ニューラルネットワークによる導管網漏洩位置推定*

竹 内 淳^{*1}, 小 杉 幸 夫^{*2}Neural Network Implementation to Leak
Localization Problems of Pipe Networks

Jun TAKEUCHI and Yukio KOSUGI

We implemented the classification procedure using the multilayer perceptron (MLP) on the leak localization problems of fluid pipe networks. In our implementation, we first segmented the whole pipe network into a finite number of regions or pipe groups. Then we trained the MLP to produce the relationship between the measurement values and the leak region. Because an MLP for 1 out of M classification problems approximates the Bayesian posterior probability, we can estimate the leak probability for each region. Using this probability value we updated the segmentation to improve the resolution around the leak position. We also considered the allocation of measurement points, and implemented a genetic algorithm procedure to improve it. Numerical simulation results are presented to show the validity of these algorithms.

Key Words: Neural Network, Pipeline, Diagnostics, Leak Localization, Genetic Algorithm

1. 緒 言

日常生活を支えるガスや水の輸送には、地上や地中に張り巡らされた導管網が広く用いられている。これら導管網が地震等により破損し漏洩が発生した場合、その漏洩位置を推定することは被害を最小限に抑え、復旧を早める上で重要な課題である。漏洩が発生した場合その応答は流量や圧力分布の変動としてあらわれることから、導管網上で圧力や流量を測定することにより、漏洩に関する情報を得ることができる。流量や圧力の測定値を用いた漏洩位置推定手法としては、過渡応答のモデルとパイプライン末端での流量や圧力勾配を用いた手法⁽¹⁾⁽²⁾がすでに示されている。しかしながら、これらの手法は導管網が閉ループを含んだ複雑な枝別れ構造である場合や、末端での流量や圧力勾配が分からない場合には直接適用することはできない。また推定される漏洩位置も一ヶ所の確定値であり、確率的にどの範囲でどのくらいの可能性があるかは分からない。

そこで本稿では任意の位置の測定点を用いた、確率的な漏洩位置推定を行う方法として、ニューラルネットワークを用いた手法⁽³⁾を提案する。用いるネットワークは、逆問題や認識問題で広く用いられている層状のフィードフォワードネットでのMLP (Multilayer Perceptron) と呼ばれている。MLP の入力としては圧力や流量の測定値を用い、出力としては導管網をいくつかの有限の数の領域に分割した場合の各領域での漏洩有無を用いる。従って漏洩位置推定問題は、漏洩がどの領域に属するかという分類問題に置き換えらる。分類問題にMLPを適用し、誤差逆伝搬法などで学習した場合、出力はベイズの事後確率を近似するように学習することが知られている⁽⁴⁾。したがってMLPの出力を求めることにより、どの領域に漏洩点があるかが確率的に推定できる。

このように漏洩位置推定問題を、どの領域に漏洩があるかという問題に置き換えた場合、位置に関する精度は領域の大きさによって左右される。精度をあげるために非常に多数の小さな領域に導管網全体を分割すると、MLPのサイズは非常に大きくなり、学習に必要な学習パターン数や学習時間も著しく増大する。そこ

* 原稿受付 1995 年 6 月 20 日。

^{*1} 正員、東京工業大学大学院 (〒226 横浜市緑区長津田 4259)。^{*2} 東京工業大学。

で本稿では、分割領域数は増やさずに、その配置を段階的に修正することによって、推定精度を上げるという手法を示す。

なお漏洩位置推定を行う上で重要な点の一つに、測定点配置の問題がある。一般に測定設備の設置には費用が掛かるため、その数は限定される。従っていかに限られた数の測定点を有効に配置するかが、推定精度を上げる上で重要である。本論文ではMLPの誤差関数を推定の不確定さの尺度とみなし、それが小さくなるような組み合わせを単純な遺伝的アルゴリズムを用いて探索する方法を示す。

