

4K-1

# サンプルの隣接関係に着目した多次元データに内在する 共変関係検出に関する考察

名見耶 厚<sup>†</sup> 石川 慎也<sup>†</sup>  
東京電機大学理工学部情報社会学科<sup>†</sup>

小野 裕次郎<sup>‡</sup> 市野 学<sup>‡</sup>  
十文字学園女子大学社会情報学部<sup>‡</sup>

## 1 はじめに

データ解析において、データに内在する特徴間の共変関係の検出は重要である。ピアソンの積率相関係数<sup>1)</sup>は、特徴間の線形構造の評価を目的としている。非線形の共変関係を含むより広い共変関係の評価法として、カルホーン相関係数<sup>2)</sup>が提案されている。しかし、これらの方法は、基本的に2特徴間の関係に注目している。

本研究では、2特徴の共変関係ばかりでなく、3特徴の共変関係も検出できる方法の構築を目的としている。特徴間に共変関係が存在する場合、ある特徴において近隣にあるサンプル対は、他の特徴においても近隣に存在する傾向にある(図1,2参照)。このような性質は、「幾何学的に薄い」サンプルの分布に共通しており、カルホーン相関係数においても利用されている。また、この性質は3特徴においても同様に保たれる。

本報告では、サンプル同士の隣接関係を複数の特徴で同時に調べることで、幾何学的に薄い構造を検出する手法について考察する。まず、2特徴で非線形の共変関係を有するデータを対象にした結果を示す。つぎに、その過程において取得できるパラメータが、2特徴、3特徴の「幾何学的に薄い構造」を有するデータに共通する、有用な情報となることを述べる。

## 2 共変関係の検出

### 2.1 隣接関係の定義

与えられたデータが、 $N$  個のサンプル  $k$  ( $k=1,2,\dots,N$ )、 $d$  個の特徴  $F_k$  ( $k=1,2,\dots,d$ ) によって記述されているとする。  $p$  番目の特徴  $F_p$  において、任意のサンプル対  $i, j$  によって形成される閉区間を想定する。その閉区間に包含される他のサンプルが存在しないとき、これらのサンプル対  $i, j$  は、特徴  $F_p$  に関して相対近隣(Relative Neighborhood, RN)であるという<sup>3)</sup>。

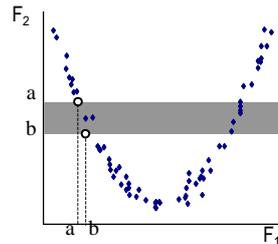


図1 幾何学的に薄い構造

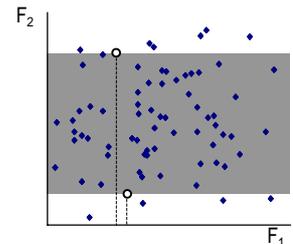


図2 幾何学的に厚い構造

次に、1特徴におけるRNが複数の特徴において同時に成り立っているサンプル間の関係を、MRN(Multi-feature Relative Neighborhood)とよぶ。MRNは、線形構造を含む単調な構造において、隣接サンプル対が満たす特有の性質である。

### 2.2 多価性への対処

特徴間に非線形構造を有するデータにおいては、その多価性によりMRNを満たさないサンプル対が現れる(図1参照)。さらにノイズの追加によっても、同様にMRNの成立が妨げられる。そこで、「RNが複数の特徴で同時に成立すること」としていたMRNの成立条件に対し、「対象となるサンプル対の間に含まれるサンプルの数が  $p$  個以下であることが同時に成立すること」という緩和条件を追加する。このときの  $p$  を許容度と呼び、許容度  $p$  の下にMRNとして成立するサンプル間の関係を  $MRN(p)$  と表すことにする。幾何学的に薄い構造を有するデータの場合、 $MRN(p)$  は小さな範囲の許容度  $p$  で成立し、逆に多次元の乱数構造など、幾何学的に厚い構造に対しては許容度  $p$  の増大に対して、 $MRN(p)$  の総数は緩やかな増加を見せる。

## 3 性能評価実験と検討

### 3.1 データ構造の骨格的表現

$p$  を0から逐次増加していき、 $MRN(p)$ の成立したサンプル対を辺で結んで無向グラフとして表現する。ただし、グラフの生成において「連結グラフになったら終了」という共通の終了条件を適用した。

図3に、2特徴間で非線形構造を有するデータ

Detection of covariant relation in multi-dimensional data by using relative neighbors

<sup>†</sup>Atsushi Nagoya, Shinya Ishikawa, Manabu Ichino,  
Department of Information and Arts, Tokyo Denki University

<sup>‡</sup>Yujiro Ono,  
Department of Social Sciences and Information Science,  
Jumonji University

