

n次元空間上の点分布からの外周データ簡易抽出法と その応用

高木, 英行
松下電器産業株式会社中央研究所

<https://hdl.handle.net/2324/4377893>

出版情報 : The transactions of the Institute of Electronics, Information and Communication Engineers. J74-D2 (11), pp.1617-1620, 1991-11-25. The Institute of Electronics, Information and Communication Engineers

バージョン :

権利関係 :

***n*次元空間上の点分布からの外周データ簡易抽出法とその応用**

正員 高木 英行[†]

Outer Surface Data Extraction Algorithm from Point Cluster in N-Dimensional Space and Its Applications

Hideyuki TAKAGI[†], Member

[†] 松下電器産業株式会社中央研究所, 守口市
Central Research Laboratories, Matsushita Electric Industrial Co., Ltd.
Moriguchi-shi, 570 Japan

あらまし *n*次元空間上に離散的かつ不均一に分布するデータの中から, 分布の外周に位置するデータを, 超だ円体を用いて簡易に抽出するアルゴリズムを提案, 更に外周データを用いた今後の応用の可能性について広く議論する.

1. まえがき

パターン処理では *n*次元の特徴ベクトル空間に分布するパターンデータを用いて, 識別や学習などの処理を行う. このデータ分布はベクトル空間上に不均一に分布する点の集まりで, 認識などのパターン処理では, クラスの分布形状に重要な情報がある. 多くの識別処理ではクラス間の境界を扱い, 各クラスそのものの形状を直接扱うことは少ない.

一方, エッジ検出や表面検出などのパターン処理では, データの分布形状(物体図形・画像形状)を扱う. その方法の基本は隣接するデータのもつ情報の比較で, 通常の画像信号のように均一にデータが分布していることが前提になる.

以上の従来の取組みに対し, 本論文では第1に, *n*次元空間上に複数の点が不均一に分布している場合を扱い, 分布の外表面に位置するデータ点を簡単に抽出するアルゴリズムを提案し, その特徴について述べる. 連続図形の領域分割法に, 基本図形を内挿して近似する手法^{(1),(2)}があるが, 本提案方法とは内挿近似という点で考え方に類似点がある. 第2に, 抽出された外周データの今後の応用について議論する. 外周データは分布の形状情報をもっており, 今後広い応用が期待できる. 3.では実験結果も踏まえ応用について広い議論を提供し, 今後の応用展開への一助とする.

2. 外周データ抽出アルゴリズム

2.1 外周データ抽出手順

アルゴリズムの概略を述べる. *n*次元空間内に分布する *m*個のデータ $p_i (i=1\sim m)$ を扱うものとする. まず

データ分布の内部の代表点を考える. 次に, この代表点と任意の対象データ点を長軸の両端とする超だ円体を考え, この超だ円体内部に包含されるデータを削除する. 以下この作業を繰り返すものである.

ここで扱う *n*次元超だ円体は, (*n*-1)本の短軸がすべて等しいものとする. この短径と長径の比を *c* ($0 < c \leq 1$) とする. この *c* が 1 に近いと粗い外周データになり, 0 に近いと多くのデータを外周データと判断するようになる.

[手順1] 分布内部の代表点決定

データ分布内に代表点 q , 例えば重心点, を求める. *k* トラスのような複雑な形状の場合は, 複数の代表点を求め, 陰に隠れる外周データがないようにするが, ここでは1点だけの場合について以下説明する.

[手順2] 超だ円体の中心を原点へ移動

代表点 q と任意のデータ p_i を長軸端とするだ円の中心 $r=(q+p_i)/2$ を求め, r を原点へ移動する. 新座標での長軸端をそれぞれ Q と P_i とする.

[手順3] 新座標での焦点決定

超だ円体の焦点は式(1)で与えられる.

$$\begin{aligned} F_1 &= \sqrt{1-c^2} Q \\ F_2 &= \sqrt{1-c^2} P_i \end{aligned} \quad (1)$$

[手順4] 超だ円体内部に位置するデータの削除

他のデータ $p_j (j=1\sim m, j \neq i)$ の新座標 $P_j=p_j-r$ を求める. 式(2)のように P_j から二つの焦点への距離の和が長径以下ならば, P_j は超だ円体の内部に位置するので P_j を削除し, 長径を超えるなら残す(図1参照).

$$\|F_1 - P_j\| + \|F_2 - P_j\| \leq \|Q - P_i\| \quad (2)$$

以上の[手順2]~[手順4]を $i=1\sim m$ について繰り返す. このアルゴリズムの適用イメージを図2に示す.

