B 1 1 8

自己組織化マップを用いた棒状物体 3次元計測アルゴリズムの開発

森川 敏英[○](京工繊大院), 村田 滋(京工繊大)

Development of measuring algorithm for slender objects in three-dimensional space using a self-organizing map

Toshihide MORIKAWA and Shigeru MURATA

ABSTRACT

This paper presents the clustering algorithm for detected points of slender objects in 3D space using a self-organizing map(SOM) and its test results in numerical simulations. In the 3D measurement of slender objects using digital holography, a lot of object points are detected for each slender object. The present method can identify the detected points for each object to know the object information, such as shape and inclination. The clustering performance is checked in numerical simulations. The simulations employ two different models in which the detected points are isotropically and linearly distributed in 3D space. The test results show that this algorithm can successfully identify several target clusters in 3D space.

Keywords: Slender objects, Self-organizing map, 3D measurement, Digital holography, clustering

1. はじめに

近年、レーザ光の可干渉性を利用したホログラフィ法の一つであるデジタルホログラフィ⁽¹⁾を用いた計測法が注目されている。この手法は一般の画像処理計測と同様、像として対象物が再生されるため様々な形状のものにも適用出来る。粒子が対象の場合は、ある1点の奥行き位置(カメラ等の観測機器との水平距離)で像は結像し、1点の空間位置が検出される。しかし、アスペクト比が大きい対象物の場合では、図1の様に物体の一部である点a,点b,点cはそれぞれ $z=z_1, z_2, z_3$ と複数の奥行き位置で像が結像し、複数の空間位置が検出される。図1はデジタルホログラフィの再生過程であり、 ξ - η 面はホログラム面、 x - y 面は再生面、 z は奥行き再生方向である。

Fig.1 Reconstructed images for a slender object
in digital holography

物体が1つであれば物体の姿勢計測⁽²⁾に問題無いが、近傍に2つ以上物体があれば検出点(候補点)が混ざり、計測精度を低下させてしまう可能性がある。そこで、物体候補点に正確にラベルを付ける為に3次元クラスタリングする事は姿勢計測精度を高める上で非常に有効である。

そこで本報では、Kohonenにより一般化された自己組織化マップ(Self-organizing map, SOM)⁽³⁾⁽⁴⁾の考え方を基にした3次元物体の候補点をクラスタリングするアルゴリズムを考えた。又、正規分布状に広がって分布した候補点群と、アスペクト比の大きい一番シンプルな形状である直線状に分布した棒状物体候補点群の2つの物体モデルを用い、数値シミュレーションにおける本手法アルゴリズムの性能評価を行った結果について報告する。

2. クラスタリングアルゴリズム

今回行った自己組織化の法則として、候補点同士が互いに影響し合う要素を互いの引力と見立てる。よって、お互いが近くにあればある程大きく影響し合うという方法を採用している。そこで、候補点同士が影響して近づく様子を図2に示す。

Fig.2 Basic concept of particle clustering

SOM に従うと 1 回の反復計算により候補点があるルールに従って移動させ、少しずつ候補点同士を引き寄せていく事ができる。図 2 は 1 回の反復計算における i 番目の候補点 (黒点) (x_i, y_i, z_i) が j 番目の候補点 (白点) (x_j, y_j, z_j) に影響を受け、 j 番目の粒子に引き寄せられる様子の概念図である。 r_{ij} は候補点間距離、 dx_{ij} , dy_{ij} , dz_{ij} は各座標軸方向へ影響を受ける量、 ϕ_{ij} は x - z 面内での角度、 θ_{ij} は x - z 面からの仰角であり、次式で表される。

$$\begin{aligned} dx_{ij} &= \alpha f(x_{ij}, y_{ij}, z_{ij}) \cos \theta_{ij} \cos \phi_{ij} \\ dy_{ij} &= \alpha f(x_{ij}, y_{ij}, z_{ij}) \sin \theta_{ij} \\ dz_{ij} &= \alpha f(x_{ij}, y_{ij}, z_{ij}) \cos \theta_{ij} \sin \phi_{ij} \end{aligned} \quad \dots\dots(1)$$

$$\begin{aligned} \theta_{ij} &= \sin^{-1}(y_{ij} / r_{ij}) \\ \phi_{ij} &= \tan^{-1}(z_{ij} / x_{ij}) \\ r_{ij} &= \sqrt{x_{ij}^2 + y_{ij}^2 + z_{ij}^2} \\ (x_{ij}, y_{ij}, z_{ij}) &= (x_j - x_i, y_j - y_i, z_j - z_i) \end{aligned} \quad \dots\dots(2)$$

