ニューラルネットワークを用いたインピーダンス CT による
ボイド分布測定法の実用化*隅田 勲^{*1}, 田中 一也^{*2}
早矢仕 英謙^{*3}, 若井 和憲^{*4}Development of Practical Measurement Method for
Void Fraction Distribution in Two-Phase Flow
Using Impedance CT Technique with Neural NetworkIsao SUMIDA^{*5}, Kazuya TANAKA,
Hideaki HAYASHI and Kazunori WAKAI^{*5} Department of Mechanical Engineering, College of Engineering, Chubu University,
1200 Matsumoto-cho, Kasugai-shi, Aichi, 487-8501 Japan

The learning process of neural network in the impedance CT for void distribution measurement was improved. A void distribution function to express void distribution only by three parameters was introduced, so that 81 of output layer units in the previous network, was decreased to 3 units. Input layer units were reduced by eliminating duplicated current data and numbers of hidden layer units were minimized. The best learning parameters were recalculated about the slimmed network by using the error back propagation technique. As the results, the learning speed of the impedance CT was about 30 times faster than that of the previous paper. Two types of experiments were conducted using a square duct. One used acrylic rods as dummy voids, the other used air-water two phase flow. Comparison between experiment and prediction indicated that the impedance CT method was able to predict void distributions with good accuracy.

Key Words: Multiphase Flow, Neural Network, Inverse Problem, Void Fraction, Impedance CT

1. 緒 論

気液二相流は原子炉の炉心や蒸気発生器、ボイラーなどの機器に出現し、機器内のボイド分布は流動や伝熱に影響を与えるため、詳細な情報が望まれている。気液二相流のボイド率測定法には探針式プローブを始めとして最近ではX線・ γ 線CTや中性子ラジオグラフィなどが開発されている^①。しかし探針式プローブは原理的に局所ボイド率のみの測定であるために流路内のボイド分布測定に時間がかかることが問題である。またX線・ γ 線CTや中性子ラジオグラフィなどは放射線の使える環境に限定され、装置も複雑で簡単には利用できない。一方、物体の内部状態を知る方法としてインピーダンスCTがある^{②③}。これは物体表面に取付けた多数の電極間の自己・伝達インピーダンスを測定することで物体の内部の導電率分布を同定する方法で

あり、いわゆる逆問題を解く方法である。この方法は医療分野においては肺部体積や血管断面積の推定などに、また工業分野においては非破壊検査への適用^④が試みられている。精度的に若干問題はあるが、装置が安価、簡便であることや3次元映像への拡張が容易であるなどの利点がある。このインピーダンスCTの気液二相流のボイド分布測定への応用は比較的早く、二流体モデルの基本的要素である界面面積密度などの情報を得るための研究が進められているが、まだ十分な成果は得られていない^⑤。

われわれは前報においてニューラルネットワークをインピーダンスCTにおける逆問題解析に利用して、流路内の時間平均ボイド分布を測定する方法を試み、その有効性を示した^{⑥⑦}。

この方法は一度ネットワークの学習が完了すれば積和演算を行うだけで出力信号が得られ、また未学習の入力信号に対しても妥当な値を出力できる性質を持つために簡便な測定法として利用できると考えられる。

* 原稿受付 2000年9月20日。

^{*1} 正員、中部大学工学部(☎487-8501 春日井市松本町1200)。^{*2} 中部NTT(☎460-8506 名古屋市中区三の丸1-9-1)。^{*3} 大同特殊鋼(☎477-0035 東海市元浜町39)。^{*4} 正員、岐阜大学工学部(☎501-1112 岐阜市柳戸1-1)。

E-mail: sumida@isc.chubu.ac.jp

しかし、教師データの作成および学習の段階で膨大な時間を要することが問題であった。

本研究ではボイド分布関数などの新しい方法の導入および教師データの作成方法やネットワーク構造の見直しによって学習速度を向上させ、より実用的な方法を提案することを目的としている。

2. おもな記号

(1) ボイド関数について

a: ボイド関数のピーク位置における局所ボイド率

b, c: ボイド関数における x 方向, y 方向の偏心率

(2) ニューラルネットワークについて

o_{pj}^k : パターン p における k 層 j 番目ユニット u_j^k の

出力値

i_{pj}^k : パターン p における k 層 j 番目ユニット u_j^k の

入力値

t_{pi}^n : パターン p における最終層 n 層のユニット i の

教師信号値

$w_{i,j}^{k-1,k}$: k-1 層 i 番目ユニット u_i^{k-1} と k 層 j 番目

ユニット u_j^k との重みの値

f_j^k : k 層 j 番目ユニット u_j^k における入出力関数

θ_j^k : k 層 j 番目のユニット u_j^k のしきい値

N_k : 第 k 層のユニット数

3. 測定原理

図 1 に示すようにインピーダンス CT の装置構成は極めて簡単で、流路の周囲に複数の電極を設置し、一つの電極に電圧を印可して他の電極に流れる電流値を測定するだけである。このとき得られる電流値は、流路内の二相流状態（ボイド分布の違い）によってさまざまな値をとる。