2.2 アルゴリズムの特長

提案アルゴリズムで超だ円体を用いる理由は二つある. 第1の理由は, 離散的な点分布では連続体のように表面が一意に決まらず, パラメータによって外周を




図1 だ円体の内外判定
Fig. 1 Decision whether data exist in ellipse.

可変的に定義できる必要があるためである。2.1 では短径と長径の比 c をパラメータにして、分布の外表面を規定し外周データの抽出数を可変にしている。第2の理由は、抽出の高速化のためである。だ円の場合は二つの焦点への距離の和を用いて超だ円体の内部に含まれるかどうかの判定、つまり削除すべきかどうかの判定ができる。この計算を簡単にするため、提案アルゴリズムでは $(n-1)$ 本の短軸がすべて等しい、 n 次元空間のフットボール状の超だ円体を用いる。

演算の高速化について更に配慮できる点がある。第1は、[手順4]で削除されたデータは以後の反復処理での演算と判定を行う必要がない点である。第2は、最初に代表点と全データの距離を求め、ソーティングを行って距離の遠いデータから2.1のアルゴリズムを適用すれば、初期の段階で削除できるデータ点数が多くなり時間短縮が図れる点である。

また提案アルゴリズムは、外周データ抽出だけでなく、例えば空洞のある球のような分布の、内側の面に位置するデータを抽出することにも展開できる。この場合は[手順4]で式(2)を満たす P_i が一つでも存在するとき、 P_i を削除すればよい。




図2 だ円体内挿による外周データの抽出

Fig. 2 Outer surface data extraction by fitting hyper-ellipses.

2.3 アルゴリズムの適用限界とその対応

このアルゴリズムが適用できるデータの分布形状は、位相幾何で扱う図形よりかなり限られる。例えば、ボールと馬てい形では位相幾何では同じであるが、このアルゴリズムの適用対象としてみた場合は異なる。図3は $c=0.6$ の超だ円体を用いて得られた外周データである。後述するように[手順1]の代表点が1点の場合は適用できる形状に制約がある。 $c=0.6$ の場合、図3(c)までの凹部は可能だが図3(d)ほど急しゅんな凹部は対応不能になる。図3(d)の凹部に対応するにはより小さな c のだ円が必要である。

提案アルゴリズムが扱えるデータ分布をあえて定義すれば、「データ分布の内部の1点から n 次元の光を当てた場合、陰に隠れる部分がない形状分布」のみが対象になる。これは数学的にはかなり適用が限られる条件であるが、実用上は次の理由により十分有用性がある。それは、ここで対象となるデータは離散的に分布しており「陰に隠れる部分」をそれほど厳密に考える必要がないこと、この条件を多少満たさないデータ分布に適用しても応用によっては十分有用な場合があること、更に本質的に、この適用の定義の「1点から」を「 r 点から」に拡張すればほとんど同じアルゴリズムが、例えばドーナツ型の分布に対しても、適用可能になるからである。

3. 外周データの適用例

できるだけ広い範囲にわたった応用を提案し、今後の議論の一助にする。

3.1 ニューラルネットの前学習

全学習データを用いて学習する前に、代表的な少数データを用いて大ざっぱにかつ高速に前学習をしておき、総学習時間を短縮させることを考える。中心ベクトルを用いる⁽³⁾代わりに、クラス形状情報をもった外周データを前学習データとして用いる方法である。

実験には図4の3クラス識別問題を用いた。図4(a)





図3 外周データ抽出例 ($c=0.6$)

Fig. 3 Sample of extracted outer surface data ($c=0.6$).



(a) All data of three classes, (b) Outer surface data, (c) Centroid of each class

図4 外周データを用いたニューラルネットの前学習の効果
Fig. 4 Effect of prelearning of neural networks using outer surface data.




図5 外周データを用いた外周形状の修正
Fig. 5 Modification of surface form using outer surface data.

表1 NN学習の収束時間(3回平均:sec)

NN learning method by using	extraction of prelearning data	prelearning	learning	total
(1) all data	—	—	8.24	8.24
(2) centroid data + all data	0.08	1.39	6.52	7.99
(3) surface data + all data	0.32	0.98	4.30	5.60

は全データを、(b)は外周データを、(c)は重心データを示す。実験では(1)全データで用いる従来法、(2)3点の重心データを完全分離するよう前学習をした後、全データを用いる学習法、(3)外周データで認識率80%まで前学習をした後、全データを用いる学習法を比較した。収束までのCPU時間を3回計測しその平均値を表1に示す。

図3(e)のように部分的な外周データしか得られない場合には、常に表1のような良い結果が得られるわけではなからうが、表1はニューラルネット(NN)の前学習に用いることに対する、今後の可能性の大きさを示していると思われる。