以上に述べた手法により、数値シミュレーションを行った。ただし圧力流量分布は定常解析により求めた値を用いた。数値シミュレーションの結果は、本手法が導管網の漏洩位置推定に適用可能であることを示している。

2. 導管網の方程式

今ある導管 k の両端の節点を i と j とした場合、定常状態での導管 k を流れる流量 Q_k は(1)式のように近似される。

$$Q_k = \alpha_y (P_y)^n \quad (1)$$

ここで n は流体の種類によって決まる定数であり、ガスの場合は一般に0.5の値が広く用いられる。また α_y は流量係数、導管の延長(長さ)、直径、流体の比重などによって決まる係数であり、 P_y は導管両端の差圧である。差圧はガスの場合、低圧 (10^4Pa 以下) では両端節点圧力の差 $|P_i - P_j|$ であり、中圧以上 (10^4Pa 以上) では両端節点の絶対圧力の2乗の差 $|P_i^2 - P_j^2|$ である。導管網の各節点では圧力もしくは流量が条件として与えられるので、各節点での流量保存則を満たすような節点圧力を求めるか、あるいは各閉ループの圧力変動が0となるような閉ループ流量を求めることで、導管網全体の圧力流量分布を求めることができる。具体的な解法としては例えば Hardy-Cross 法が挙げられる⁽⁵⁾。

本稿で漏洩推定に用いる MLP はその学習のために多数の、漏洩・測定値パターンを必要とする。そのためのデータは、後述の数値シミュレーションにおいては仮想的な漏洩に対する圧力・流量分布を Hardy-Cross 法を用いて求めることによって生成する。ここで言う仮想的な漏洩は、導管上に節点を配置しその節点で導管網外部への流量を条件として与えることに相当する。

なお、漏洩は通常その流量によって特性付けられるが、その漏洩量自体は導管網の状態に依存するので、必ずしもその導管の破断程度を表してはいない。そこ

で導管の破断の程度を表すものとして破断率を以下のように定義する。破断率は、その点が導管外部の圧力まで開放したときの漏洩量を Q_M 、実際の漏洩量を Q_L とした場合、 Q_L/Q_M で定義する。したがって各点での漏洩は0~1の値をとる破断率で表すことができる。漏洩点が一箇所の場合には、ある破断率にたいする Q_L は、その点を外部圧力に固定して求めた Q_M から容易に求められる。漏洩点が複数箇所の場合には漏洩点相互の影響を考慮する必要があるため、緩和法などの反復解法を使って求める。

3. 漏洩位置推定手法

3.1 Multilayer Perceptron MLPは非線形入出力関係を学習するニューラルネットワークであり、非線形モデルの近似や、分類問題・逆問題の解析において広く適用することができるネットワークである⁽⁶⁾。今MLPの入力、出力と期待(教師)出力を図1に示すようにそれぞれ $\mathbf{X}, \mathbf{Y}, \hat{\mathbf{Y}}$ とし、MLPの状態をあらわすパラメータを $\mathbf{W}$ とする。この場合MLPの誤差関数 J は(2)式に示される。

$$J = \frac{1}{2} \sum_{i=1}^T \|\mathbf{Y}_i - \hat{\mathbf{Y}}_i\|^2 \quad (2)$$

ここで T は入出力パターン数である。MLPの学習には誤差逆伝搬法などが用いられるが、それは実質的には、ネットワークのパラメータ $\mathbf{W}$ を、誤差関数に対する最急降下法により修正することに相当する。

Fig. 1 Multilayer Perceptron

いま入力 $\mathbf{X}$ の各要素は漏洩推定のために用いる圧力や流量の各測定値であるとし、また期待出力 $\hat{\mathbf{Y}}$ の要素 $\hat{Y}_i$ は i 番領域内に漏洩(破断)がある場合にはその破断率にかかわらず1、漏洩がない場合には0の値をとるものとする。また一度に複数の領域で同時に漏洩が発生しないと仮定する。

