PIVにおけるフーリエ変換法の
ニューラルネットによる性能改善*村田 滋^{*1}, 山本 貴幸^{*2}Performance Improvement of the Fourier Transform Method
in Particle Image Velocimetry Using a Neural Network

Shigeru MURATA and Takayuki YAMAMOTO

In this paper, we present a new Fourier transform method with improved PIV measurement accuracy and processing time. A multiple-layer neural network is used in order to suppress obviously incorrect velocity vectors and to reduce the processing time. The information input to the network is the complex phase extracted from the Fourier transforms of two images obtained in a short time interval, and the output is the mean spatial shift of the image pattern in a sampling window. The learning of the correlation between the input and the output is performed using an error back propagation method, and performance tests are carried out using numerically simulated particle images and images obtained experimentally. The test results show that the present method is more robust against velocity fluctuation than the original one and the CPU time is reduced to about 75% of that of the original method.

Key Words: Flow Measurements, Velocity Distribution, Digital Image Processing, Flow Visualization, Neural Network Model, Fourier Transform

1. 緒 言

流れの可視化画像を画像処理して流速場を計測する手法は今日までさまざまな改良が行われ、粒子画像流速測定法(Particle Image Velocimetry, PIV)として機械・建築・土木などの工学分野で幅広く利用されつつある。これは近年画像計測用ハードウェアが比較的入手しやすくなったこと、各時刻における速度場が得られるため視覚的に流れ場が捕らえやすいことなど大きな理由と考えられる。しかし一方で、どのようなアルゴリズムを採ろうとも少なからず誤速度ベクトルが計測されてしまう問題があり、これを回避するための処理手順が速度計測本来のものに比べ極めて膨大になるため、誤速度ベクトルの発生が画像処理による流速場測定法の簡便さを大きく損なっているといえる。一方、奥野ら⁽¹⁾が提案したフーリエ変換法はPIVの代表的な一手法であり、計測原理が数学的に簡潔であるという特徴をもつが、実際の計測では先に述べた誤速度ベクトルが多数発生してしまうという問題をもって

いた。著者らは前報⁽²⁾において、このフーリエ変換法に正規化処理・低域強調フィルタを施すことにより測定精度の改善を行った結果について報告したが、突発的な誤速度ベクトルの低減にはなおいっそうの改良が求められる。

本報では、フーリエ変換法における誤速度ベクトル低減ならびに処理速度の改善を図るため、フーリエ変換法に階層形ニューラルネットワークモデルを適用し、その性能評価を行っている。ニューラルネットをPIVに適用した例として、時刻の異なる画面間で粒子追跡法(Particle Tracking Velocimetry, PTV)の立場から粒子の対応付けを行ったTeoら⁽³⁾、Grantら⁽⁴⁾、流跡線の軌跡識別を行ったCenedeseら⁽⁵⁾、また後処理として誤速度ベクトルを排除したKimuraら⁽⁶⁾の報告があげられるが、本報では粒子画像だけでなく広い処理画像対象をもつ処理法に対して、画像パターン移動量を検出する処理法そのものにニューラルネットを適用している。学習過程を伴うニューラルネットは教師信号を基に、任意の入力に対して高い補間性能を有しており、この特徴を生かして突発的な誤速度ベクトルの低減を図るものである。

* 原稿受付 1996年6月28日。

^{*1} 正員、京都工芸繊維大学工学学部 (〒606 京都市左京区松ヶ崎御所海道町)。^{*2} 三菱電機(株)姫路製作所 (〒670 姫路市千代田町840)。

2. 処 理 法

2・1 フーリエ変換法 まず、フーリエ変換法の処理手順を簡単に述べる。この方法は、微小時間間隔で取り込まれた2枚の瞬間可視化画像を用いて可視化パターンの移動量をパターンマッチングなどにより計測する手法に属する。この時間的に連続した2枚の画像の輝度分布を $f(x, y)$ および $g(x, y)$ と表すと、可視化パターンが $(\Delta x, \Delta y)$ だけ平行移動している場合、両者の関係は次のように表される。

$$g(x, y) = f(x - \Delta x, y - \Delta y) \quad \dots\dots\dots (1)$$

式(1)をフーリエ変換すると、

$$G(\xi, \eta) = \exp\{-j(\Delta x \cdot \xi + \Delta y \cdot \eta)\} \cdot F(\xi, \eta) \quad \dots\dots\dots (2)$$

となる。ただし、 F, G はそれぞれ輝度関数 f, g のフーリエ変換であり、 j は虚数単位である。ここで、 F/G を D と表すと

$$D(\xi, \eta) \equiv F(\xi, \eta)/G(\xi, \eta) \\ = \exp\{j(\Delta x \cdot \xi + \Delta y \cdot \eta)\} \quad \dots\dots\dots (3)$$

