

疎な距離画像からの物体形状記述

8C-8

堀越 力 鈴木 智

NTT ヒューマンインタフェース研究所

1 はじめに

物体形状の認識・生成においては、その形状が何らかのモデルで記述できていることが望ましい。その際、対象物の表面形状データから元の物体形状を推定することになり、記述するためのモデルの決定と、そのモデルで記述できるような部品への分割が必要になる。あるデータが与えられた時に、そのデータをモデル(関数)で記述する手法として最小二乗法がある。このときデータの特徴を効率良く表現するモデルが必ずしも二乗誤差が最小のモデルであるとは断定できない。なぜならば、細かいモデルを多数用いれば、それだけ誤差の小さな記述が可能だからである。我々は細かな複数の部品を統合することにより、最少の部品による記述を求める手法としてAIC(Akaike's Information Criterion) [1] という情報量規準を導入した。

2 AIC とは?

あるデータに関するモデル推定手法として最尤法があるが、異なる数のパラメータを有するモデルどうしの比較ができない。AICはこのパラメータ数の違いによる推定のずれを考慮した規準であり次のように定義される。

$$AIC = -2 \times (\text{最大尤度}) + 2 \times (\text{自由パラメータ数}) \quad (1)$$

ふたつのモデル $s_1(x), s_2(x)$ による記述結果に格段の差があるときは右辺第1項に著しい差が現れ、どちらのモデルでも記述結果が同等である場合第2項が作用してパラメータの数が少ない方が良いものとして評価される。

3 異なるデータセットの同一性の判定

対象物 O が2つのデータセット x_1, x_2 で表現されていたとする。これら関数 $s(x_{ki}; \theta_k)$ で記述しようとしたとき、それぞれのデータセットが異なる正規分布モデルに従うと仮定するならば各データセットの確率分布モデルは、

$$f(x_{ki}|s(x_{ki}; \theta_k), \sigma_k^2) = \frac{1}{\sqrt{2\pi\sigma_k^2}} \exp \left\{ -\frac{1}{2\sigma_k^2} (y_i - s_k(x_{ki}; \theta_k))^2 \right\}, \quad k=1, 2 \quad (2)$$

と表わすことができる。

各データセットはパラメータ空間 $\Theta = \{\theta_k, \sigma_k^2\}$ で定義された自由パラメータを持つ。以後、 $s(x; \theta_k)$ を $s_k(x)$ と表す。

まず n_k 個のデータからなるデータセット x_k の尤度関数 L_k は、

$$L_k(x_{k1}, \dots, x_{kn_k} | \theta_k, \sigma_k^2) = \prod_{i=1}^{n_k} f(x_{ki} | s_k(x_{ki}), \sigma_k^2) \quad (3)$$

となり、対数尤度は次式で表される。

$$\ell = -\frac{n_k}{2} \log 2\pi - \frac{n_k}{2} \log \sigma_k^2 - \frac{1}{2\sigma_k^2} \sum_{i=1}^{n_k} (y_i - s_k(x_{ki}))^2. \quad (4)$$

この最大対数尤度は、

$$\hat{\ell} = -\frac{n_k}{2} \log 2\pi - \frac{n_k}{2} \sum_{i=1}^{n_k} \hat{\sigma}^2 - \frac{n_k}{2} \quad (5)$$

として求められる。ただし、 $\hat{\sigma}^2$ は、データセット x_{ki} に属するデータの残差分散であり、

$$\hat{\sigma}^2 = \frac{1}{n_k} \sum_{i=1}^{n_k} (y_i - s_k(x_{ki}))^2 \quad (6)$$

2個の各データセットが互いに独立であると仮定するならば、この対象物 O 全体の尤度関数は、各データセットの尤度の積で表され、最大対数尤度関数は次のように書き換えられる。

$$\hat{\ell}_1 = -\frac{n}{2} \log 2\pi - \frac{n_1}{2} \log \hat{\sigma}_1^2 + \frac{n_2}{2} \log \hat{\sigma}_2^2 - \frac{n}{2}, \quad (7)$$

ここで n は入力データの総数である。このときのAICは、

$$AIC(s_1, s_2, \sigma_1, \sigma_2) = -2\hat{\ell}_1 + 2 \times 2 \times (\text{自由パラメータ数}) \quad (8)$$

となる。

次にこれらのデータセット x_1, x_2 が1つのモデルとして記述できると仮定するならば、 $s_1 = s_2 = s', \sigma_1 = \sigma_2 = \sigma'$ となり、対象物 O を記述した時の $AIC(s', \sigma')$ は次のように表される。

$$AIC(s', \sigma') = -2\hat{\ell}_2 + 2 \times 1 \times (\text{自由パラメータ数}) \quad (9)$$

