

2C4-1 モデル内包学習による感染対応病室内の 速度・濃度場推定法

Estimation Method of Air Flow and Contamination Density Distributions in Infection-free Hospital Room by Model Inclusive Learning

○ 黒江 康明 (京都工繊大学) 学 餘家 章浩 (大阪電気通信大学大学院)
正 木村 一郎 (大阪電気通信大学) 正 加賀 昭和 (大阪大学大学院)

Yasuaki Kuroe, Kyoto Institute of Technology, Matsugasaki, Sakyo-ku, Kyoto
Akihiro Yoke, Osaka Electro-Communication University, Hatsu-cho, Neyagawa, Osaka
Ichiro Kimura, Osaka Electro-Communication University, Hatsu-cho, Neyagawa, Osaka
Akikazu Kaga, Osaka University, Yamadaoka, Suita, Osaka

Air purification in infection-free hospital rooms is becoming more and more important for preventing infection. To design such a room with the air purifier, it is necessary to measure airflow and contamination density distributions over the entire space in the room. It is however very difficult to measure the distributions over the whole flow field for such a real hospital room. This paper proposes a novel method for modelling 3-D flow velocity vector and contamination density distributions from sparsely measured data and boundary conditions. The proposed method is based on the model inclusive learning of a neural network in which the network is trained by using not only teaching data but also a priori knowledge whose model is included in the learning loop. The proposed method makes it possible to estimate simultaneously both 3-D flow velocity vector and contamination density distributions so that they satisfy the continuity and the diffusion equations which are modeled by a priori knowledge on the flow field. 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 and the results are compared with the measured distribution data obtained by smoke tracer-release experiments

Key Words: Neural Network, Model Inclusive Learning, Simultaneous Estimation, 3-D Velocity Distribution, Contamination Density Distribution, Infection-free Hospital Room

1. はじめに

近年、かつては国民病であった結核の患者数が再び増加傾向にあり、多くの病院施設は空気感染症対策の必要性に迫られている。以前はサナトリウムなどの結核患者専用の施設が利用されていたが、最近では既存の施設を専用の空気清浄システムの導入により感染対応病室に改造するケースが多くなってきている。感染対応病室では、医療従事者への感染を防止するため室内に浮遊する結核菌の数を少なくするとともに、菌の室外への流出を防ぐために室内を陰圧に保つことが要求される^①。このような感染対応病室における空気清浄効果を確認するためには、全室内にわたる3次元風速分布と汚染物質の濃度分布を測定する必要がある。しかし、実際の病室での全領域の風速分布測定は困難である。また結核菌そのもの、または代替トレーサの濃度を全領域で測定することも不可能に近い。そこで、限られた測定点での風速データから、全領域での風速・濃度分布を推定することが必要となる。

一方、近年ニューラルネットワークが優れた学習能力と非線形写像の能力を持つため、計測、信号処理、制御など様々な分野に応用されている。筆者らもすでに、ニューラルネットワークを用いて、限られた測定点の風速データより3次元場全体の風速データを推定する方法を提案している^{1,2,4)}。これらの研究で用いているニューラルネットの学

習法は、筆者らによって提案されているモデル内包学習法である^②。通常、未知なる対象のモデルをニューラルネットワークの学習によりネットワーク上に実現する問題において、対象より得られるデータを教師信号としてニューラルネットワークを学習させる。ところが現実の問題においては、対象より得られるデータに加えて対象に対する何らかの事前知識が与えられていることが多い。モデル内包学習法はこれら事前知識をモデル化し、このモデルを、データを教師信号とした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方法^③で、対象の事前知識を自然に含んだモデルをニューラルネットワーク上に構築でき、定性的にも定量的にも優れたモデルが構築できる。

文献 1,2,4)においては、流れ場が連続の式を満足するという事を事前知識として、限られた少ない数の風速測定データを教師信号とし、事前知識のモデルである連続の式を内包させてニューラルネットワークを学習させることにより3次元場全体の速度場の推定を行っている。また汚染物質の濃度分布の推定は、ニューラルネットワークにより得られた速度推定結果を用いて拡散方程式を解くことにより行っている。

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、流れ場が連続の式を満たすこと加えて風速と汚染物質の濃度が拡散方程式で結びつけられることを事前知識として、これらのモデルを内包するモ

デル内包学習法により、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. モデル内包学習⁵⁾

ここでは、本研究で用いるモデル内包学習法の考え方を簡単に説明する。未知なる対象の入出力データが与えられたとして、そのデータを用いてニューラルネットワークを学習させ、未知なる対象のモデルをニューラルネットワーク上に実現する問題を考える。この問題は、ニューラルネットワークの入力に対象の入力データを入力したとき、その出力が出力データに一致するように学習させる、すなわち出力データを教師信号としてネットワークのパラメータを学習させることにより解決できる。学習法としても、階層型のニューラルネットワークに対しては、バックプロパゲーション法のような方法が使える。ところが現実の問題においては、直接、教師データが得られない問題も多い。この場合は、学習において特別な考慮が必要となるが、その際、対象に対する事前知識などを用いて解決するということが考えられる。また、教師データが得られる問題に対しても、対象に対する何らかの事前知識が与えられている場合は、これらを学習に組み込むことにより、入出力データの情報だけでなく事前知識の情報も含んだ形で、より忠実に対象をニューラルネットワーク上に実現できる。そこで、対象に対する事前知識をモデル化し、これを考慮したニューラルネットワークの学習法を考える。ここでは、対象に対する事前知識をモデル化したものを、Partial Modelと呼ぶことにする。

提案するモデル内包学習法概念図を Fig.1 に示す。




Fig. 1 Model inclusive learning of neural networks.