このように期待出力のうち一つのみが1で残りが0

であるという条件のもとで MLP の学習を行った場合、MLP の出力 $\mathbf{Y}$ は、入力 $\mathbf{X}$ の条件下でのベイズの事後確率を近似するようになる⁽⁴⁾。したがって測定値である入力 $\mathbf{X}$ に対して 0~1 の間の値をとる各出力 Y_i は、その測定値の条件下で i 番領域内に漏洩(破断)が存在する確率を近似するものとなる。

3.2 領域分割 前節で述べた手法を用いる場合、位置に関する精度は領域の大きさにより制限される。したがって高精度の推定をするためにはより小さい領域を使う必要がある。しかし各領域を小さくするために全体の領域数を増大させると、学習に必要な学習時間や学習パターン数も同時に増大してしまう。そこで本稿では領域数を一定に保ったままにしておき、領域の形状を推定結果を用いて段階的に変更することによって、漏洩点周りの推定精度を上げることとする。

いま導管 i と導管 j の間の距離 L_{ij} を式(3)で定義する。

$$L_{ij} = \left[\frac{1}{2}(L_i + L_j) + \text{Min}_{R_{ij}} \left(\sum_{k \in R_{ij}} L_k \right) \right] \dots\dots\dots (3)$$

ここで R_{ij} は導管 i から導管 j への経路上の導管の集合であり、導管 i と j は含まない。すなわち L_{ij} は導管 i の中心位置から導管 j の中心位置までの、導管網上で最短経路の長さに相当する。

また本稿では各領域は導管の集団から構成されるものとして、その場合の領域 r のサイズ S_r を式(4)で定義する。

$$S_r = \text{Max}_{i,j \in r} [L_{ij}] \dots\dots\dots (4)$$

すなわち各領域のサイズは、その領域内で最も距離の離れた二つの導管の間の距離に相当する。

導管網上で近接した位置での漏洩に対しては、測定値も近くなると考えられるので、分類を容易にするためには各領域が連結した導管の集団から構成されることが好ましいと考えられる。またあらかじめどこで漏洩が起こり易いか分からない場合、各領域はなるべく均等の大きさを持たせるのが妥当である。そこで導管網を N 個のなるべく均等な大きさの領域に分割する手順を以下に示す。

- 1) 各導管をランダムに、 N 個の領域に割り当てる。
- 2) 導管を一つ選び、 N 個の領域のサイズの最大値が最も小さくなるように、その導管を適当な領域に組み入れる。これをすべての導管に対して行う。
- 3) もし各領域の導管の組み合わせに変更が無ければ終了し、変更があった場合は2)に戻って再度修正を試みる。

あらかじめ、漏洩発生場所に関する情報が有る場合や、それまでの推定結果が有る場合には、漏洩発生の可能性の大きい部分で、領域が小さくなるようにすることが望ましい。そこで(3)式の各導管の距離に重みを加えることを考えた。すなわち導管 i の重みを ω_i とし、(3)式を(5)式で置き換える。

$$L_{ij} = \left[\frac{1}{2}(\omega_i L_i + \omega_j L_j) + \text{Min}_{R_{ij}} \left(\sum_{k \in R_{ij}} \omega_k L_k \right) \right] \dots\dots\dots (5)$$

漏洩の可能性が大きい部分の導管の重みを相対的に大きくすることによって、その部分の領域の重みがない時のサイズ、すなわち空間的な大きさを小さくすることができる。結果としてその部分でより精密な位置推定が行えるようになる。

3.3 漏洩推定手順 以上を示した、手法を組み合わせて、以下のような手順で推定を行う。

- 1) すべての導管の重み ω_i を 1 にセットする。
- 2) 3.2 節で示した手順で各領域の重み付きサイズが均等になるように領域分割を行う。
- 3) 様々な点での漏洩を仮定したときの応答を、数式モデルを解くことにより求め、得られた圧力流量パターンと各領域の漏洩有無を用いて MLP を学習する。
- 4) 漏洩推定のための測定値を MLP に入力して出力を求め、その出力の大きさに応じて対応する領域内の導管の重みを更新する。例えば導管 i を含む領域に対応する MLP の出力が Y_i であるとした場合に式(6)を用いて更新する。ここで α と β はどちらも正の定数である。

$$(\omega_i)_{\text{new}} = (\alpha + \beta Y_i)(\omega_i)_{\text{old}} \dots\dots\dots (6)$$

