

科学研究費助成事業 研究成果報告書

平成 29 年 6 月 12 日現在

機関番号：13903

研究種目：基盤研究(C) (一般)

研究期間：2014～2016

課題番号：26330191

研究課題名(和文)大規模計算解剖モデルのハイブリッド階層化による汎化性能と頑健性の圧倒的向上

研究課題名(英文)Big improvement of the generalization ability and robustness in construction of hybrid hierarchical statistical shape model of anatomical structures

研究代表者

本谷 秀堅(Hontani, Hidekata)

名古屋工業大学・工学(系)研究科(研究院)・教授

研究者番号：60282688

交付決定額(研究期間全体)：(直接経費) 3,600,000円

研究成果の概要(和文)：臓器の統計形状モデルの表現に、通常の正規分布を採用するのではなく、q-正規分布を採用することにより、学習データ数が少ない場合でも頑健にモデルパラメータを推定できる頑健なモデル構築法を開発した。モデルは学習データ集合より構築され、臓器の多様性の次数と比べて充分多くのデータを収集することは容易ではない。データ数が少ないとき、正規分布を採用すると、過学習によりモデルの表現能力を高くすることが難しい。従来の階層モデルも、各層における表現に正規分布を採用していた。本研究の成果を用いると、各階層における表現にq-正規分布を採用し、学習データに応じて最も汎化性能の高い表現を自動的に採用することが可能となる。

研究成果の概要(英文)：In this project, we developed a new method for constructing statistical shape model of anatomical organs robustly by employing not a normal distribution but a q-exponential distribution for the representation of the variety of the shape in order for estimating appropriate values of parameters even when the number of training data is small. A statistical shape model is constructed from a set of training data and it is not easy to collect the training data as many as the degree of the freedom of the shape variety. When the training data set is small and one employs a normal distribution for the representation, the resultant model overfits to the small training data set and the representation ability is degraded. Each layer of many conventional hierarchical models for the organs is mainly represented by a normal distribution. Using the results of this research, one can automatically select the best representation that maximizes the generalization ability.

研究分野：医用画像処理

キーワード：統計モデリング モデル選択

1. 研究開始当初の背景

画像からの対象領域検出のために、対象の統計形状モデルの非剛体位置合わせが広く採用されている。統計形状モデルは学習データより構築するが、学習データを十分な数だけ収集することは容易ではない。学習データ数が少ないとき、モデルがデータに過適合するため、汎化性能が劣化する。

2. 研究の目的

複数臓器を対象に汎化性能の高い統計形状モデルを構築する手法を開発する。汎化性能を高めるためにモデルを階層化するとともに、各階層における表現の汎化性能を改善する手法を開発する。

3. 研究の方法

臨床画像より手作業で抽出した臓器表面群を学習データとし、実際に統計モデルを構築する。臓器表面の表現には Point Distribution Model (PDM) を採用する。

4. 研究成果

(1) 概略

各階層における統計表現に正規分布を採用するのではなく、q-正規分布を採用し、AIC 規準を用いて最良なパラメータ q の値を求めることにより、汎化性能の最良なモデル表現を得ることができることを確認した。例えば学習データ数が少ないときには、裾野の広い分布が自動的に採用される。研究開始当初は各階層における表現に正規分布を採用したまま、その共分散行列の過学習を Graphical LASSO により回避することを検討するつもりであったが、途中から q-正規分布による表現の探求に研究方針を修正した。

(2) q-正規分布導入の準備

臓器表面に PDM を採用するとき、各点の座標を確率変数とするグラフィカルモデルにより臓器の多様性を表現することができる。グラフィカルモデルは、各点座標の事前分布と、2点間の相対位置分布の2種類の分布の組み合わせにより次式のとおり表すことができる。

$$p(\{\mathbf{x}_j\}, \{I_j\}) = \prod_j p(\mathbf{x}_j) p(I_j | \mathbf{x}_j) \prod_{e_{j,k} \in \epsilon} p(\mathbf{x}_j, \mathbf{x}_k)$$