事前知識により得られる Partial Model は対象モデルの一部と考えられ、ニューラルネットワークで実現されるモデルを合わせて、未知対象の全体のモデルを表わすことになる。従って Fig. 1 に示すように、ニューラルネットワークと Partial Model を適切に配置し、対象より得られた入力データをこれらに入力する。このとき対応する出力データを、このときのニューラルネットワークの出力の教師信号とできる場合は、この出力データをニューラルネットワークの教師信号とし、ニューラルネットワークの出力がこれと一致するように学習させればよい。出力データをニューラルネットワークの教師信号とできない場合は、事前知識を用いて、対象の出力データに対応する信号を Partial Model の出力となるように Partial Model をモデル化しておく。学習は、対象の出力データを Partial Model の出力の教師信号とし、Partial Model の出力が教師信号と一致するように行えばよいことになる。このようにすると、ニ

ューラルネットワークの学習ループに Partial Model が内包され、事前知識を考慮した学習が実現できることになる。学習においては、たとえば Partial Model の出力と教師データの 2 乗誤差を評価関数として、この評価関数が減少するようにニューラルネットワークのシナプス荷重などのパラメータを決めることになる。このための学習アルゴリズムの導出においては、勾配法に基づく方法を用いればよい。このとき評価関数のシナプス荷重に関する勾配の計算が必要となるが、その導出にはバックプロパゲーション法のような方法をそのまま用いることができず、学習ループに Partial Model が内包されていることを考慮して導出する必要がある。この詳細については省略する。なお、このモデル内包学習法は、Partial Model に不確定要素や未知パラメータが含まれる場合にも拡張できる。すなわち Fig. 2 に示すようにニューラルネットワークのシナプス荷重の学習と同時に Partial Model に含まれる未知パラメータも学習パラメータとして学習させればよい。すなわち、Partial Model の出力と教師データの 2 乗誤差を評価関数として、これが減少するようにニューラルネットワークのシナプス荷重と Partial Model の未知パラメータを決定すればよい。このためには先ほどと同様に勾配法に基づく方法を用いることができるが、この場合の学習アルゴリズムの導出においても、学習ループに Partial Model が内包されていることを考慮して導く必要がある。また、評価関数のシナプス荷重に関する勾配の計算に加えて、Partial Model の未知パラメータに関する勾配を計算する必要がある。




Fig. 2 Model inclusive learning of neural networks with unknown model parameters.

3. 病室モデルによる実験方法

3.1 病室モデル¹⁾

本研究では、速度・濃度場を推定するために実際の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. 3 に示す。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。

3.2 実験方法

4 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. 3 で示した病室モデル内で、速度と濃度の測定を行う。




Fig. 3 Full size model of a hospital room

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. 4 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. 5 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。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. 4 Measured velocity vectors

4. ニューラルネットワークの学習法

本節では先に述べた病室内でのいくつかの位置で測定により得られた風速の速度データと汚染物質（線香の煙）

の濃度データより、部屋全体での速度分布および濃度分布をニューラルネットワークの学習により同時に推定する方法を提案する。Fig.6 に提案するニューラルネットワークのモデル内包学習による速度場と濃度場の推定法の概念図を示す。

病室内の 3 次元空間の位置座標を $X(x, y, z)$ とし、各位置における風速ベクトルを $V(u, v, w)$ 、汚染物質の濃度を C とする。ここでの問題は、いくつかの測定点において超音波風向風速計により得られた 3 次元の速度風速データ $V_m(u_m, v_m, w_m)$ と、パーティクルカウンタによって得られた




Fig. 5 Measured smoke concentration distributions

濃度測定データ C_m により、病室内の全 3 次元位置による風速の速度ベクトルと汚染物質の濃度を推定することである。ここで、3 次元非圧縮性流体の流れ場において、連続の条件

$$\text{div} V = 0 \quad (1)$$

が成立することが知られており、この条件を事前知識として利用することにする。また、流れ場における汚染物質の濃度分布は、次の拡散方程式で表されることが知られている。

$$D\nabla^2 C = V\nabla C \quad (2)$$

したがってこの関係式も事前知識として推定に利用することにする。ここで D は乱流拡散係数であり、後の実験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。以下では、これらの事前知識のモデルを内包させて学習させる方法を説明する。

