C207

ニューラルネットモデル内包学習による 3次元空間の速度・濃度場の推定

餘家 章浩[○]、木村 一郎(大阪電気通信大学)、

加賀 昭和(大阪大学)、黒江 康明(京都工芸繊維大学)

Whole Field Estimation of Velocity and Concentration in a 3-D Space by Neural-Net Model Inclusive Learning

Akihiro Yoke, Ichiro Kimura, Akikazu Kaga and Yasuaki Kuroe

ABSTRACT

This paper proposes a novel algorithm using an artificial neural network for modelling both 3-D flow velocity vector and concentration fields from measured values and boundary conditions. By using its trained neural network, we can estimate 3-D velocity vectors and concentrations over the entire field. The network is trained by using sparsely measured values and boundary conditions as teaching data so that the output of the network agrees well with those data. In addition, the continuity and the diffusion equations are systematically satisfied by the model inclusive learning. In order to evaluate the effectiveness, the proposed method is applied to air flow fields in the full size model of an infection-free hospital room. The concentration distributions in the room are estimated and then compared with the experimental smoke concentration data over the field for validating the proposed algorithm. The estimated results grasp the experimental diffusion behavior.

Keywords: Neural network, Model inclusive learning, Estimation of velocity and concentration, Three-dimensional space

1. 緒 論

3次元空間における流れ場の全域測定は、空調設備の設計などに必要不可欠であるが、病室やドーム型スタジアムのような実際の3次元空間では様々な制約上の問題があり、極めて困難である。これに対し著者らは、ニューラルネットワークを用いた学習による場全体の推定手法^{1,2)}を提案している。この手法は、まず限られた少ない数の風速測定値からニューラルネットワークにより、連続の式を満足する形で場全体の速度場の推定を行い、その後全域の速度推定結果から拡散計算を行い濃度場の推定を行っている。

本研究では、感染対応病室モデルを対象に数少ない速度・濃度の測定データから、ニューラルネットワーク内に連続の式に加えて拡散方程式をも内包する形で3次元空間の速度場と濃度場を同時に推定する新しい手法を提案する。

2. 病室モデルによる実験方法

2.1 病室モデル¹⁾

本研究では、速度・濃度場を推定するために感染対応

病室を想定し、実物大の病室モデルを用意し実験を行った。病室モデルの形状、寸法およびベッド、空気清浄機の位置関係をFig.1に示す。

Fig.1 Full size model of a hospital room

空気清浄機の形状は、上部に吹出口、下部に吸込口がある。この空気清浄機は $0.3\mu\text{m}$ の微粒子を 99.99%以上

捕獲する能力を持つ HEPA(High Efficiency Particulate Air)フィルターを内蔵したものである。また、排気機構も備えており室内を陰圧に保つことができる。本研究は、換気回数を 6 回/h、外部へ汚染が漏洩しないように清浄機のリターン空気の一部(2 回/h)を排気して、室内を陰圧に保っている。

2.2 実験方法

3 章で述べるが、ニューラルネットワークの学習には、教師データが必要である。この教師データを得るために、Fig.1 で示した病室モデル内で、速度と濃度の測定を行う。

速度の測定は超音波風向風速計を用いた。測定点は、x 方向に 1210、1890(mm)の 2 ヶ所、y 方向に 1000、1500、2000、2500、3000、3500(mm)の 6 ヶ所、z 方向に 900、1400(mm)の 2 ヶ所である。ただし、z 方向が 1400(mm)のときの測定点は x 方向に 1210、1890(mm)、y 方向に 1000、1500(mm)の 4 ヶ所であり、計 16 点である。Fig.2 にその測定結果を示す。

濃度の測定はパーティクルカウンタを用いた。本研究では、菌などの汚染物質の代替トレーサとして線香の煙粒子を利用した。患者から菌が発生することを想定して、線香をベッド上に 6 箇所、患者の咳などで床などに菌が飛散することを想定して、床上に 8 箇所設置し、発煙させて測定を行った。濃度の測定点は、x 方向に 600、1210、1890、2540(mm)の 4 ヶ所、y 方向に 500、1000、1500、2000、2500、3000、3500、4000(mm)の 8 ヶ所、z 方向に 500、1000、1500(mm)の 3 ヶ所の計 96 点である。これらの一部を濃度の教師データとする。Fig. 3 に 96 点での濃度測定結果を $z=500\text{mm}$ 、 $z=1000\text{mm}$ 、 $z=1500\text{mm}$ のそれぞれの断面で示す。なお、これらの測定結果を推定結果と比較することにより、本手法の有効性を検証する。

Fig. 2 Measured velocity vectors

3. ニューラルネットワークの学習法

Fig. 4 にモデル内包学習のためのニューラルネットワークの構成を示す。

Fig. 3 Measured smoke concentration distributions

ニューラルネットワークの教師データは、超音波風向風速計による速度測定データ $V_m(u_m, v_m, w_m)$ と、パーティクルカウンタによる濃度測定データ C_m である。入力教師データの位置座標 $X(x, y, z)$ である。ニューラルネットワークの出力は、ベクトルポテンシャル $A(A_x, A_y, A_z)$ と濃度 C_e である。ここで、推定される速度ベクトル $V_e(u_e, v_e, w_e)$ とベクトルポテンシャル A の関係は次式で表される²⁾。

$$V_e = \text{rot} A \quad (1)$$

式(1)より次式が成立する。

$$\text{div}V_e = \text{div}(\text{rot}A) = 0 \quad (2)$$

すなわち3次元非圧縮性流体の連続の式を自動的に満足することになる。したがって、式(1)によって求められた速度ベクトル V_e と超音波風向風速計の測定データである教師データ V_m を一致させるための評価関数 J_1 は次式で与えられる。

$$J_1 = \frac{1}{2} \sum (V_m - V_e)^2 = \frac{1}{2} \sum (V_m - \text{rot}A)^2 \quad (3)$$