α は加重変化率であり、反復計算を加速する為のパラメータとする。 f は候補点同士が引き寄せ合う強さとし、候補点間距離に従う正規分布の確率密度関数の値をとり、次式で表す。この f を反復計算の重み関数とする。

$$f(x_{ij}, y_{ij}, z_{ij}) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2} \left\{ \left(\frac{x_j - x_i}{\sigma_x} \right)^2 + \left(\frac{y_j - y_i}{\sigma_y} \right)^2 + \left(\frac{z_j - z_i}{\sigma_z} \right)^2 \right\}} \dots\dots(3)$$

$\sigma_x, \sigma_y, \sigma_z$ は、各座標軸方向の標準偏差である。 m 個の候補点により影響を受け、1 回の反復計算での i 番目候補点の移動量は次式で表される。

$$(dx_i, dy_i, dz_i) = \left(\sum_{k=1}^m dx_{ik}, \sum_{k=1}^m dy_{ik}, \sum_{k=1}^m dz_{ik} \right) \dots\dots(4)$$

N_c 回の計算後の i 番目の候補点の座標 $(x_i^{N_c+1}, y_i^{N_c+1}, z_i^{N_c+1})$ は N_c-1 回目の計算後の座標 $(x_i^{N_c}, y_i^{N_c}, z_i^{N_c})$ を用いて次式で表される。

$$(x_i^{N_c+1}, y_i^{N_c+1}, z_i^{N_c+1}) = (x_i^{N_c} + dx_i, y_i^{N_c} + dy_i, z_i^{N_c} + dz_i) \dots\dots(5)$$

又、より迅速に組織化を行う為に、標準偏差・加重変更する閾値 s_e を設ける。全候補点数を n とし、1 回の反復計算での全候補点移動量の合計が $s_e = n/1000$ pixel を下回ると次式の様に変化させる。

$$\begin{aligned} \alpha &\leftarrow \alpha / \beta \\ \sigma &\leftarrow \beta \sigma \end{aligned} \quad \dots\dots(6)$$

又、 β ($0 < \beta < 1$) は減衰率であり、今回は α の初期値を $\alpha_0 (=0.005)$ 、 β の初期値を $\beta_0 (=0.99)$ としている。一回の反復計算で、各候補点の移動量が $\alpha_1/2$ を下回る個数が $0.95n$ を超えると反復計算処理終了とする。そして、反復計算後の各候補点の座標において候補点間距離が 1pixel 未満のものには同ラベルを付ける。

対象が等方的に広がっているものであれば上記したアルゴリズムで複数の物体候補点をクラスタリング出来る。しかし、棒の様にアスペクト比が大きいものになると、近傍に違う物体の候補点があれば上手くクラスタリング出来ない。そこで、図 3 の左から右の様に正規分布を x 軸方向に引き延ばし (y, z 軸方向に縮める)、その分布の値を重み関数にする。

Fig.3 Weighting function f

図 4 左の様に注目候補点 i (黒点) を中心に、ある近傍 R より内にある対象候補点 (白点) との平均角度 (θ_i, ϕ_i) を求め、対象候補点全ての座標 (x_{j1}, y_{j1}, z_{j1}) を座標変換し、変換後の座標 (x_{j2}, y_{j2}, z_{j2}) を次式に示し、その座標における分布の値を用いる。そうすると近傍にある棒状物体の候補点だけを集める事が出来る。 θ_i と θ_{ij1} 、 ϕ_i と ϕ_{ij1} が共に似た値の時、 x 軸に近づく。