- 5) 2)に戻って繰り返す。

手順の4)において出力 Y_i の大きい領域内の導管ほど、重みも相対的に大きくなるので、手順2)で再び均等領域に分割する際その部分の領域は逆に小さくすることができる。

4. 数値シミュレーション例

前節で示した手順に従って数値シミュレーションを行なった。数値シミュレーションに用いた導管網モデルを図2に示す。モデルは実際の中圧導管網に基づいており、54 個の節点と導管を持っている。黒丸は定圧供給源のガバナーであり、矢印と数値は消費量を表している。また流体としては比重 0.65 のガスを想定している。

図3に、(a)測定点配置と漏洩点設定値、(b)各段階

での領域分割と漏洩推定値の移り変わり、を示す。破断率は0.5~1.0の範囲を考慮しており、領域は5領域、測定点は4ヶ所の場合である。この測定点配置は、後述する方法により得られたものである。また用いたMLPは三層で中間層ユニット数は4である。なお学習パターンとテストパターンを別に用意しておき、テストセットの誤差関数の変化を見ることでMLPが過学習をしないことを確認した。

Fig. 2 Pipe network model for numerical simulations

結果は図3(b)に示すように、漏洩点付近の領域は離れた領域よりも推定値は大きい値となった。また漏洩点付近の領域の大きさは反復とともに小さくなり、推定位置がしだいに絞り込まれていくのがわかる。

本来事後確率の近似という点では、全領域の推定値の和は1になるべきであるが、実際には大きく違う値もとっている。これは主にMLPのサイズが小さくて近似能力が低いことに起因する。ただしすでに述べたようにMLPのサイズの増大は、学習パターン数や時間を増大させるので、推定システムの処理能力などに応じて調節する必要がある。

5. 測定点配置

漏洩位置推定に用いる流量や圧力の測定値を得るための計測機器を新規に設置する場合、導管網のどこに配置するかは、推定精度に大きく影響する重要な問題である。本稿で示した漏洩推定手法の場合には、推定に用いるMLPの誤差関数が小さいほど、正しい推定ができていくことになるので、なるべく誤差関数が小さくなるような測定点配置の組み合わせを見付ければ、推定精度も向上すると考えられる。組み合わせの最適化手法としては、遺伝的アルゴリズム⁽⁷⁾が近年広く用いられている。本稿では測定点数が固定された場合に

a) Measurement nodes and leak location

b) MLP outputs for each region at each iteration

Fig. 3 Numerical simulation result

対して、一種の遺伝的アルゴリズムの手法を用いて測定点配置の改善を試みた。

遺伝的アルゴリズムを適用する場合に用いた遺伝子は式(7)に示すベクトル形式で表現できる。

$$x = (x_1, x_2, \dots, x_n) \dots \dots \dots (7)$$

ここで各 x_i は0または1の値をとり、 x_i が0のとき i 番節点は測定点ではなく、1のときは測定点である。いま測定点数を M とするとベクトル内の1の要素の数は M 個である。各個体は一つの遺伝子を持ち以下に示す操作で新しい個体を生成する。

操作としては、変異と合成を用いた。変異は一遺伝子内でランダムに選んだ x_i と x_j の値を入れ替えるもの

である。合成は二遺伝子の各要素の論理和をとったあとに、遺伝子内の1の数が合計 M 個になるようにランダムに1の要素を選んで0に置き換えるものである。操作の例を図4に示す。