ここで、 \mathbf{x}_j は j 番目の点の座標であり、 I_j は j 番目の点近傍のアピランスを表す。従来法の多くは上式右辺の各項を正規分布で表現しており、全体としても多変量正規分布により全点の同時確率分布を表現していた。汎化性能はグラフ構造、具体的には $p(\mathbf{x}_j, \mathbf{x}_k)$ を表現する組の集合 ϵ を疎にすることによ

っても改良することができる。しかし、正規分布は裾野が短い分布であり、特に学習データ数が少ないときに共分散行列が過学習することが知られている。

(3) q-正規分布

q-正規分布は、次式で表現される。正規分布と同様に平均と分散を表すパラメータを持ち、それに加えて、分布形状を変化させるパラメータ q を有する。

$$p_q(\mathbf{x}_j; \boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j) \equiv Z \left[1 + \frac{1}{\nu} (\mathbf{x}_j - \boldsymbol{\mu}_j)^T \boldsymbol{\Sigma}_j^{-1} (\mathbf{x}_j - \boldsymbol{\mu}_j) \right]^{1/1-q}$$

ただし、正規化の係数 Z は次式のとおりである：

$$Z = \frac{\Gamma((\nu+d)/2)}{(\pi\nu)^{d/2} \Gamma(\nu/2) |\boldsymbol{\Sigma}|^{1/2}}$$

パラメータ q が 1 のときには正規分布と一致し、q の値を 1 より大きくすると裾野の広い分布を表現するようになる。下に、q の値を変化させたときの分布の違いを図示する。q を 1 より大きくさせると、裾野が広がるのが分かる。

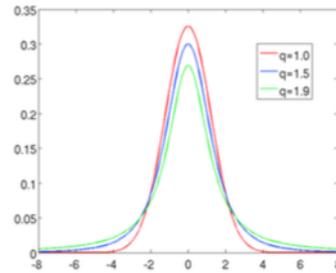


図 1 : q-正規分布

(4) q-正規分布の導入

グラフィカルモデルの各項の表現に、正規分布ではなく q-正規分布を採用し、最適な q の値を AIC 規準により選択する。このことにより、q-正規分布族中で汎化性能の最も高いモデルを、学習データごとに自動的に選択する。

まず q の値を固定した上で、学習データの分布を表現するパラメータ $\boldsymbol{\mu}$ と行列 $\boldsymbol{\Sigma}$ を推定する。前者は平均を表し、後者は正規分布の場合の共分散行列を表す。正規分布の場合のパラメータ推定と同様に、パラメータの値は最尤推定する。ただし、正規分布の場合と異なり、 $\boldsymbol{\mu}$ と $\boldsymbol{\Sigma}$ を closed form で推定する手法は存在しないため、EM アルゴリズムにより推定する。与えられたデータに対する尤度は次式で表現される：

$$L_q(\boldsymbol{\mu}, \boldsymbol{\Sigma}) = M \log(Z) + \frac{1}{1-q} \sum_{i=1}^M \left(\frac{\nu + s^i}{\nu} \right)$$

ただし、学習データを \mathbf{x}^i で表すとき、

$$s^i = (\mathbf{x}^i - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1} (\mathbf{x}^i - \boldsymbol{\mu})$$

である。また、データの次元を d で表すとき、

$$\nu = -d - 2/(1-q)$$

である。 μ も Σ も学習データに対する重み付きの加算演算で算出することができ、その重みを繰り返し更新する。すなわち、まず、それぞれの最尤推定値は次式で定義される：

$$\hat{\mu}_{ML} = \frac{\sum_i w_i \mathbf{x}^i}{\sum_i w_i},$$

$$\hat{\Sigma}_{ML} = \frac{1}{M} \sum_i w_i (\mathbf{x}^i - \mu)(\mathbf{x}^i - \mu)^T,$$