いま、流路内の二相流のボイド分布が既知とすると、各電極を流れる電流値は単なる順問題として、次式で計算できる。

$$\nabla \cdot (\sigma \nabla \phi) = 0$$

ここで σ : 水のコンダクタンス, ϕ : 局所ポテンシャルである。

すなわち、インピーダンス CT の測定原理は、この逆問題を解くことに帰着する。このため本論文では以下に述べる方法を用いる。

まず順問題として、既知のボイド分布に対して各電極

Fig. 1 Schematic Diagram of Test Apparatus

を流れる電流値を支配方程式から解き、「ボイド分布—電流分布」という 1 対 1 の関係を持つ 1 組のデータ（教師データ）を得る。この教師データを複数個用意し、これらの非線型な関係をニューラルネットワークで学習させる。このような学習済みのニューラルネットワークを用意しておけば、ボイド分布の未知である二相流状態において測定した電流分布を入力するだけでボイド分布を得ることができる。

ただし、実際の二相流はさまざまな気泡群を含み、電極から得られる電流データには 3 次元ボイド分布の情報を含んでいる。このような状態を対象としたのではニューラルネットワークに学習させるべき教師データの数に極めて多くなり、3 次元順問題の解析およびニューラルネットワークの学習に要する時間は非現実的なものとなる。このため本研究では電流データの時間平均値による 2 次元ボイド分布を測定対象として扱っている。これは、一般に、時間平均値として得られるボイド分布の流れ方向の変化は小さく、2 次元分布として扱ってよいと考えられるからである。

3. 1 ボイド分布関数

ニューラルネットワークにおける学習を高速化する方法の 1 つは、出力層ユニット数を削減することである。前報では、方形流路断面を 9×9 に分割し、それぞれの分割領域におけるボイド率を出力として、81 個の出力層ユニットを用いた。しかし、一般的な流れではほとんどの場合ボイド分布のピークは 1 個であることに着目すると、流路内ボイド分布を近似的に以下の式で表すことが可能と考えられる。

$$f(x, y) = a \{ x^{2b} (1-x)^{2-2b} \cdot y^{2c} (1-y)^{2-2c} \}$$

ただし, $(0 \leq a, 2b, 2c, x, y \leq 1)$

ここで a, b, c はそれぞれ定数である。

このボイド分布関数を用いることにより出力層ユニット数を 81 個から 3 個に減らすことができる。

3.2 ニューラルネットワークの構築

インピーダンス CT において精度よくボイド分布を測定するためには多くの教師データを学習させておく必要がある。また、実験を繰返しなが、最適なネットワーク構造を見出す場合、未学習データの再学習に長時間を必要としたのでは効率が悪い。前報では教師データの作成や学習に多大な時間を要したため、学習させた教師データの数に限られ、探針式プローブで測定した結果とインピーダンス CT の出力の結果に一部食い違いが生じた。また、前報で使したニューラルネットワークは隠れ層 2 層を持つ 4 層構造で、各層のユニット数はそれぞれ 64 個, 32 個, 32 個, 81 個であった。

このうち、入力層と出力層のユニット数は電流データ 64 個および 9×9 個のメッシュに対する 81 個の局所ボイド率から一意的に決定されるが、中間層の層数や各層のユニット数は経験的に決定していた。

いま、 n 層から構成される階層型ニューラルネットワークを考えると学習パターン p における k 層 ($k=2, 3, \dots, n$), j 番目のユニット u_j^k の入出力関係は次式のよ

うに示される⁸⁾。

$$o_{pj}^k = f_j^k(i_{pj}^k) \quad (1)$$

$$i_{pj}^k = \sum_{i=1}^{N_k} w_{i,j}^{k-1,k} o_{pi}^{k-1} + \theta_j^k \quad (2)$$