3.2 適応性実現のための追加学習

使っているうちに機器が使いやすくなるような機能を実現しようとする場合、常に過去の学習データを保持することは、機器組込みを考えると非現実的である。従って追加データのみで部分的な修正が可能な機能、または過去の限られた学習データ+追加データのみで部分修正が実現できることが求められる。

この適応性の実験を図5(a)に示す。黒丸の外周データが示すだ円状の分布クラス形状に対して、白丸で示した追加学習データを用いてクラス形状を変化させる。

白丸と黒丸を用いて新たな外周データを求めた結果が図5(b)である。

ルールベース型の制御システムでは、入力特徴空間のルール分割が本質的である。このサブ空間の形状を変化させることは適応的にルールを変更することに相当する。図5はルール分割の際の全学習データを保持しなくても、外周データと2.1のアルゴリズムさえあれば適応的な制御が可能になることを示している。

これはNNの追加学習にも適用できる。従来の追加学習⁽⁴⁾は全データを用いるものであったが、この方法は、常時稼動しかつメモリ制限がある実際の機器へNNの学習機能を組み込むことに対する一つの解決法を示唆している。

更に機器の制御では、安全性確保のため追加学習を許さないルールが存在することが考えられる。この場合、追加学習データがこのルール分割空間に入っているかどうかを判定する必要があるが、2.1で述べた外周データ抽出アルゴリズムを使えば可能になる。すなわち、追加学習データがルール分割空間の外周データと代表点で形成される超だ円内部に含まれるかどうかの判定を行えばよい。

3.3 パターン認識

従来のテンプレート方式はクラスの代表点からの距離をもとに認識順位を決定する方法で、クラス形状によって影響を受けやすい。外周データをテンプレートとして用いれば、認識すべき入力パターンが学習時のクラス内か外かの判定が可能になるので、単なる距離による信頼度だけでなく認識の確実さを示す情報も出力できる。クラス形状に凹凸がある場合、クラスの代表点からの距離が遠い位置にある入力パターンの方が学習データのクラス内に存在し、近い位置の入力パターンがクラス外であることもあり得るが、2.1のアルゴリズムを用いればこのような場合の誤認識を防ぐことができる。

更に確からしさに階層をもたせる場合にも有効である。母音認識を例にとれば、定常部のパターンが作る分布、わたりの影響を受けた部分のパターンが作る分布、過渡部のパターンが作る分布、の各分布形状は異なるが、外周データで各分布の内外判定ができれば、より詳しい認識情報を提供できる。

また、データが集めにくい場合にも応用展開が可能である。例えば、話者同定・筆者同定や音声/非音声の判定など、無限にある対象外のクラスのデータを集めることはできない。この場合でも対象クラスの分布形状を扱うことで対処可能になる。

3.4 分布形状の外内挿

隣接する外周データを3点ずつ選び、平面または曲面を内挿すれば分布形状の外表面が求められる。特に3次元の場合、離散的に分布する点集合であっても、

分布形状を物体形状のように3次元画像表示することができるようになる。

3.5 クラス重複判定

二つの点分布クラスに重複領域がある場合、2.1のアルゴリズムを用いれば簡単に重複判定ができる。クラス1の外周データとクラス1の代表点とから構成される円体内に、クラス2の外周データ(またはクラス2の任意データ)が包含されるかどうかを判定すればよい。

4. むすび

パターン処理のように多次元距離空間に分布する点データから、だ円体を用いて外周に位置するデータ点を簡易に抽出するアルゴリズムを提案し、抽出した外周データの有効性と今後の展開の可能性を議論した。実際の応用展開はこれからであり、応用分野についての議論と共に、実際に応用を図っていく必要がある。

謝辞 幾何学的側面について御討論頂いた当社超LSI技術研究所の小田中主任技師に感謝します。

文 献

- (1) 原 潤一, 加藤博一, 井口征士: “だ円膨張法を用いた動物シルエット画像の記述と認識”, 信学論(D-II), J74-D-II, 3, pp. 366-375 (1991-03).
- (2) Pitas I. and Venetsanopoulos A. N.: “Morphological Shape Decomposition”, IEEE Trans. Pattern Anal. & Mach. Intell., 12, 1, pp. 38-45 (1990).
- (3) 城 和貴, 森 吉弘: “ニューラルネットの学習における新しいタイプの教師”, 信学技報, PRU88-94 (1988-12).
- (4) 益岡竜介: “バックプロパゲーションの高速学習アルゴリズム—追記学習—”, 信学技報, MBES8-176 (1989-03).
(平成3年4月22日受付)