であるから、さらに式(3)をフーリエ変換すると、 δ を Dirac のデルタ関数として、

$$d(x, y) = \delta(x - \Delta x, y - \Delta y) \quad \dots\dots\dots (4)$$

が得られる。したがって、式(4)から明らかなように、関数 d のピーク値の位置を検出することによって可視化パターンの移動量 $(\Delta x, \Delta y)$ が求められる。しかし、光切断して観測した二次元可視化画像では、流れの三次元性や速度変動のため、可視化パターンが必ずしも完全に平行移動するわけではなく、式(1)の成立条件が大きく損なわれるとき測定誤差が生じる。本研究では、式(3)に示す $D(\xi, \eta)$ の位相が直接移動量 $(\Delta x, \Delta y)$ を表している点に着目し、式(3)から式(4)へのフーリエ変換を行う代わりに次に述べるニューラルネットワークモデルにより移動量を決定した。このモデルの学習機能により、著しく大きな誤速度ベクトルの抑制が期待でき、また比較的計算量の多いフーリエ変換を3回から式(2)の F と G のみの2回に減らせるため、計算効率の点でも有利になると考えられる。

2・2 ニューラルネット 本研究では図1に示すような階層形ニューラルネットワーク⁽⁷⁾⁽⁸⁾を用いている。図1では入力層および中間層ユニット数 N_i, N_j が等しく、出力層ユニット数 $N_k=1$ である3層ネットワークを表している。左端の入力層に入力された情報は左から右へと一方向に流れ、右端の出力層ユニットから出力される。まず、中間層ユニットでは、次式のように入力情報を総合し、次の出力層へと出力する。

Fig.1 A multiple layer neural net

$$U_j = \sum_{i=1}^{N_i} w_{ji} \cdot I_i + \theta_j \quad \dots\dots\dots (5)$$

$$H_j = \phi(U_j) \quad \dots\dots\dots (6)$$

ただし、上式では入力層の出力 I_i を受けた中間層の出力 H_j を求めるが、上式において、 w_{ji} は入力層ユニット i から中間層ユニット j への結合係数、 θ_j は中間層ユニットのオフセットを示す。また、 ϕ は次式で表されるシグモイド関数である。

$$\phi(x) = \{1 + \tanh(x/u_0)\}/2 \quad \dots\dots\dots (7)$$

u_0 はシグモイド関数の形状を決定するパラメータであり、これが零に近いほど階段関数に近づく。さらに、中間層ユニットの出力を受けた出力層ユニットの出力も式(5)、(6)と同様に表現される。そして、出力層ユニットの出力 O_k とそれに対応した教師信号 T_k のずれを次式で定義する総誤差 E_t で評価し、これを最小化するように各層ユニット間の結合係数と各ユニットのオフセットを変更する。

$$E_t = \sum_{p=1}^{N_p} \sum_{k=1}^{N_k} (T_k^p - O_k^p)^2 / 2 \quad \dots\dots\dots (8)$$

ただし、式(8)において学習すべき入力パターンを上付き添字 p と表し、学習パターン数を N_p とする。

先にも述べたように、本手法では式(3)に示す $D(\xi, \eta)$ の位相 ϕ を入力情報として採っている。 $D(\xi, \eta)$ の実部を D_r 、虚部を D_i と表すと、 ϕ は次のように得られる。

$$\phi = \begin{cases} \cos^{-1}(D_r/|D|) & \text{for } D_i \geq 0 \\ -\cos^{-1}(D_r/|D|) & \text{for } D_i < 0 \end{cases} \quad \dots\dots\dots (9)$$

デジタル画像処理でフーリエ変換を離散的に行うため、フーリエ変換を施す窓領域の大きさを $M \times M$ とすると、任意の空間周波数成分の位相 ϕ_i は入力信号 I_i の領域が半開区間 $(-1, 1]$ となるよう、

$$I_i = \phi_i / \pi \quad \dots\dots\dots (10)$$

として与えている。

教師信号 T_k は、ニューラルネットの出力に対応させて、その値域を次のように $(0, 1)$ に規準化している。

$$T_k = \Delta x / M + 0.5 \quad \dots\dots\dots (11)$$

Fig. 2 Input information to a neural network

また、学習には階層形ニューラルネットの学習に標準的に用いられる誤差逆伝ば法⁽⁷⁾⁽⁸⁾を用いており、学習パターン数 N_p は移動量 Δx のとり得る数、すなわち $M-1$ である。学習時の入力情報である位相 ϕ は、式(3)右辺の指数部を離散的に表した次の理論式によって与えている。ただし、 m, n はそれぞれ x, y 方向空間周波数を表している。