Fig.4 Coordinate transform

$$\begin{pmatrix} x_{j2} \\ y_{j2} \\ z_{j2} \end{pmatrix} = \begin{pmatrix} r_{ij} \cos \theta_{ij2} \cos \phi_{ij2} \\ r_{ij} \sin \theta_{ij2} \\ r_{ij} \cos \theta_{ij2} \sin \phi_{ij2} \end{pmatrix} \dots\dots(7)$$

$$\begin{aligned} \theta_{ij2} &= \theta_{ij1} - \theta_i \\ \phi_{ij2} &= \phi_{ij1} - \phi_i \end{aligned} \quad \dots\dots(8)$$

又、等方的に広がっているものは中心に候補点が密になっているが、棒状物体の候補点は数密度が一定なので一本の棒が分断されてクラスタリングされない様に、近

傍にある候補点全てに同ラベルが付くまで計算処理は終了しない様に計算終了条件を変更する。

3次元においては上記の方法で反復計算し、2次元では $\phi_{ij} = \phi_i = \phi_{ij1} = \phi_{ij2} = 0$ として反復計算する。

3. 数値シミュレーション

3.1 等方的に分布した候補点群

1つの候補点集合群を、2次元では $n_p=50$ 、3次元では $n_p=100$ の候補点数で σ_1 の標準偏差で分布させた。その候補点群を標準偏差 $\sigma_2(=\sigma_x=\sigma_y=\sigma_z)$ の正規分布における確率密度関数値を用いてクラスタリングする。集合群の座標は一様乱数で2モデル発生させ、結果はその平均値をとる。

3.1.1 候補点群が1個の場合

1つの集合群をクラスタリングする場合、候補点を分布した正規分布の標準偏差 σ_1 (約70%) 以内にある候補点を同ラベル付けできる σ_2/σ_1 の値の範囲を調べる。図5, 図6はそれぞれ2次元平面, 3次元空間で、 σ_2/σ_1 の値を変えたときの正しくクラスタリングされた候補点の割合を表している。

Fig.5 Relation between σ_1 and σ_2 in 2D problem

Fig.6 Relation between σ_1 and σ_2 in 3D problem

図5, 図6の結果より、70%以上正しくラベル付けするには、 $\sigma_1 \geq 10\text{pixel}$ のとき、 $\sigma_2/\sigma_1 \geq 0.4$ でなければならない。

3.1.2 候補点群が2個の場合

3.1.1の結果より、 $\sigma_1 \geq 10\text{pixel}$ のとき $\sigma_2/\sigma_1 = 0.4$ で70%以上の候補点をクラスタリング出来る事が分かった。次に、候補点群間距離を d とし、 d/σ_1 をどれだけ大きくすれば正しく2つにクラスタリング出来るかを調べた。図7, 図8はそれぞれ2次元平面, 3次元空間で d/σ_1 の値を変えたときの正しくクラスタリングされた候補点の割合

を表している。

Fig.7 Relation between d and σ_1 in 2D problem

Fig.8 Relation between d and σ_1 in 3D problem

図7・図8より、 $\sigma_1 \geq 10\text{pixel}$ 、 $\sigma_2/\sigma_1 = 0.4$ のとき、 $d \geq 1.4\sigma_1$ であれば、70%以上の候補点をクラスタリング出来る事が分かった。

図9は $\sigma_1 = 10\text{pixel}$ で $d = 1.4\sigma_1$ 、 $\sigma_2/\sigma_1 = 0.4$ の時のクラスタリング結果である。尚、丸の大きさは点密度を表したものであり、556回の反復計算後に80%クラスタリングされた。

Fig.9 Result of particle clustering for two groups in 3D space

3.1.3 候補点群が多数個の場合

候補点群が多数あってもクラスタリング出来るか、2次元・3次元の場合について調べた。

図10は、 $256 \times 256\text{pixel}$ の面内に、 $\sigma_1 = 10\text{pixel}$ で分布した20の集合群 ($n_p=20, n=400$) を $\sigma_2/\sigma_1 = 0.4$ でクラスタリングした結果であり、1539回の反復計算で78%クラスタリングされた事を示している。ただし、 $d/\sigma_1 \geq 1.3$ である。