さらに、以下の説明では、式 (2) におけるしきい値

θ_j^k を重みに含めた式 (3) を用いる。

$$i_{pj}^k = \sum_{i=1}^{N_k+1} w_{i,j}^{k-1,k} o_{pi}^{k-1} \quad (3)$$

このニューラルネットワークの評価関数として、教師信号と出力値の 2 乗誤差 E を用いる。

$$E = \sum_p E_p \quad (4)$$

$$E_p = \frac{1}{2} \sum_{i=1}^{N_n} (t_{pi}^n - o_{pi}^n)^2 \quad (5)$$

ここで、入出力関数には次式で表されるシグモイド関数を用いる。

$$f(z) = \frac{1}{1 + \exp(-z)} \quad (6)$$

ニューラルネットワークの学習には前報と同じくバックプロパゲーションアルゴリズムを用いている⁸⁾。このため、まずネットワーク構造やパラメータ (層数、ユニット数、学習定数など) の最適化が必要である。

なお、ニューラルネットワークの学習方法としては次の修正モーメント法を利用する。

パターン p に対する結合係数の変化量は

$$\Delta_p w_{i,j}^{k-1,k} = -\eta \frac{\partial E_p}{\partial w_{i,j}^{k-1,k}} = \eta \delta_{pj}^k o_{pi}^{k-1} \quad (7)$$

ここで

$$\frac{\partial i_{pj}^k}{\partial w_{i,j}^{k-1,k}} = \frac{\partial}{\partial w_{i,j}^{k-1,k}} \sum_{s=1}^{N_{k-1}+1} (w_{s,j}^{k-1,k} o_{ps}^{k-1}) = o_{pi}^{k-1} \quad (8)$$

また、 δ_{pj}^n は、出力層に対して

$$\delta_{pj}^n = (t_{pj}^n - o_{pj}^n) \frac{\partial}{\partial i_{pj}^n} f_j^n(i_{pj}^n) \quad (9)$$

出力層以外に対して

$$\delta_{pj}^k = \frac{\partial}{\partial i_{pj}^k} f_j^k(i_{pj}^k) \sum_{s=1}^{N_{k+1}} (\delta_{ps}^{k+1} w_{j,s}^{k,k+1}) \quad (10)$$

$(k = 2, 3, \dots, n-1)$

である。結合係数の修正は、パターンに対する出力結果と目標値である教師信号との誤差を逆伝播させながら、各層の各ユニットにおける誤差を求め、その誤差をもとに結合係数の修正量を計算し、次式を利用して結合係数を修正する。

$$\Delta_p w_{i,j}^{k-1,k}(m) = \eta \delta_{pj}^k o_i^{k-1} + \alpha(m) \Delta_p w_{i,j}^{k-1,k}(m-1) \quad (11)$$

$$\alpha(m) = \alpha(m-1) + \Delta \alpha \quad (12)$$

ここで、 m は学習回数である。

3. 3 学習速度の向上

つぎに、学習速度を向上させるための検討を進めた。

(1) 教師データの削減

前報の測定では教師データ 1 パターンに含まれる電流データは電圧を印加する電極を 1, 5, 9, 13 と 4 通りに変化させて得られる合計 64 (4×16) 個で構成されている。しかし、この中には電極 1 から電極 5 と電極 1 から電極 5 のように重複した経路が含まれており、これらは削減可能と考えられる。また、シミュレーションの計算結果と実際の測定データの比較から電圧を印加する電極の両端での測定誤差が特に大きく、これはシミュレーションの分割メッシュ数が少ないためシミュレーション上の電流経路が実際の経路と異なることによると考えられる。本研究は流路内の分布を得ることが目的であるので、これらの測定誤差が大きい壁面を流れる電流経路を削除しても再構成に問題はない。したがって、電極番号 1~64 について以下のデータを削減し、従来の教師データ 1 パターンから 18 個のデータを削減して 46 個に削減した。

(a) 電圧印加電極でのデータ 1, 21, 41, 61

(b) 重複するデータ 17, 33, 37, 49, 53, 57

(c) 電圧印加電極の両隣 2, 16, 20, 22, 40, 42, 60, 62

ここで、電流データの個数が 64 個と 46 個の 2 通りの教師データを用意して、それぞれ二乗誤差 0.0001 以下になるまで学習させた。このニューラルネットワーク

Fig2. Effect by Elimination of Teacher Data

に種々の測定データを入力したときに得られる出力の二乗誤差を比較した結果を図 2 に示す。電流データを削減した方が誤差が小さくなっている。

(2) 中間層ユニット数の削減

中間層のユニット数も少ないほど、計算速度やシステムコストの点で有利になる。しかし、ユニット数が少ないときには重みの初期値によっては学習が収束しな

い場合が生じる。このためニューラルネットワークに対して学習時間の短縮や局所的最小点からの脱出のために、学習にほとんど影響を及ぼしていない中間層のユニットを削除し、重みを適当な乱数値でリセットするアルゴリズムを適用した⁽⁹⁾⁽¹⁰⁾⁽¹¹⁾。その結果、学習可能な中間層のユニットの最小値を 4 個に削減できた。