$$\phi(m, n) = \cos^{-1}[\cos \{2\pi(m \cdot \Delta x + n \cdot \Delta y)/M\}]$$

$$(m, n=0, 1, \dots, M-1) \dots \dots \dots (12)$$

図2に、本研究で入力情報として用いたフーリエ成分を示す。それぞれ $M=16$ の場合について (0,0) 定常成分から (7,7) 波数成分までのフーリエ成分のみを正方形格子状に示している。左上隅の I_1 が (0,0) 定常成分であり、図2(a)は水平方向の並び $I_1 \sim I_8$ から x 方向の移動量 Δx を、垂直方向の並び $I_1 \sim I_8$ から y 方向の移動量 Δy を求める場合で、8入力1出力のニューラルネットを2組別々に構築する。一方、図2(b)は (0,0) 定常成分から (4,4) 波数成分の低周波数に相当する16成分のみを入力する場合で、16入力2出力のニューラルネットを構築して $\Delta x, \Delta y$ を同時に求める。図2のような入力情報を採用した理由は、図2(a)の場合は、図に示すフーリエ成分が $M \times M$ 画像の x, y 軸上への一次元投影像に関するフーリエ変換を表しており、 $\Delta x, \Delta y$ を個々に求めるために適切であるからである。また、図2(b)の場合は、前報⁽²⁾においてフーリエ変換法では低域強調フィルタが誤差低減に有用であるとの結果を得ているためである。なお、本研究では、図2(a)、(b)の二つの異なるニューラルネットについて性能を検討しているが、前者を BPN in 1D、後者を BPN in 2D と表記している。

3. 性能試験

3.1 学習過程 まず、ニューラルネットの学習に関する結果を示す。表1は用いた3層ニューラルネ

Table 1 Parameters of three-layer neural nets

	M	u_0	N_i	N_j	N_k
BPN in 1D	16	0.50	8	8	1
BPN in 2D	16	0.60	16	8	2

Fig. 3 Comparison of learning history

ットの仕様をまとめている。図3は、 $M=16$ の場合について、横軸に学習回数、縦軸に式(8)に示した総誤差 E_t をとり、 $\Delta x, \Delta y$ を別々に求める一次元手法 (BPN in 1D) と同時に出力する二次元手法 (BPN in 2D) について学習曲線を比較している。一次元手法は学習速度が速く、およそ500反復数で総誤差が計算機の丸め誤差のオーダーに達しており、学習が完了していることがわかる。これに比べ、二次元手法は収束性が低く、1000反復数に至っても総誤差は約 10^{-3} であるが、十分な学習が必ずしも未知入力に対して高精度の出力を保証するとは限らないので、二次元手法では1000回で学習を打ち切っている。二次元手法の収束性が低い理由は、式(12)からわかるように、異なる移動量 $\Delta x, \Delta y$ の組に対して同じ位相 ϕ をとり得る場合が起こり、入出力関係を一意的に決定し難いことが考えられる。

3.2 可視化像モデル 学習により構築したニューラルネットの性能を検討するため、乱数を用いて作成した模擬可視化像に本手法を適用し、その測定性能を検討する。ここでは単一のフーリエ変換窓を考え、トレーサ粒子の空間分布・移動量を乱数で与える。測定精度に影響を与える因子として、窓内の空間速度変動と窓境界から流入流出する粒子を考慮すると、それぞれの影響のみを表した粒子画像モデルは図4のように示される。図4(a)は速度変動を表しており、各粒

Fig. 4 Two models of particle images

子の移動量は標準偏差 $\sigma(\text{pixel})$ の正規分布をなすよう与えられる。窓境界から流出した粒子は相対する窓境界から流入させ、離散的フーリエ変換の前提である信号の周期性を確保している。図 4(b) は粒子の流入流出を表しており、流入粒子はその流入位置を乱数で決定している。すべての粒子は一定の移動量をもたせ、速度変動の影響を排除している。

3.3 試験結果 3.2 節で示した粒子画像モデルの画像 500 枚について、本手法を適用した結果を図 5 および図 6 に示す。前者は標準偏差 $\sigma=1(\text{pixel})$ の速度変動モデル、後者は粒子流入流出モデルに対する結果であり、ともに縦軸に平均絶対値誤差率、横軸に可視化パターンに与えた平均移動量をとっている。図 5, 6 中の記号は x 方向および y 方向移動量の別、手法の違いを表しており、FT Method は奥野によるフーリエ変換法の結果であることを示している。

