他のルートにおけるケーススタディ

本論文のモデル化プロセスが、他の入出力地点でも適用可能であるかを検討するために、図3で示した対象管網の、残りの2本のルートにおけるモデル化を試みる。

ルート2は入力要素の組み合わせがルート1と同様な5ケース、ルート3は推定滞留時間が長いことを考慮して6ケースを設定し、ネットワークの学習と検証を行った。最大誤差の一覧を表3、表4に示す。検証精度が最良のケースとして、ルート2ではCase 2.2、ルート3ではCase 3.5のモデルが選択された。これらの最良モデルの入力ユニット数は3入力と9入力であり、いずれもルート1の場合とは異なっている。そこで推定最大滞留時間との対比を行うと、滞留時間の短いルートほど各最良モデルの入力数が少なくなっているという関係が見られる。つまり、全3ルートの最良モデルは、滞留時間の長短という各ルートの特性が反映されたものといえる。図6はルート2の、図7はルート3の最良モデルと5入力モデルの時系列グラフである。滞留時間の短いルート2（図6）では、短い時間遅れ要因のみによるモデル（Case 2.2）の方が未学習データに対しても高い適合性

表3 ルート2の各モデル精度

出力:Y2 _t	入力数	学習結果	検証結果
Case 2.1	1入力	0.12	0.12
Case 2.2	3入力	0.10	0.10
Case 2.3	5入力	0.10	0.12
Case 2.4	7入力	0.10	0.11
Case 2.5	9入力	0.10	0.24

(単位:mg/L)

を示しており、滞留時間の長いルート3（図7）では、時間遅れの追加（Case 3.5）の優位性が認められる。

以上のケーススタディから、対象とした配水管網の主要3ルートについて、ニューラルネットワークによる残留塩素濃度のモデル化を行い、いずれも予測シミュレーションに有用なモデルであることが検証された。なお、各モデルの検証結果時系列グラフを比較してみると、期間の最初の数時間で予測精度がやや劣るという共通点があり、この時間帯には管網全体として何らかの、他の時間帯と異なった状況が生じていて、今回の入力要因では説明し切れなかったものと思われる。

表4 ルート3の各モデル精度

出力:Y3 _t	入力数	学習結果	検証結果
Case 3.1	1入力	0.18	0.13
Case 3.2	3入力	0.10	0.19
Case 3.3	5入力	0.03	0.12
Case 3.4	7入力	0.02	0.12
Case 3.5	9入力	0.02	0.09
Case 3.6	11入力	0.01	0.10

(単位:mg/L)




図6 ルート2の検証結果時系列の比較






図7 ルート3の検証結果時系列の比較

5. おわりに

本論文では、配水管網の水質管理に対して有益な残留塩素濃度モデルとして、ニューラルネットワークを用いたモデル化プロセスを提案した。すなわち、配水管網をブラックボックスとして捉え、ニューラルネットワークモデルを適用するという、モデル化の基本的な考え方について示した。次にケーススタディとして、実際の配水管網を対象としたモデル化を試み、ネットワーク構造の予備分析として中間層構造の検討を行い、3層4ユニットの中間層を選択した。また時間遅れの検討によって、対象とする管網ルートでは3時間前程

度までの過去の入力情報が、出力に対して影響が強いと判断された。これらの予備分析結果を考慮してニューラルネットワークモデルを作成し、残留塩素濃度の予測が十分に可能であると検証された。さらに、同管網の他のルートに対しても同様のモデル化を行い、いずれも予測シミュレーションに有用なモデルが作成できた。本モデル化プロセスは、季節毎の適用を含め、様々な地域で使用可能であると思われる。

なお、本ニューラルネットワークモデルは、管路特性をシナプス荷重に集約・固定しているため、水流の部分的な停滞に対してバイパス管路を設置するといった施設改良計画についての予測シミュレーションは適用範囲外となる。しかし、EPANET に比べモデル化が容易であり、管路特性データが必ずしも管網全域にわたって入手可能でない場合にも適用可能であるという特徴があるので、両者それぞれの特性を生かした利用方法により、配水管網の水質改善に役立つものと考えている。

今後の課題としては、原水の水質変化を入力層に加えたモデルの検討や、配水池での塩素消費を考慮したモデル化などを行うとともに、水質制御への利用も視野に入れた研究を進めて行きたい。

<参考文献>

- 1) W. M. Grayman, R. M. Clark and R. M. Males "Modeling Distribution-System Water Quality: Dynamic Approach" *Journal of Water Resources Planning and Management, ASCE*, 114(3), pp.295-312, 1988
- 2) 高桑哲男：配水管網の解析と設計，森北出版，pp.89-93，1978
- 3) L. A. Rossman, P. F. Boulos and T. Altman "Discrete Volume-Element Method for Network Water-Quality Models" *Journal of Water Resources Planning and Management, ASCE*, 119(5), pp.505-517, 1993
- 4) L. A. Rossman, R. M. Clark and W. M. Grayman "Modeling chlorine residuals in drinking-water distribution systems" *Journal of Environmental Engineering, ASCE*, 120(4), pp.803-820, 1994
- 5) J. J. Vasconcelos, L. A. Rossman, W. M. Grayman, P. F. Boulos and R. M. Clark "Kinetics of chlorine decay" *Journal of American Water Works Association*, 89(7), pp.54-65, 1997
- 6) 菊池豊彦：入門ニューロコンピュータ，オーム社，pp.17-34，1990
- 7) 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，pp.24-27，1994
- 8) 橋本雅至・古高龍太郎・森川治記・山村佳裕：上水道配水管網における動的な水質解析，KUBOTA TECHNICAL REPORT, No.31, pp.19-24, 1996
- 9) 稲員とよの・小泉明：ニューラルネットワークによる配水管網のモデル化，水道協会雑誌，第65巻，第7号，pp.17-25，1996
- 10) 稲員とよの・小幡晋・小泉明：ニューラルネットワークによる水道管内残留塩素濃度のモデル化に関する一考察，土木学会第53回年次学術講演会講演概要集CS部門，pp.148-149，1998
- 11) 稲員とよの・小幡晋・小泉明・榊原康之：ニューラルネットワークモデルによる配水管網内残留塩素濃度の推定，第50回全国水道研究発表会講演集，pp.412-413，1999