(3) ニューラルネットワークのパラメータ決定

中間層の最適化からネットワーク構造は 3 層でユニット数を 64-4-3 にできた。つぎに、このニューラルネットワークのパラメータ（学習定数 η 、モーメント係数 α 、シグモイド関数の傾き ε ）について 3 パターンからなる教師データを用いて学習を行った。最適なパラメータ値は学習定数が 3、モーメント係数が 0.9、シグモイド関数の傾きが中間層で 1.4、出力層で 1.0 と決定した。

3. 4 学習速度の比較

これまで述べた検討の結果をまとめ、前報と本研究のニューラルネットワークの構造と学習速度の違いを下表に示した。

Table 1. Comparison of Networks

	Input Layer	Hidden Layer1	Hidden Layer2	Output Layer	Learning Time
Previous Report	64	32	32	81	3h55m44s
This Report	48	4	—	3	7m43s

学習速度の違いを見るために、それぞれのニューラルネットワークにおいて 4 パターンの教師データを 20 万回学習する時間を測定して比較した。測定にはパーソナルコンピュータ (HITACHI FLORA, Pentium 160 MHz, 48MB) を用いた。

結果は表 1 に示す通りであり、本研究のネットワークを用いることで学習時間は約 1/30 になっている。

4. 実験による検証

4. 1 模擬ボイドによる実験

本研究では、流れ方向にボイド分布が変化せず 2 元的特性で扱えるような二相流を測定の対象としている。そこで $\phi 2[\text{mm}]$ や $3 \times 3[\text{mm}]$ などのプラスチック棒材 (長さ 50mm) を模擬ボイドとして用いて図 3 に例示するような流れ方向に分布のない状態を再現し、本研究の方式によりボイド分布が再構成できることを確認した。

各電極には固定抵抗が取付けられ、その両端の電圧を測定することで各電極に流れる電流値を計算する。

得られた電流値を測定時の水のコンダクタンスと入力電圧で無次元化して模擬ボイド測定データとした。

Fig.3 Example of Dummy Void Rods Distribution

ニューラルネットワークには、表2に示す45パターンの教師データを作成して、ニューラルネットワークで二乗誤差が0.0001になるまで学習させ、学習を終えたニューラルネットワークへ測定データを通してボイド分布を再構成する。

Table 2 Learning Data for Dummy Void Prediction

Parameter of Void Distribution Function	a	b	c
Range of Parameter	0.1~0.9 0.1 step	0.1~0.5 0.1 step	0.5 fixed
No. of Data	9	5	1

測定には電気分解の影響、測定値の安定性などを考慮して、交流1V, 1 kHz を用いた。

Fig. 4 Reconstruction Results for Dummy Void Distribution

模擬ボイドデータ（白丸）に対して再構成結果（黒丸）を比較して図4に示す。ボイド率および分布の形は良く再現されている。

4. 2 二相流による実験

模擬ボイドによる検証に続いて、前報と同じく空気-水二相流を用いた実験による比較を試みた。実験装置の構成は図5に示す。実験では、1kHzの交流1Vを1つの電極に印加したときに各電極に流れる電流値の時間平均値を測定した。

また測定は、水の流量を10[l/min]に固定して空気の流量を4, 12, 20[l/min]と変化させて行い、流路内に仕切り板を設置しない場合と、1/2(幅25mm)仕切り板を設置する場合の2通りの実験を行った。前報では仕切り板を流路の1/4(幅12.5mm)としたから今回の実験ではボイド分布の偏りが大きくなっている。

ニューラルネットワークの学習には、表3に示す153パターンの教師データを、二乗誤差が0.0001以下に減少するまで学習させて、ニューラルネットワーク内の重みを構築した。

このインピーダンスCTの再構成結果を評価するために、

Table 3 Learning Data for Actual Void Prediction

Parameter of Void Distribution Function	a	b	c
Range of Parameter	0.1~0.9 0.05 step	0.05~0.45 0.05 step	0.5 fixed
No. of Data	17	9	1