図 5 では、前報⁽²⁾ において報告したようにフーリエ変換法は空間的速度変動に影響されやすく、このモデルであれば $\sigma=0$ の場合誤差零となるにもかかわらず、15%以上の誤差を生じている。本手法はフーリエ変換法よりも誤差が低く抑えられており、特に二次元手法では平均移動量の広い範囲にわたって約 7%の誤差に低減されている。したがって、ニューラルネットを用いて速度変動の影響が良好に抑制できることがわかる。

一方、図 6 では、平均移動量の絶対値が大きくなると誤差が増加することがわかるが、全体的に本手法よりもフーリエ変換法のほうが誤差が低く、本手法の測定精度は画像パターンの周期性が確保されなくなることによって大きな影響を受けることが示されている。現実には、トレーサ粒子がすべて同じ移動量で運動することはほとんどあり得ないので、本手法とフーリエ変換法に図 6 のような大きな測定精度の差が生じるとは考えられないが、4 章では、流速の分布計測において、この粒子の流入流出の影響を抑制する手法について述べる。

Fig. 5 Effect of velocity fluctuation on measurement accuracy

Fig. 6 Effect of non-periodicity of particle pattern on measurement accuracy

4. 流速分布測定

画像パターンの移動量を検出する粒子画像流速測定法では、通常 1 枚の粒子画像中に格子状に測定窓を設定して速度分布を求める。本章では、粒子の流入流出の影響を排除するため、注目する測定窓とその 8 近傍に隣接する測定窓で検出された位相情報から、注目する測定窓における位相を LMedS 法⁽⁹⁾ を用いて推定する手法を述べ、その性能評価を行っている。

4.1 位相情報推定 LMedS 法 (Least Median of Squares Regression) では、標本データと測定値との誤差の中央値 (median) を最小とすることによって推定値を求める。これにより、突発的に大きな誤差をもつ例外値に左右されることなく推定値が求められる。LMedS 法による推定値決定手順を次に示す。

(手順 1) N 個の標本値を小さい順にソートし、これを y_i ($i=1, \dots, N$) とする。

(手順 2) 区間幅 $y_{h+i-1} - y_i$ が最小となる i を求め $i=H$ とする。ただし、 h は本報では $h=N/2+1$ とする。

(手順3) 区間 H の中央値 Y を次式より求める。

$$Y = (y_{h+H-1} - y_H) / 2 \dots \dots \dots (13)$$

注目しているフーリエ変換窓 W_{ij} の周囲には図7のように8近傍の窓 $W_{i-1,j-1} \sim W_{i+1,j+1}$ があり、これら 3×3 の九つの窓におけるフーリエ変換比 D の実部 D_r および虚部 D_i について、すなわち $N=9$ として上述の LMedS 法による推定を行う。

4.2 数値シミュレーション 本節では速度分布が明らかな数値流体解析結果を用いて、LMedS 法を適用した本手法の測定性能を評価する。第1画像として、半径1の円柱の中心を原点にして、 $-5 \leq x, y \leq 5$ の領域にトレーサ粒子を乱数で3000個設定し、次に、第2画像として、放物形多重格子法⁽¹⁰⁾による数値解に基づき、時間 Δt 後の粒子位置を決定している。実際のぼけを伴う画像を表すため、粒子像は粒子位置を (x_0, y_0) として次の濃度分布で表している。

$$h(x, y) = \exp \left[-\{(-x-x_0)^2 + (y-y_0)^2\} / (2\rho^2) \right] \dots \dots \dots (14)$$

円柱直径を代表長さにとったレイノルズ数は100で、測定点は $-2.0 \leq x \leq 2.5$, $-2.25 \leq y \leq 2.25$ の領域に

Fig. 7 Layout of sampling windows

15×15 点とり、また、2画像の時間間隔 Δt は0.06、画像分解能は 128×128 、画像ぼけのパラメータ ρ は4としている。

図8は、(a)数値解、(b)本手法 ($M=16$)、(c)フーリエ変換法 ($M=16$) による速度ベクトル分布を比較している。本手法の結果は円柱近傍で流れ方向が適切でない速度ベクトルが見られるが、本手法では連続値を出力するので全体を通して速度分布が滑らかで、数値解に近い分布が得られている。一方、フーリエ変換法では、5箇所ほど極めて異常な誤速度ベクトルが生じ、また速度値も画素単位で段階的に変化するため、速度分布に不連続性が認められる。

表2に以上の結果をrms誤差でまとめている。LMedS法を適用しない本手法は、粒子の流入流出の影響でフーリエ変換法に比べ誤差が大きくなっているが、LMedS法の適用により約1/3に誤差が低下している。