探索は、まず L 個の親となる個体をランダムに生成し、それにたいして操作のいずれかを行うことにより、 K 個の子孫となる個体を生成する。これら $K+L$ 個の個体のうち、適応度の良いものから L 個が生き残って次の世代の親となる。適応度はその個体の優秀さを表すもので、本稿では個体の遺伝子が表す測定点配置を用いてネットワークを学習した場合の、テストセットに対する誤差関数の値を適応度の尺度とする。すなわち誤差関数の値が小さいほど適応度は高く、良い個体であるとした。

図2に示したものと同一モデルを、図5(a)に示す5領域に分割した場合について計算を行った。親と子の個体数はともに5に設定した。第1、第5、第20世代の親個体の遺伝子に基づく測定点配置をそれぞれ図5の(b)~(d)に示す。初期の多様な個体が世代とともに最終的な結果に収束していくのがわかる。探索はさらに第50世代まで続けたが第21世代以降最適な組み合わせに変化は生じなかった。

探索によって最良の個体の誤差関数の値は、0.451から0.278に減少した。前節で用いた測定点配置はこうして得られたものである。

Fig. 4 Examples of the genetic operations

6. 結 言

圧力・流量測定値からの、導管網漏洩位置推定手法として、ニューラルネットワークの一種であるMLPによる手法を示した。本手法では、どの部分領域に漏洩が存在するかを確率的に求めることによって漏洩位置の推定を行った。さらに測定精度を改善するための段階的領域分割の更新手順を示した。この手法を用いた数値シミュレーション結果は、漏洩推定が有効に行われうることを示すものであった。

このようなMLPを用いる手法の大きな利点の一つは、漏洩位置推定のための情報が比較的自由に選べることであり、そしてその情報に見合った程度で推定が行えることである。実際にはネットワークの構造や学習をうまく調整しなければ正しい推定は行えないが、解析的な推定計算式が得られない場合でも利用できるのは大きな利点であるといえる。

Fig. 5 Simulation model and measurement node location at each generation

本稿ではさらに測定点の配置問題について、遺伝的アルゴリズムの手法を用いた場合の手順と、数値シミュレーション結果を示した。こうして得られた測定点配置は、各測定点が導管網全体に分散しており、直感的にも妥当な配置といえる。

本稿では漏洩の位置の推定に重点を置いたため、導管網全体に対し空間的な分割のみを行ったが、破断率の推定を重視するのであれば破断率をいくつかの区間に分割してそれぞれを独立の分類クラスとして MLP を構成する必要がある。このような位置や破断率に関する分割は一意的なものではなく、複数種類の分割とそれぞれに対応した複数の MLP を同時に並行して使用することも可能である。したがってもしそれら多数の推定結果をうまく統合することができれば、並列分散処理的な観点からも有効な手法となりうるものであり、今後の重要な検討課題として捉えている。

謝 辞

中圧ガス導管網のサンプルデータの提供、ならびに様々な助言をいただいた東京ガス森田昌吾様に感謝申し上げます。

文 献

- (1) G. Z. Wang, C. Z. Fang, K. F. Wang, State Estimation and Leak Detection and Location in Pipeline, *proc. IECON*, (1991), 155-160
- (2) 木内, パイプラインの過渡応答計算による漏洩位置の検知, 機論 (B 編), 57-541, (1991-9), 3000-3007
- (3) 竹内, 佐瀬, 小杉, ニューラルネットワークによる導管網解析と漏洩位置推定, 日本機械学会第 71 期通常総会講演会講演論文集 (I), (1994-3), 10-12
- (4) Michael D. Richard and Richard P. Lippmann, Neural Network Classifiers Estimate Bayesian a posteriori Probabilities, *Neural Computation*, 3 (1991), 461-483
- (5) Andrew P. C. and Anthony S. White, A comparison of several computational methods for pipe networks, *Int. J. of Mech. Eng. Edu.*, 13-4, (1984), 259-271
- (6) 矢川元基編, ニューラルネットワーク, (1992), 2, 培風館
- (7) L. デービス編, 嘉数ほか 5 名共訳, 遺伝アルゴリズムハンドブック, (1992), 13, 森北出版