A231 ニューラルネット・遺伝的アルゴリズムを用いた 粒子追跡画像計測法

○古川 亨, 上田昌孝, 服部敦彦, 木村一郎 (大阪電気通信大学)
黒江康明 (京都工芸繊維大学), 加賀昭和 (大阪大学)

Particle tracking velocimetry using neural networks and genetic algorithms

Toru FURUKAWA¹, Masataka UEDA¹, Atsuhiko HATTORI¹, Ichiro KIMURA¹,
Yasuaki KUROE², Akikazu KAGA³

¹Osaka Electro-Communication University, Hatsu-Cho, Neyagawa, Osaka

²Kyoto Institute of Technology, Matsugasaki, Sakyo-ku, Kyoto

³Osaka University, Yamadaoka, Suita, Osaka

Particle tracking velocimetry (PTV) is one of the methods to measure flow velocity fields which is considered to be essential and useful for analyzing complex flow fields. This paper proposes a temporally particle pairing method using genetic algorithms and a flow velocity field estimation method using neural networks. The particle pairing method is based on spatial pattern relationship between pair-candidate particles with their respective neighbour particles in two exposures taken over a small time interval. If two particles are paired correctly, the spatial patterns of their pair-candidate particles are to be similar. The method finds correct pairs by applying a genetic algorithm. A potential problem of the method is that it can't measure velocity vectors at the points where no particles exist. The flow velocity field estimation method proposed in this paper solves it, which uses neural networks. The neural network is trained by using measured velocity vectors as teaching data so that the derivatives of a certain scholar function agree well with the measured data. The continuity equation of flow is consequently satisfied in the estimated vector fields and the scholar function gives the stream function.

Keywords: PTV, Neural networks, Genetic algorithm

1. はじめに

流れを可視化し、その流れ場を計測することは、工学において重要な課題である。PTVは、流れの中に混入されたトレーサ粒子を追跡することにより、速度ベクトルを計測する手法で、撮影時刻の異なる複数の画像内の粒子を時間的に対応づけることで、速度ベクトルを計測する。本研究では、その時間的対応づけに遺伝的アルゴリズム(以下GAと略す)を適用し速度ベクトルを求め、さらにトレーサ粒子の存在しない領域では、流れ関数を学習するニューラルネットワークを用いて、速度ベクトルを推定する、新しい方法を提案し、その有用性を示す。以下にその詳細を述べる。

2. 粒子の位置パターンの類似性を考慮した、遺伝的アルゴリズムによる粒子追跡速度計測法

遺伝的アルゴリズムを粒子追跡に適用するため、問題空間を遺伝子型に対応づける。まず、計測対象となる、第1画面内の粒子ラベルの集合が $A=\{a_1, a_2, \dots, a_i, \dots, a_n\}$ 、第2画面内の粒子ラベルの集合が $B=\{b_1, b_2, \dots, b_j, \dots, b_n\}$ となるように、ラベリングする。ただし、2つの画像におい

て流入/流出する粒子はないものとし、それぞれの画面内の粒子数は n とする。ある世代 g における、 m 個の個体の集合 P を

$$P = \{P_1(g), P_2(g), \dots, P_k(g), \dots, P_m(g)\}$$

のように表わす。また、ひとつの個体の遺伝子配列は、

$$P_k(g) = \{b_5, b_6, b_1, \dots, b_j, \dots, b_3\}$$

のように表わし、始点粒子 a_i に対応する終点粒子 b_j を、遺伝子配列の j 番目に配置する。

粒子が流れに乗って移動し、解析対象の流れが微小時間間隔で撮影されたとすると、それぞれの粒子の近傍の粒子分布パターンは類似していると考えられる。始点粒子、終点粒子と、それぞれの近傍に存在する粒子とをベクトルにより対応づけ、そのベクトルの差の大きさの合計を適応度関数 E とする。ただし、流体が回転運動していると、粒子クラスタも回転するので、始点粒子、終点粒子それぞれの最も近くにある粒子へのベクトルの角度を算出し、この角度だけ、終点粒子クラスタを回転補正する。

適応度関数 E が小さくなれば、類似した粒子クラスタが対応づけられることになるが、複数の類似した粒子クラ

スタの組が存在すると、誤対応が出てくることがある。そこで、この誤対応による局所解から抜け出す適応度関数を導入する。画像内の小領域において、始点粒子、終点粒子の軌跡を表わすベクトルは、近傍のそれと類似している、すなわち、小領域において、流れ場は一樣流であると考えることができる。これより、ある粒子の移動ベクトルとその近傍粒子の移動ベクトルの差の合計を適応度関数 E' とする。 E' はある程度、粒子の時間的対応ができていない状態でないと、意味をなさないため、適応度 E の値が変化せずに、一定の世代以上経過したときに、 E から E' へ移行する。