上式の重み w_i は EM アルゴリズムの E-step では次のとおりに更新する。

$$w_i^{(m)} = \frac{\nu + d}{\nu + (\mathbf{x}^i - \mu^{(m)})^T (\Sigma^{(m)})^{-1} (\mathbf{x}^i - \mu^{(m)})}$$

次に M-step において μ と Σ を次式に従って更新する。

$$\mu^{(m+1)} = \frac{\sum_i w_i^{(m)} \mathbf{x}^i}{\sum_i w_i^{(m)}},$$

$$\Sigma^{(m+1)} = \frac{1}{M} \sum_i w_i^{(m)} (\mathbf{x}^i - \mu^{(m+1)})(\mathbf{x}^i - \mu^{(m+1)})^T.$$

上記手続きを収束するまで繰り返すことにより、 q を固定したときのパラメータの値を最尤推定できる。

(5) AIC によるモデル選択法

AIC (Akaike's Information Criterion) は、真の分布とモデルとの KL-ダイバージェンスより導出される量であり、モデル選択のための情報量規準として広く採用されている。その定義は次式のとおりであり、右辺第一項は 2 倍の負の対数尤度であり、第二項はパラメータ数の 2 倍である。

$$AIC(q) = -2L_q(\hat{\mu}_{ML}, \hat{\Sigma}_{ML}) + 2l,$$

q の値を変化させることにより、裾野の広さの異なる、別の確率分布のモデルを表現できる。そして AIC(q) を最小にする q を求めることにより、 q -指数分布族の中で汎化性能が最大のモデルを選択することができる。ここで、 q -指数分布族を考えると、 q を変化させてもパラメータ数は変化しないため、AIC を最小にするパラメータ q の値は、対数尤度を最大にする q を選択することにより決定できる。

(6) 実験結果

まず、シミュレーション実験の結果を示す。真の分布を正規分布とする。そして、正規分布よりデータを少数サンプルする。この得られた少数サンプルを学習データとみなし、 q の値を 1 より少しずつ大きくしながら、それぞれの q の値においてパラメータ μ と Σ を EM

アルゴリズムにより最尤推定する。そのあと、学習データをサンプルしたのと全く同じ正規分布より、今度は性能評価用のデータを生成し、最尤推定により得られた分布モデルとの誤差 (KL ダイバージェンス) を評価する。ダイバージェンスが小さい値であるほど、モデルがデータを良く説明しているため、良いモデルであることを意味する。また、学習データと異なるサンプルにより性能評価しているため、KL ダイバージェンスを小さくするモデルほど、汎化性能が高い。図 2 に実験結果の例を示す。学習データの次元が 1 で、総数が 10 の場合の例である。学習データも性能評価用のデータも正規分布より生成されたにもかかわらず、誤差が最も小さく、汎化性能が最良のモデルは $q=1$ 、すなわち正規分布をモデル関数として採用したときではなく、 $q=1.18$ のとき、すなわち正規分布よりも裾野の広い分布を採用したときに獲得できた。これは決して自明なことではなく、データの次元数と比べてサンプル数が少ないときには、裾野の広い分布関数を表現に採用することにより汎化性能を改善できることを示している。

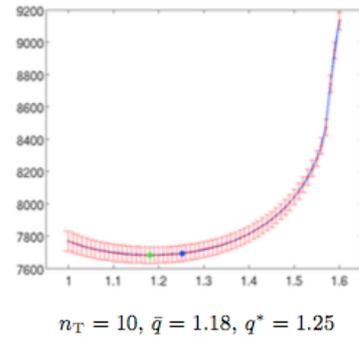


図 2: 人工データに対する汎化性能の評価実験結果。横軸: q の値。縦軸: KL-ダイバージェンス。横軸 q の値が増えるほど、正規分布より裾野が広がる。縦軸は小さい値ほど汎化性能が高い。