4.3 可視化像への適用 最後に、実際の流れの可視化画像に本手法を適用した結果を示す。対象流れ場は、一辺40mmの正方形柱後方の流れであり、正方形断面の対角線を主流方向に $\pi/4$ 傾けて設置した。可視化は粒径 $80 \sim 200 \mu\text{m}$ 、比重1.05の白色ナイロン11粒子で行った。実験条件はレイノルズ数4000、電子シャッター速度 $1/125 \text{ s}$ である。処理画像は $1/16 \text{ s}$ 間隔のものを二値化操作を施さない濃淡原画像のまま扱

Table 2 Comparison of root mean square error

	RMS ERROR
BPN in 2D	1.43(pixel)
BPN in 2D(LMedS)	0.44(pixel)
FT Method	0.82(pixel)

Fig. 8 Comparison of detected velocity vectors

Fig. 9 Velocity vectors for flow visualization images

Table 3 Comparison of CPU time

	M	CPU-TIME
BPN in 2D	16	18.0(sec)
FT Method	16	24.1(sec)
FT Method	64	326.5(sec)

い、測定点は 15×15 点とっている。また、画像分解能は 0.41 mm/pixel である。

図 9(a)～(c)はそれぞれ、LMedS 法を適用した本手法 ($M=16$)、正規化処理を伴うフーリエ変換法 ($M=16, 64$) で求めた速度分布を比較している。ただし、上段と下段は異なる 2 時刻の結果である。主流方向は左から右であり、主流と垂直方向に振動する流れが認められる。フーリエ変換法は変換窓の空間分解能が高いほど、すなわち M が大きいほど測定精度がよいことがすでに明らかになっている。図 9 からわかるように、 $M=16$ の場合のフーリエ変換法では多くの誤速度ベクトルが発生しているが、本手法では滑らかな速度分布が得られており、また、高精度な $M=64$ の場合のフーリエ変換法の結果によく一致している。

表 3 には、先の条件で 1 枚の画像を処理する処理時間がまとめられている。使用計算機はサンマイクロシステムズ Sparc Station 20 (60 MHz) である。本手法はフーリエ変換法よりフーリエ変換が 1 回少ない分、同じ $M=16$ において処理時間が約 75% に短縮化されている。さらに、図 9 で示したように同程度の測定結果を示す $M=64$ のフーリエ変換法と比べると、約 5.5% の処理時間で測定結果が得られることがわかる。

5. 結 言

本研究では、フーリエ変換法に階層形ニューラルネットワークを適用し、入力可視化パターンとその移動量の関係を学習させることによって、移動量の検出精度・処理時間の改善を図った。まず、数値解析解による単一測定窓でのモデル試験では、本手法は空間速度変動に強く、測定窓境界部での粒子の流入流出に敏感であることが示された。また、粒子の流入流出の影響を低減するため、LMedS による推定法を本手法に適用したところ、速度分布計測において測定精度・処理時間が改善できることを示した。今後、多次元画像の測定に発展させることや、可視化パターンを直接入力するネットワークを構築して処理速度を向上させることなどが課題と考えられる。なお、本研究では

LMedS 法に関して、京都工芸繊維大学 塩山忠義教授にご助言を賜った。記して謝意を表する。

文 献

- (1) 奥野武俊・木下民法, 第4回流れの計測大阪シンポジウム講演論文集, (1987), 177-184.
- (2) 嶋田浩・村田滋・木瀬洋, 機論, **58**-552, B(1992), 2472-2478.
- (3) Teo, C. L., Lim, K. B., Hong, G. S. and Yeo, M. H. T., *Proc. IEEE Int. Conf. Syst. Man Cybernet.*, (1991), 1535-1538.
- (4) Grant, I. and Pan, X., *Exp. Fluids*, **19**-3(1995), 159-166.
- (5) Cenedese, A., Paglialunga, A., Romano, G. P. and Terlizzi, M., *Proc. 6th Int. Symp. Appl. Laser Tech. Fluid Mech.*, LISBON, (1992), chap. 27.1.
- (6) Kimura, I., Kuroe, Y. and Ozawa, M., *J. Flow Visualiz. Image Process.*, 1-4(1993), 261-269.
- (7) 飯沼一元編, ニューロコンピュータ, (1989), 38-84, 技術評論社.
- (8) 矢川元基編, ニューラルネットワーク, (1992), 2-46, 培風館.
- (9) 栗田多喜夫, 電子情報通信学会誌, **76** 12(1993), 1293-1297.
- (10) 村田滋・里深信行・木瀬洋, 機論, **58**-545, B(1992), 44-50.