適応度が得られた個体に対して、選択・淘汰、交叉および突然変異の操作をすることによって、より適応度の高い個体を作っていく。適応度関数 E または E' の値の小さい個体から順位づけを行なう。順位の低い個体を一定数消滅させ、適応度の高い個体を、その数の分だけコピーする。続いて個体集団からランダムに2つの個体を選択し、親個体とする。続いて、親の遺伝子配列を任意の位置で前後に分割し、親1の遺伝子配列の前半部分をそのまま子1に引き継ぎ、残りの遺伝子を親2の遺伝子配列に出現する順に、ひとつずつ順に引き継ぐ。子2は、親2の遺伝子配列の後半部分をそのまま引き継ぎ、残りを親1から引き継ぐ。さらに、ある確率で1つの個体中の任意の2つの遺伝子要素の位置を交換することで、突然変異を実現することで、個体集団の多様性を広げる。

3. ニューラルネットによる速度ベクトル場の推定

2次元非圧縮流体においては、流れ関数 $\Psi(x, y)$ が存在し、2次元速度成分 u, v は、式(1)のように表される。

$$u = \frac{\partial \Psi}{\partial y}, \quad v = -\frac{\partial \Psi}{\partial x} \quad (1)$$

これにより流体の連続の式は恒等的に満足される。この流れ関数 Ψ をニューラルネットワークに学習させることができれば、連続の式を満たす速度ベクトル場を推定することになる。Fig. 6に、そのネットワークの構成を示す。

ニューラルネットワークは、前述の遺伝的アルゴリズムによって得られた速度ベクトルから、流れ関数を学習するので、座標 x, y が入力されると、その点での流れ関数を出力し、速度成分 u, v を計算する。この学習アルゴリズムは、アジョイント・ニューラルネットワークで算出することができる[1]。座標 x, y を入力として与えたときの、ニューラルネットワークの出力 Ψ の入力に関する微分、 $\partial \Psi / \partial y, -\partial \Psi / \partial x$ が、それぞれの速度成分 $u(x, y), v(x, y)$ に一致するように学習させる。学習の際のデータ数を P とし、評価関数 J をつぎのように定義する。

$$J = \frac{1}{2} \sum_p \left[\left\{ \frac{\partial \Psi}{\partial y} - u(x, y) \right\}^2 - \left\{ -\frac{\partial \Psi}{\partial x} - v(x, y) \right\}^2 \right] \quad (2)$$

J が最小となるようなシナプス荷重を、ニューラルネット

ワークの学習則により求める。学習後のニューラルネットワークに、速度ベクトルを計測できなかった領域の座標を入力すれば、その領域における流体の速度ベクトルを推定できる。

前章の方法で計測した速度ベクトル場を Fig. 2 に、その速度ベクトル場にニューラルネットワークによる推定方法を適用した結果を、Fig. 3 に示す。Fig. 2 において、粒子が正しく対応づけられ、速度ベクトル場が計測されていることが分かる。しかし、計測に用いた粒子が存在しない位置での速度ベクトルは計測できていない。Fig. 3 の速度ベクトル場は PIV 標準画像と共に提供されている、正解のベクトル場とほぼ一致する。

Fig. 1 Neural network

Fig. 2 Velocity field measured by the PTV using GA

Fig. 3 Velocity field estimated by the neural network

4. 結論

GAを用いた粒子追跡計測法、および流れ場を学習するニューラルネットワークを導入することにより、流れ場全体の速度ベクトルを推定するという手法を提案し、その有効性を示した。このニューラルネットワークが、どの程度のデータ量で、正しい速度ベクトル場を推定できるのか、また、その能力向上に関して検討中である。

参考文献

- [1] 三井, 川上, 黒江, 森: ニューラルネットワークによるベクトル場の学習法, 第39回システム制御情報学会研究発表講演回論文集, 499/500 (1995)
- [2] S. セーハン, 岩上, 黒江: アジョイントニューロンモデルを用いたニューラルネットワークの学習, 電子情報通信学会記述研究報告, NC90-31, 1/8 (1990)
- [3] 服部, 山田, 木村: 「遺伝的アルゴリズムによる速度場計測, 可視化情報 Vol.17 Suppl. No.2, 133/136 (1997)