電極のすぐ下流の流路断面における局所ボイド率を探針式プローブをスキャンさせて1mm間隔で測定した。

Fig. 5 Experimental Setup for Two Phase Flow

(1) 仕切り板がない場合

図6に仕切板のない場合について空気流量を3通りに変化させたときのボイド分布をインピーダンスCTの像再構成結果(黒実)と探針式プローブの測定値(白抜き)を $y=25[\text{mm}]$ の位置で比較した。ボイド率の小さいところでは流路端部にずれが見られるが、ボイド率の比較的大きい領域では両者の一致はかなり良好である。

Fig. 6 Comparison of Results without Baffle Plate

(2) 仕切板がある場合

図7は仕切板がない場合と同様に、インピーダンスCT

Fig. 7 Comparison of Results with Baffle Plate

の像再構成結果を、それぞれ探針式プローブの測定値と $y=25[\text{mm}]$ の位置で比較したものである。

図から仕切板のない場合と同じく、ボイド率の大きい場合には両者の一致は良好であるが、空気流量の少ない場合には分布の形がずれている。これはボイド分布の測定位置が仕切板に近く、ボイドがまだ流路内に拡散していない状態にあるのに対して、ボイド関数の関数形がこのような分布を表現できないことに起因していると考えられる。この

関数形の改良は今後の課題である。一方、ボイドピークの偏りは、かなり良く予測できている。比較のため、前報と同じ方法で予測した結果を参考として図8に示す。

Fig. 8 Prediction by Previous Method

図から本方式が前報の方式と比較して予測能力が大幅に改善されていることがわかる。

5. 結論

ニューラルネットワークを使ったインピーダンスCTの逆問題解析では学習段階に膨大な時間を要することから、学習速度の向上を含め、より実用的な方法を検討し、以下の結論を得た。

- (1) 実際に出現すると考えられるボイド分布の形状に着目し、3つの定数だけでボイド分布を表現するボイド分布関数を導入した。これにより、ニューラルネットワークの出力層ユニット数を前報の81個から3個に減少させることができた。
- (2) ニューラルネットワークの入力層ユニット数を構成している電流データを、前報の64個から46個まで削減でき、かつ精度も向上することを示した。
- (3) ニューラルネットワークの中間層ユニット数の削減について検討し、学習可能な中間層ユニット数を最小値の4個とした。
- (4) 新しいネットワーク構造に適する各種パラメータを検討し、最適なパラメータを得た。
- (5) これらの改良の結果、前報の方式に比べて学習速度を約30倍速くすることができた。
- (6) 模擬ボイドを用いた実験および実際に空気-水を使った二相流の実験においても、本研究で提案したインピーダンスCTがボイド率の大きい領域では高い精度でボイド分布を再構成でき、ボイド率の小さい領域についてもボイド分布のピーク位置はよく再現できることを示した。

(7) 実験において、ボイド率の小さい領域では探針式プローブの測定結果とのずれが顕著であった。これはボイド関数の関数形が不十分であることに起因すると考えられる。これらの改良は今後の課題である。

(8) 本方式は水中に金属電極を浸すため、探針式プローブと同じように、電極腐食や温度による水のインピーダンス変化など実用化に当たっては誤差の要因となる項目のさらなる検討が必要である。

以上、これらの研究の成果はインピーダンス CT 法の実用化に貢献するものと考えられる。

なお、本研究を遂行するに当たって、実験データの収集に協力していただいた岐阜大学卒業生野村知市君に感謝します。

6. 参考文献

- (1) 小幡 仁・ほか 3 名, 混相流シンポジウム'92 講演論文集, (1992), 173.
- (2) D. C. Barber, B. H. Brown and I. L. Freeston., Elec. Lett., **19**, 933-935, (1983)
- (3) D. C. Barber and B. H. Brown, Proc. 9th Int. Conf. Info. Proc. Med. Imaging, 106-121 (1985)
- (4) O. C. Jones et al., Chem. Eng. Comm. **118**, 299-325, (1992)
- (5) 矢川元基・ほか 2 名, 機論, **59**-559, A, (1993), 526
- (6) 早矢仕英謙・ほか 3 名, 機論, **62**-593, B, 130-136, (1996)
- (7) 隅田勲・ほか 2 名, 混相流, 11-1, 70-73, (1997)
- (8) 坂和正敏・田中雅弘, ニューロコンピューティング入門, (1997), 森北出版
- (9) 楊子江, 計測自動制御学会論文集, **33**, 3, 216-223 (1997)
- (10) 荻原将文, 信学技報, NC80-104 (1986)
- (11) 松永豊・ほか 3 名, 電子情報通信学会論文誌, J74-D-II, 8, (1991), 1118-1121