ニューラルネットワークの出力である濃度 C_e と濃度の教師データ C_m の差を求める評価関数 J_2 を式(4)に、拡散方程式を満足させるための評価関数 J_3 を式(5)に示す。

$$J_2 = \frac{1}{2} \sum (C_m - C_e)^2 \quad (4)$$

$$J_3 = \frac{1}{2} \sum (V_e \nabla C_e - D \nabla^2 C_e)^2 \quad (5)$$

式(5)の D は乱流拡散係数であり、ここでは簡単のために空気の動粘性係数のおよそ1000倍の $1.0 \times 10^{-2} (\text{m}^2/\text{s})$ で一定としている。この評価関数 J_1 、 J_2 、 J_3 の合計を J とし、この J が最小になるように、ニューラルネットワークの結合荷重の更新を行うことにより、連続の式と拡散方程式を考慮したネットワークを構築することができる。学習の際に評価関数にある $\text{rot}A$ 、 ∇C_e 、 $\nabla^2 C_e$ などを求める必要があるが、複数のアジョイントニューラルネットワークを用いることにより導出することができる³⁾。

Fig. 4 Model inclusive learning method

4. 3次元空間の速度・濃度場推定

ニューラルネットワークの学習に用いた速度の教師データは、病室モデル内で測定により求めた16点に加えて境界条件として速度が0になると考えられる部屋の壁のデータ、空気清浄機の吹き出し口のデータ、吸い込み口のデータ、陰圧を想定してのドア隙間のデータ、ベッドの壁データの計168点とした。濃度の教師データは、病室モデル内で測定された96点の濃度測定データから24点を選び出して教師データとした。濃度の境界条件としては、ベッド上の患者から菌が発生すると想定して、ベッド上の濃度を6点、患者の咳などで床などに菌が飛散することを想定して、床上の濃度を8点、計38点とした。

以上の教師データを用いて3層の階層型ニューラルネットワークの中間層のニューロンを20個、学習回数を20000回とした。このときの病室全体の速度推定結果をFig. 5に示す。空気清浄機の吹き出し口からの空気がベッド付近で下降し、吸い込み口の方へ流れている気流が見られる。これは患者から発生した菌が、床付近を通り空気清浄機に吸い込まれていることを意味している。

Fig. 5 Estimated velocity vector distribution

Fig. 6に $z=500\text{mm}$ 、 $z=1000\text{mm}$ 、 $z=1500\text{mm}$ のそれぞれの断面での濃度推定結果を示す。Fig. 6では、濃度推定結果を測定結果と比較するために、推定する位置座標と測定を行った位置座標を同一のものにして、推定範囲を測定範囲と合わせている。このときの病室全体の濃度推定結果をFig. 7に $z=500\text{mm}$ 、 $z=1000\text{mm}$ 、 $z=1500\text{mm}$ のそれぞれの断面で示す。

濃度推定結果のFig. 6より $z=500\text{mm}$ でのベッド上から高濃度の発生が見られる。 z 方向に高くなるにつれて濃度が低くなっている。これらの点において、濃度測定結果のFig. 3と濃度推定結果のFig. 6を比較すると推定結果は大局的な特徴を捉えた結果であるといえる。

$z=1500\text{mm}$

$z=1000\text{mm}$

$z=500\text{mm}$

Fig. 6 Estimated smoke concentration distributions

$z=1500\text{mm}$

$z=1000\text{mm}$

$z=500\text{mm}$

Fig. 7 Estimated smoke concentration distributions over the entire field

5. 結論

3次元空間全域での速度・濃度場を測定により求めることは、測定個所の数などの制約上の問題により極めて困難である。本研究ではモデル内包型ニューラルネットワークを用い速度・濃度場の推定を行う新しい手法を提案した。この手法は、連続の式や拡散方程式のような流れにおける支配方程式をニューラルネットワークの学習ループに内包させて学習することができるという特徴をもつ。

参考文献

- 1) 福井, 伊藤, 木村, 加賀, 黒江: 感染対応病室内の風速分布のニューラルネットワーク推定, 可視化情報, Vol. 23, Suppl, No. 1 (2003年7月) pp. 441-444.
- 2) 古川, 木村, 加賀, 黒江: ニューラルネットワークによる3次元速度場の推定, 可視化情報, Vol. 20, Suppl, No. 1 (2000年7月) pp. 205-206.
- 3) Kuroe, Y., Mitsui, M., Kawakami, H. and Mori, T.: A learning method for vector field approximation by networks, Proc. Of 1998 IEEE International Joint Conference on Neural Networks (IJCNN'98), 1998, 2300.