又、図11は、 $128 \times 128 \times 128(\text{voxel})$ の空間内に、 $\sigma_1 = 10\text{pixel}$ で分布した20の集合群 ($n_p=20, n=400$) を $\sigma_2/\sigma_1 = 0.4$ でクラスタリングした結果であり、1519回の反復計算後に72%クラスタリングされた事を示してい

る。ただし、 $d/\sigma_1 \geq 1.4$ である。

Fig.10 Result of particle clustering for twenty groups in 2D space

Fig.11 Result of particle clustering for twenty groups in 3D space

3.2 直線状に分布した候補点群

3.1の結果より、2次元アルゴリズムを3次元に拡張してもクラスタリング精度に大差は無いので、直線状に分布した候補点群は3次元アルゴリズムのみの検討とする。又、候補点群が一本の場合は引き延ばした正規分布を用いなくてもクラスタリング出来るので、直線状に分布した候補点群が2つ以上の場合を対象とする。

3.2.1 候補点群が2個の場合

主な2物体の配置には3パターンあるので、それぞれの配置で物体間の最短距離 d と図4の座標変換させる角度を決める候補点の窓の広さ R との関係を調べる。ここで、一本の棒状物体の長さを30pixel($n_p=15$)とする。又、今回は正規分布の x 軸方向への引き延ばし方として、 $\sigma_x=10\text{pixel}$, $\sigma_y=\sigma_z=1\text{pixel}$ とし、 $d=5\text{pixel}$ のときに正しくクラスタリング出来る R の値を検討する。

2物体が平行、直交、ねじれの位置にある時、 d はそれぞれ図12の様に定義する。

Fig.12 Two groups of particles paralleled(left), right-angled(center) and twisted(right)

図13は $d=5\text{pixel}$ のモデルを $R=5\text{pixel}$ としたときのクラスタリング結果で、反復回数はそれぞれ1150回、807回、790回であった。

Fig.13 Result of particle clustering for Fig.12 in 3D space

いずれの場合も $d \geq R$ の時は100%正確にクラスタリング出来た。尚、 $d < R$ の時は1つにクラスタリングされてしまう結果となった。

3.2.2 候補点群が多数個の場合

128*128*128(voxel)の空間内に、1本の長さが各30pixel($n_p=15$)の棒を20本乱数で配置させ、 $R=5\text{pixel}$ でクラスタリングした結果を図14に示す。

Fig.14 Result of particle clustering for twenty groups of slender objects in 3D space

図14の結果は917回の反復計算後に100%正確にクラスタリングされた事を示した。ただし、 $d \geq 5\text{pixel}$ である。

4. おわりに

本研究では自己組織化マップにより、①等方的に広がって分布した候補点群と、②直線状に分布した候補点群を3次元クラスタリングするアルゴリズムを開発した。その数値シミュレーションの結果、①は $d/\sigma_1 \geq 1.4$ ならば $\sigma_2/\sigma_1=0.4$ のとき、70%以上(本研究の目標値)正確にクラスタリング出来る結果であった。②は $d \geq R$ であれば100%正確にクラスタリング出来る結果であった。

尚、本研究は日本学術振興会平成17・18年度科学研究費補助金基盤研究(C) 17560148 および三豊科学技術振興協会(MAST)研究助成を受けて実施された。記して謝意を表する。

参考文献

- 1) Murata, S., et al., Optics & Laser Tech., Vol. 32 (2000), 567.
- 2) 森川敏英・村田滋, 可視化情報, Vol. 25, Suppl No. 2, (2005), 363-364
- 3) 森原崇文・村田滋, 日本機械学会論文集, 70-698, B (2004)
- 4) Kohonen, T., Self-organization and Associative Memory, Second Edition, (1988), Springer-Verlag, Berlin.