次に、X 線 CT 画像中の肝臓を題材に汎化性能を最良とするモデルを構築した。全身の X 線 CT 画像を、まずランドマークを手掛かりに体型正規化をおこなった。正規化に用いたランドマークを図 3 に示す。

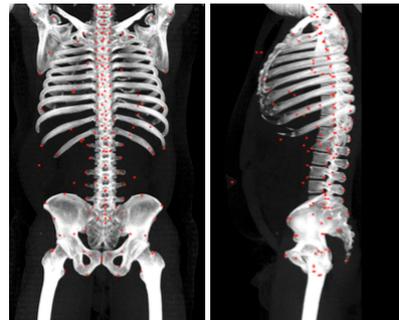


図 3: 体型正規化のためのランドマーク

体型正規化の後、臓器表目に対応点を配置する。配置された対応点の例を図4に示す。

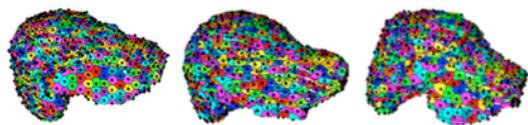


図4:Point Distribution Model

これらの点配置に基づき、AICを最小にする q の値を部位ごとに決定した結果を図5に示す。赤い色ほど選択された q の値が大きく、より裾野の広いモデルが汎化性能を改善するために好まれた領域を示す。

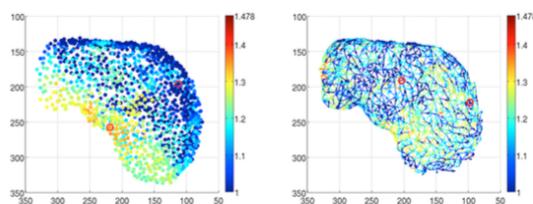


図5:AICを最小にする q の選択結果。左は各点の事前分布に選択された q の値の分布を表し、右は隣接2点間の分布の表現に選択された q の分布を示す。

図5の結果を解析すると、臓器の体表側ではなく体内側で、より裾野の広い分布が選択されていた。これは、体型正規化による拘束の強さが体内側のほうが体表側と比べて弱いことを反映していると考えると整合する。このように、汎化性能を最良とするモデルを部位ごとに自動的に選択できることは、モデルの汎化性能と頑健さを同時に改良する上で極めて有用である。

5. 主な発表論文等

(研究代表者、研究分担者及び連携研究者には下線)

[雑誌論文] (計1件)

- ① 後藤秀聡、本谷秀堅、荷重積分法による局所アピアランスのパラメトリックな記述の頑健化のための窓幅推定、電子情報通信学会論文誌D, J98-D, 571-584, 2015

[学会発表] (計2件)

- ① M. Yamada, H. Hontani, and H. Matsuzoe, Model selection from the q -exponential family for representing statistical shape models of organs, Symposium on Statistical Shape Models and Applications, Switzerland, 2015
- ② M. Yamada, H. Hontani, and H. Matsuzoe,

A Study on Model Selection from the q -Exponential Distribution for Constructing an Organ Point Distribution Model, Workshop on Mathematical and Computational Methods in Biomedical Imaging and Image Analysis, New Zealand, 2015

[図書] (計1件)

- ① 本谷秀堅、他、スパースモデリングと多変量データ解析, 岩波書店, 2017

[産業財産権]

○出願状況 (計0件)

名称:
発明者:
権利者:
種類:
番号:
出願年月日:
国内外の別:

○取得状況 (計0件)

名称:
発明者:
権利者:
種類:
番号:
取得年月日:
国内外の別:

[その他]

ホームページ等
なし

6. 研究組織

(1) 研究代表者

本谷 秀堅 (HONTANI, Hidekata)
名古屋工業大学・工学研究科・教授
研究者番号: 60282688

(2) 研究分担者

なし

(3) 連携研究者

なし

(4) 研究協力者

なし