に対して生成されたグラフを示す．ただし，見易さを優先するため，サンプル数は 100 とした．

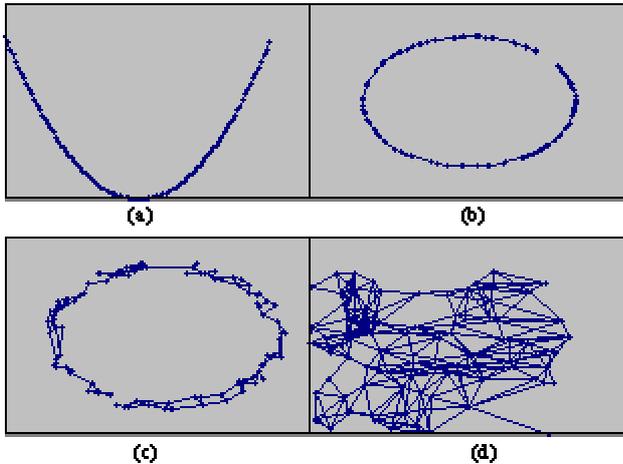


図 3 MRN(p)によるデータの骨格表現

図 3(a)は二次関数構造，(b)は円構造である．双方ともデータの骨格構造を表すグラフが生成されている．また，(a)(b)ともにノイズは加えていないが，前者はピアソンの積率相関係数<sup>1)</sup>，後者はカルホーン相関係数<sup>2)</sup>によって検出されない典型的な例である．また，図 3(c)は(b)に対してわずかなノイズを追加したデータである．元の円構造に対してノイズに相当する分の辺が追加されているが，データの骨格構造は保存されている．さらに，いずれも乱数構造である図 3(d)と比較し，データの共変関係を「幾何学的に薄い骨格」として捉えている．

実験の過程においては，線形構造や三角関数など他の共変関係を有するデータを用い，ノイズの割合を変えるなど，報告内容以外の試みも行っている．

### 3. 2 許容度の分布を利用した評価式の検討

前節において，MRN(p)のグラフがデータの骨格構造を捉えられることを述べた．次に，「特徴間に共変関係が見られる場合，狭い範囲の許容度  $p$  で MRN(p)が成立する傾向があること」に着目し，2 特徴，3 特徴それぞれのデータについて，乱数構造を有するデータとの比較実験を行った．図 4，5 は，横軸に許容度，縦軸にその許容度で成立している総 MRN(p)数を表したグラフである．ただし，サンプル数は 250 である．また，3 特徴のデータは 2 特徴のデータに新たに 1 特徴を追加する方法で生成した．乱数構造以外は，3 次元空間中で，サンプル群がロープ状に並んだ形状となっている．

2 特徴，3 特徴いずれの場合においても，乱数構造と比較すると，狭い範囲の許容度において急激

な動きが見られる．また，ノイズを付加すると，ノイズの度合いに応じて乱数構造へと近づいていく，という変化をすることも確認できており，これらを用いて評価式の作成が可能であると考えている．

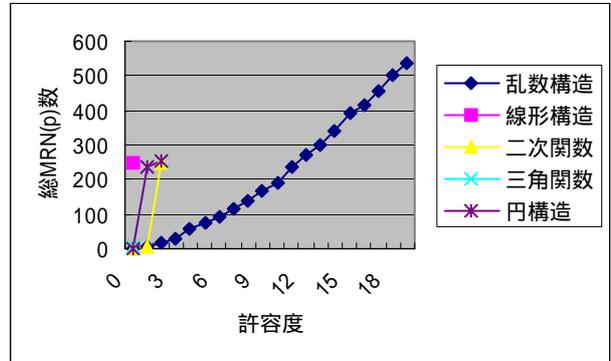


図 4 2 特徴の場合

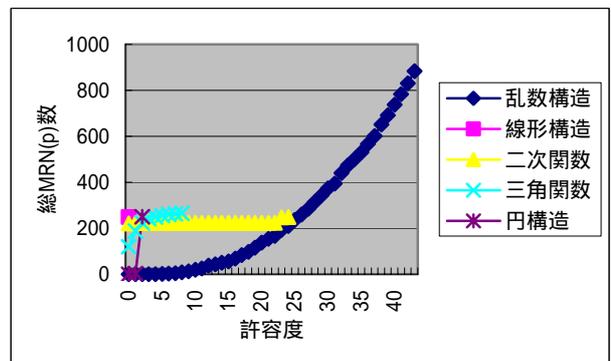


図 5 3 特徴の場合

## 4 おわりに

サンプルの隣接関係をもとに，MRN(p)という関係を定義し，幾何学的に薄い構造を 2 特徴，3 特徴において検出することを試みた．実験により，幾何学的に薄い構造に対して，MRN(p)は特徴的な動きを示すことが確認できた．今後は実験結果を利用し，評価式の定義・検証を行う．

### 参考文献

- 1) S. S. Wilks, "Mathematical Statistics", Wiley International Edition, 1962
- 2) 市野学, 矢口博之, 野中武志, "幾何学的厚みに基づく相関係数", 電子情報通信学会論文誌, Vol.J85-A, No.4, pp.490-494, 2002
- 3) Y. Ono, M. Ichino, "A New Feature Selection Method to Extract Functional Structures from Multidimensional Symbolic Data, IEICE Trans. Inf. & Syst., vol.E81-D, NO.6 June, 1998