

はじめてのパターン認識

第9章 部分空間法

11t4062a 広原裕亮

部分空間(1)

- d 次元のベクトル空間 V
 - $X_1, \dots, X_r (r \leq d)$
- V の部分空間
 - X_1, \dots, X_r の一次結合全体の集合
 - $W = \{a_1 X_1 + \dots + a_r X_r \mid a_i \in \mathbb{R}, i=1, \dots, r\}$
- すなわち X_1, \dots, X_r は一次独立であるということ

部分空間(2)

- ・ベクトル空間 V は、部分空間 S とそれと直交する部分空間 S^\perp に分解でき
 - $V = S \cup S^\perp$ 、 $S \cap S^\perp = \emptyset$ が成り立つ。
- ・任意のベクトル x は $x = x_S + x_{S^\perp}$ のように分解できる
- ・次元の縮約という観点も含め正規直交基底を求める手法として主成分分析がある

主成分分析

- 学習データの $x_i = (x_{i1}, \dots, x_{id})^T$ ($i=1, \dots, N$)の分散が最大になる方向への線形変換を求める手法である。

→ 共分散行列を求めることが出発点

N個のデータからなるデータ行列を $X = (x_1, \dots, x_N)^T$

平均ベクトル $\bar{x} = (\bar{x}_1, \dots, \bar{x}_d)^T$ 、 $X^- = X - \bar{x}$

共分散行列 $\Sigma = \text{Var}\{X^-\} = 1/N X^{-T} X^-$

主成分分析

- 係数ベクトル $a_j = (a_{j1}, \dots, a_{jd})^T$ ($j=1, \dots, d$) を用いて線形変換

$$\rightarrow s_j = (s_{1j}, \dots, s_{Nj})^T = X^T a_j$$

このデータの分散は

$$\text{Var}\{s_j\} = a_j^T \text{Var}\{X\} a_j$$

この分散が最大となる射影ベクトルは、 a_j のノルムを1に制約したラグランジェ関数

$$E(a_j) = a_j^T \text{Var}\{X\} a_j - \lambda(a_j^T a_j - 1)$$

を最大にする a_j を見つける。

主成分分析

- ・ A_j で微分して0とおくと

$$\text{Var}\{X\}a_j = \lambda a_j$$

→固有値問題を解く事により分散最大となる射影ベクトル a_j が得られることを示している。

- ・固有値を $\lambda_1 \geq \dots \geq \lambda_d$ とし、対応する固有ベクトルを a_1, \dots, a_d とする。共分散行列が実対称行列であることから

$$a_i^T a_j = \begin{cases} 1 & (i=j) \\ 0 & (i \neq j) \end{cases}$$

が成り立つ

主成分分析

- 最大固有値に対応する固有ベクトルで線形変換した特徴の分散は

$$\text{Var}\{s_1\}=\lambda_1$$

より最大固有値に一致する。

K番目の固有値に対応する固有ベクトルで変換された特徴量を第k主成分という

特異値分解

- 任意の $n \times p$ 行列 X は

$$X = UAV^T$$

$$= (u_1 \ u_2 \ \dots \ u_p) \begin{pmatrix} \sqrt{\lambda_1} & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & \lambda_p \end{pmatrix} \begin{pmatrix} v_1^T \\ \vdots \\ v_p^T \end{pmatrix}$$

3つの行列の積に分解することができる。これを特異値分解という。

特異値分解

- U は、 XX^T の非ゼロ固有値に対応する固有ベクトルからなる、 $n \times p$ 列正規直交行列
- V は、 $X^T X$ の非ゼロ固有値に対応する固有ベクトルからなる、 $p \times p$ 列正規直交行列
- A は、 XX^T または $X^T X$ の非ゼロ固有値の平方根を $\lambda_1 \geq \dots \geq \lambda_p$ の順に並べて対角要素とした $p \times p$ 対角行列

特異値分解

- $n \times p$ 行列 X を p 個の属性を持つ n 個のデータと考えれば、 $X^T X$ は共分散行列
- 固有値と固有ベクトルが λ_i と v_i となっている
 - これらから特異値分解と主成分分析の関係は明らか。

特異値分解

- また $X=UAV^T$ より $XV=UA$ が成り立つので

$$(X v_1 \dots X v_p) = (\sqrt{\lambda_1} u_1 \dots \sqrt{\lambda_p} u_p) \text{ となる}$$

- データ行列 v_1 で線形変換したベクトルが $\sqrt{\lambda_1} u_1$ となるので分散は

$$\text{Var}\{X v_1\} = \lambda_1$$

となり、第一主成分の最大固有値に一致し最大となる

部分空間法

- クラスごとに部分空間を構成する正規直交基底を学習データから求め、入力データを各クラスの部分空間に射影して識別する手法
- 相関行列を使う方法と共分散行列を使う方法
- 相関行列を使う方法はCLAFIC法という

CLAFIC法

K個のクラス C_1, \dots, C_K

クラスの部分空間 S_1, \dots, S_K

クラスiの部分空間 S_i を張る基底ベクトル $\{u_{i1}, \dots, u_{idi}\}$

データxがi番目のクラスに所属しているとき、部分空間 S_i へ正射影した長さの期待値

$$E\{\sum_{j=1}^{d_i} (x^T u_{ij})^2 \mid x \in C_i\} = E\{x^T P_i x \mid x \in C_i\}$$

が最大になるように $\|u_{ij}\|=1$ の制約の下で選択する。

CLAFIC法

- 基準を満たす*i*番目の部分空間の基底ベクトルは次のラグランジェ関数を微分して0とおいて求める

$$L_i(u_{ij}) = \dots = \sum_{j=1}^{d_i} u_{ij}^T Q_i u_{ij} - \sum_{j=1}^{d_i} \lambda_{ij} (u_{ij}^T u_{ij} - 1)$$

$$\partial L_i(u_{ij}) / \partial u_{ij} = 0$$

$$Q_i u_{ij} = \lambda_{ij} u_{ij}$$

より*i*番目のクラスの相関行列に関する固有値問題となる

CLAFIC法

- Q_i の固有値 $\lambda_{i1} \geq \dots \geq \lambda_{id_i}$
- 対応する固有ベクトル u_{ij}
- i 番目のクラスのデータ x の、 j 番目の基底への射影の長さの2乗の期待値は

$$u_{ij}^T Q_i u_{ij} = \lambda_{ij}$$

より j 番目の固有値の大きさに等しくなる

CLAFIC法

- Q_i から求めた*i*番目のクラス固有ベクトルは正規直交基底なので、個々の基底の射影の和で部分空間への射影の長さの2乗の期待値が表せる。

$$\sum_{j=1}^{d_i} u_{ij}^T Q_i u_{ij} = \sum_{j=1}^{d_i} \lambda_{ij}$$

よって上記のようになる。

CLAFIC法

- 部分空間の次元により長さが異なる。
- 射影した長さで所属クラスを決める
→次元の大きさをく所属クラスが変わってしまう

そこで固有値の累積値を用いる

$$a(d_i) = \sum_{j=1}^{d_i} \lambda_{ij}$$

CLAFIC法

- 共通なパラメータ k を導入し

$$a(d_i - 1) \leq k < a(d_i)$$

を満たす d_i を i 番目のクラスの部分空間の次元とする。

K は忠実度とよばれる。