Fig.1 に示すように 3 入力 4 出力のニューラルネットワークを用意し、ニューラルネットワークの入力は 3 次元位置座標 $X(x, y, z)$ とする。ニューラルネットワークの出力させるのは、その位置座標に対応する速度ベクトル $V(u, v, w)$ の推定値 $V_e(u_e, v_e, w_e)$ が考えられるが、本研究では $V_e(u_e, v_e, w_e)$ のベクトルポテンシャル $A(A_x, A_y, A_z)$ とする。またの残りの一つの出力には汚染物質の濃度 C の推定値 C_e を出力させることにする。速度ベクトルの推定値 $V_e(u_e, v_e, w_e)$ とベクトルポテンシャル $A(A_x, A_y, A_z)$ の関係は次式で表される。

$$V_e = \text{rot} A$$

したがって、ニューラルネットワークの出力 A より何らかの方法で $\text{rot} A$ を計算し、これが与えられた位置座標での計測速度データ $V_m(u_m, v_m, w_m)$ に一致するようニューラルネットワークを学習させる。この時、流れの連続条件の(1)式は、次式に示すように自動的に満たされることになる。

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

従って、次式の評価関数を設定し、これが最小となるようにニューラルネットワークのシナプス荷重を決めれば良い。

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

ここで、 Σ 記号は測定点に関する和を表す。これにより、連続の条件のモデルを内包した学習となっており、この条件を満足させながら学習させることができる。

ニューラルネットワークの残りの出力 C_e が汚染物質の濃度データの測定値 C_m と一致し、かつ拡散方程式の(2)式を満足させるように学習させるには次のようにすれば良い。与えられた位置入力に対するニューラルネットワークの出力 C_e を、測定により得られた濃度データ C_m を一致させるために、それらの 2 乗誤差を評価関数を次のように定義する。

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

この評価関数を最小とするニューラルネットワークのシナプス荷重を決めることにより、汚染物質の濃度データとその推定値を一致させることができる。さらに拡散方程式の(2)式を満足させるため次のようにする。ニューラルネットワークの出力 C_e より、何らかの方法で ∇C_e 、 $\nabla^2 C_e$ などを求める。これらと速度の推定値 V_e を用いて、 $D\nabla^2 C_e - V_e \nabla C_e$ を計算し、これが零となるようにすればよい。このため次の評価関数を導入する。

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

この評価関数を最小とする ($J_3 \approx 0$ とする) ニューラルネットワークのシナプス荷重を決めることにより、拡散方程式の関係を満足させることができる。

以上のように導入した 3 つの評価関数 J_1 、 J_2 、 J_3 を同時に最小化することにより、事前知識である連続の条件と拡散方程式を満足させながら、病室内全域にわたる風速分布および汚染物質の濃度分布を同時に推定することができる。このため

$$J = \alpha J_1 + \beta J_2 + \gamma J_3 \quad (6)$$

なる評価関数を定義し、これを最小化することにする。この最小化にあたっては最急降下法や共役勾配などの勾配法に基づく方法を用いればよいが、このためには、 $\text{rot} A$ 、 ∇C_e 、 $\nabla^2 C_e$ などを求め、評価関数 J のシナプス荷重に対する勾配を求める必要があり、これをいかに効率よく求めるかが問題となる。詳細は省略するが、これについては、ニューラルネットワークに対し、いくつかのアジョイントニューラルネットワークを導入することにより、効率の良い計算アルゴリズムを導くことができる³⁾。




Fig.6 Model inclusive learning method for estimating 3-D velocity vector and contamination density distributions by neural networks.

4. 病室内の速度・濃度場推定実験

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。







Fig.7 Estimated velocity vector distribution



$z=1500\text{mm}$




$z=1000\text{mm}$




$z=500\text{mm}$


Fig.8 Estimated smoke concentration distributions



$z=1500\text{mm}$



$z=1000\text{mm}$



$z=500\text{mm}$

Fig.9 Estimated smoke concentration distributions over the entire field

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.7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.8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.8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.9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.8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. 5 と濃度推定結果の Fig. 8 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。

5. おわりに

感染対応病室のような実空間では場全体の流れ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。本研究ではニューラルネットワークのモデル内包学習により、3次元空間内の速度分布および汚染物質の濃度分布を同時に推定する新しい手法を提案した。提案した方法は、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事前知識のモデルとし、このモデルを、測定データおよび境界条件を教師データとする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方法である。これにより支配方程式を満足するように推定でき、定性的にも定量的にも優れた推定値が得られ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ベース推定, 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.
- 4) 黒江, 福井, 木村, 加賀: 感染対応病室における空気清浄効果のニューラルネットベース推定, 第14回インテリジェント・システム・シンポジウム講演論文集 (FAN Symposium '04 in Kochi), pp. 109-112, 2004
- 5) 黒江: ニューラルネットワークのモデル内包学習, 計測自動制御学会 システム・情報部門学術講演会 2005 講演論文集, pp. 17-22, 2005
- 6) 田中, 西山, 曾田, “既存施設向け結核対応病棟並びに個室空調システムの安全性と課題”, 空気調和・衛生工学会近畿支部学術研究発表会論文集, 2002, pp. 11-14.