但し、

$$\hat{\ell}_2 = -\frac{n}{2} \log 2\pi - \frac{n}{2} \log \hat{\sigma}'^2 - \frac{n}{2}$$

$$\hat{\sigma}'^2 = \frac{1}{n} \left(\sum_{i=1}^n (y_i - s'(x_i))^2 \right)$$

そして、 $AIC(s_1, s_2, \sigma_1, \sigma_2) > AIC(s', \sigma')$ が成り立つならば、両者のデータセットは同一モデルで記述できることになり、対象物 O は、1つの関数モデル $s'(x)$ で表現できると判断することができる。

3D Shape Description from Sparse Range Data

Tsutomu HORIKOSHI, and Satoshi SUZUKI

NTT Human Interface Laboratories

4 適用例

4.1 対象物の分割

我々は関数モデル $s(x)$ として超二次関数を用いた。まず、対象物をこの関数で記述できる部品に分割するため、球面再サンプリング法 [2] を適用した。この手法は超二次関数を対象物の内側に近似させ、関数外部のデータを分離する。そして、この分離されたデータに再度関数を近似させていくことにより、対象物を超二次関数で記述できる凸部分に分割する手法である。

この複数に分割された部品を統合していくことにより、最終的には最少部品による記述を求める。

4.2 部品の統合

超二次関数は5個の自由パラメータを持つ。また関数近似において、データの持つワールド座標系から関数中心座標系に変換する並行移動のパラメータ3個と、回転パラメータ3個が必要である。従って、全部で11個の自由パラメータを有することになる。そこで各部品に対して超二次関数を近似したときの各部品毎の残差を求め、AIC を求める。つまり部品の数が N 個の場合、自由パラメータ総数は $N \times 11$ 個になり、AIC として

$$AIC = \sum_{k=1}^N \left[n_k \log \left(\frac{1}{n_k} \sum_{i=1}^{n_k} (1 - s_k(x_{ki}))^2 \right) \right] + 2 \times N \times 11 \quad (10)$$

を求める。

部品の統合は、先の同一性の判定で行なった要領で、各部品どうしの組合せに対しての AIC を求めていく。

(1) 輪郭データへの適用

図1(a)に示すような輪郭データを再サンプリング法を用いて分割を行なうと、図1(b)に示すような7つの部品に分割された。7個の部品の中から $k (< 7)$ 個取り出して1つの部品とする組み合わせを求め、各組み合わせに対して AIC を計算する。つまり、 k 個の部品のデータを1つのデータに統合し、このデータへの近似を行ない、残った部品に関しても同様にそれぞれ近似を行ない、各部品の近似誤差を求める。

1つの部品で記述できないような統合を行なうと、二乗誤差が大きくなり、いくつかの組み合わせが同程度の誤差である場合は全体の部品の数が少ない組み合わせが選ばれることになる。7個の部品の場合 AIC = -457.8 であったが統合の結果、最小となった組み合わせでは AIC は -1033.5 になった。


(2) 3次元データへの適用

3次元画像に適用した。部分的に疎なデータであり、最初の分割によって7個の部品に分割された。この時、AIC は 1559 であったが、最終的に5個の部品に集約され、この時の AIC は 1277 であった。

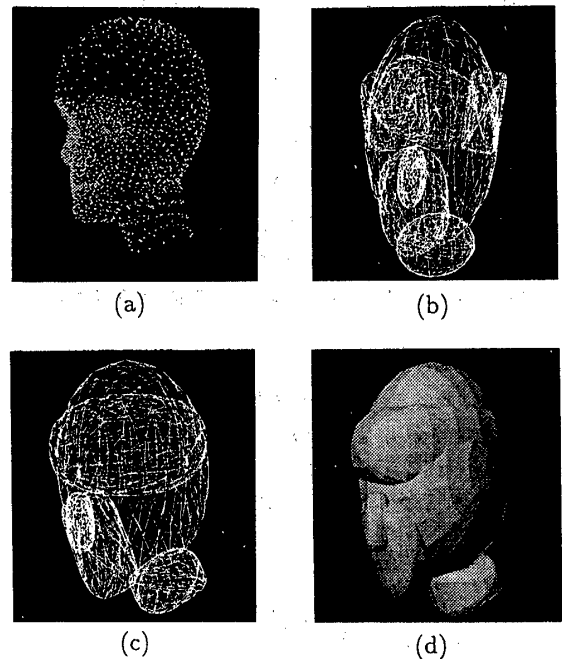
5 おわりに

対象物を部品に分割して記述するために、AIC による評価規準を導入し、客観的により少ない部品に統合する手

法を提案した。本手法では、部品の数の増加につれ、その組合せ総数が膨大になってしまうなどの課題が残されており、今後さらに検討を行なう予定である。



(a) 原データ (b) 分割結果 (c) AIC による統合結果
図 1: 輪郭データへの適用



(a) 原データ (b) 分割結果 (c),(d) AIC による統合結果
図 2: 3次元データへの適用

参考文献

- [1] 坂元, 石黒, 北川: 情報量統計学, 情報科学講座 A.5.4, 共立出版, 1983
- [2] 堀越, 浜野, 石井: “距離画像からの3次元インデックス抽出”, 信学会春季全国大会, D-660, 1992