




PCAとICA

10月17日

吉田雄介



PCA(1/10)

- PCAとは

- Principal Component Analysisの略で
主成分分析と訳される

- 主成分とは

- 分散行列の最大固有値に対応する固有ベクトル

PCA(2/10)

- R^n 上のTこの観測値ベクトル $x(1), \dots, x(T)$ が与えられたとき単位ベクトル $\|\gamma\|=1$ の中で

$$\sum_{t=1}^T \left[\|x(t) - \bar{x}\|^2 - \{\gamma^T (x(t) - \bar{x})\}^2 \right] \quad \text{式(1)}$$

を最小にする γ を求める

- 標本平均を \bar{x} 、ベクトルのノルムを $\|\cdot\|$ で表す

- 標本平均を0とすると式(1)は

$$\sum_{t=1}^T \left\{ \|x(t)\|^2 - (\gamma^T x(t))^2 \right\} \quad \text{式(2)}$$

PCA(3/10)

- 第2項を書き換えると

$$\sum_{t=1}^T \left\| (\gamma^T x(t)) \gamma \right\|_2$$

式(3)

と書き換えられ、式(2)は

$$\sum_{t=1}^T \left\| x(t) - (\gamma^T x(t)) \gamma \right\|_2$$

式(4)

と書き換えられる

PCA(4/10)

- 観測値 $x(t)$ をある定ベクトル γ の方向に定数倍 $s(t) = \gamma^\top x(t)$ して

$$x(t) \sim s(t)\gamma \quad \text{式(5)}$$

と近似したときにもとの信号を一番良く近似する γ を求めると $s(t)$ は $\gamma^\top x(t)$ となる

- これより式(4)を書き換えると

$$\sum_{t=1}^T \|x(t) - s(t)\gamma\|^2 = \sum_{t=1}^T \left\{ \|x(t)\|^2 - \|s(t)\gamma\|^2 \right\} \quad \text{式(6)}$$

となり、これを最小にする γ を考える

PCA(5/10)

- 式(5)を最小化するには

$$\sum_{t=1}^T \|s(t)\gamma\|^2$$

式(7)


を最大化する

- $s(t)$ を代入して

$$\sum_{t=1}^T \left\| \left(\gamma^T x(t) \right) \gamma \right\|^2 = \sum_{t=1}^T \left\| \gamma \left(x(t)^T \gamma \right) \right\|^2$$

$$= \gamma^T \left(\sum_{t=1}^T x(t)x(t)^T \right) \gamma$$

式(8)



PCA(6/10)

- 分散行列を

$$V = \frac{1}{T} \sum_{t=1}^T x(t)x(t)^T \quad \text{式(9)}$$

として、式(8)は

$$\gamma^T V \gamma \quad \text{式(10)}$$

となり、これを最大にする大きさ1のベクトルを
求める問題になる

PCA(7/10)

- 分散行列は正定値なので、ある直行行列Sを使って

$$S^T V S = \begin{pmatrix} \lambda_1 & & \\ & \ddots & \\ & & \lambda_n \end{pmatrix} \quad \text{式(11)}$$

のように対角化できる。

- ただし、この対角成分はVの固有値で

$$\lambda_1 \geq \dots \geq \lambda_n (\geq 0) \quad \text{式(12)}$$

となるようにSは選ぶものとする

PCA(8/10)

- この対角行列を両側から挟み込んで最大にする大きさ1のベクトルは $(1, 0, \dots, 0)$ または $(-1, 0, \dots, 0)$ であり、正負は問題ないので $(1, 0, \dots, 0)$ だけを考えてみると

$$\gamma = S \begin{pmatrix} 1 \\ 0 \\ \vdots \\ 0 \end{pmatrix} \quad \text{式(13)}$$

Vを両側から挟んで最大にするベクトルが求められる

PCA(9/10)

- 式(5)の近似は拡張でき、

$$x(t) \sim s_1(t)\gamma_1 + s_2(t)\gamma_2 + \dots \quad \text{式(14)}$$

というように精度を上げることができる

- 主成分が求められた元の観測値から主成分方向の成分を取り除いた残差

$$x(t) - s_1(t)\gamma_1 \quad \text{式(15)}$$


に対して同じように主成分分析を繰り返し行うことで

$$x(t) = s_1(t)\gamma_1 + s_2(t)\gamma_2 + \dots + s_n(t)\gamma_n \quad \text{式(16)}$$

という分解が得られる

PCA(10/10)

- $\frac{1}{T} \sum_{t=1}^T s_i(t)s_j(t)$ (式(17))について
 - $i \neq j$ のときは r_i と r_j が直交しているので式(17)は0となり、係数は無相関である
 - $i = j$ のときは式(17)は λ_i となる
- これより
$$\frac{1}{T} \sum_{t=1}^T \|x(t)\|^2 = \sum_{i=1}^n \lambda_i$$
式(18)とパワーの分解を与えていると解釈できる



ICA(1/4)

■ $y(t) = Bx(t)$ 式(19)

という変換で $y(t)$ の各成分が独立なので
 B を使って $x(t)$ を分解すると

$$x(t) = B^{-1}y(t) \quad \text{式(20)}$$

となり、 B^{-1} の各列ベクトルを γ_i 、
 $y(t)$ の各成分を $s_i(t)$ として考える

ICA(2/4)

■ $x(t) = B^{-1} Bx(t)$

$$= B^{-1} \left\{ \begin{pmatrix} 1 & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & 0 \end{pmatrix} + \cdots + \begin{pmatrix} 0 & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & 1 \end{pmatrix} \right\} Bx(t)$$

$$= B^{-1} \left\{ \begin{pmatrix} 1 \\ \vdots \\ 0 \end{pmatrix} (1 \ \cdots \ 0) + \cdots + \begin{pmatrix} 0 \\ \vdots \\ 1 \end{pmatrix} (0 \ \cdots \ 1) \right\} Bx(t)$$

$$= \gamma_1 (\gamma_1^* x(t)) + \cdots + \gamma_n (\gamma_n^* x(t))$$

$$= s_1(t) \gamma_1 + \cdots + s_n(t) \gamma_n \quad \text{式(21)}$$

ここで γ_i は行列 B^{-1} の第 i 番目の列ベクトル

γ_i^* は行列 B の第 i 番目の行ベクトル

ICA(3/4)

- $\|\gamma_i\|=1$ としても γ_i が互いに直交していないので

$$\frac{1}{T} \sum_{t=1}^T \|x(t)\|^2 \neq \frac{1}{T} \sum_{i=1}^n \sum_{t=1}^T s_i(t)^2 \quad \text{式(22)}$$

- $s_i(t)$ と $s_j(t)$ は y_i, y_j の独立性から相関が0になるので、
係数が無相関であるため

$$\frac{1}{T} \sum_{t=1}^T s_i(t)s_j(t) = 0 \quad \text{式(23)}$$

ICA(4/4)

- $x(t)^*$ は $x(t)$ の双対座標であり、この場合はユークリッド空間なので $x(t)$ の転置を考え、

$$s_i(t)^* = x(t)^* \gamma_i = x(t)^T \gamma_i \quad \text{式(24)}$$

を定義し

$$x(t)^T = \gamma_1^* s_1(t)^* + \cdots + \gamma_n^* s_n(t)^* \quad \text{式(25)}$$

という分解を考えると、基底の双対性から

$$\frac{1}{T} \sum_{t=1}^T \|x(t)\|^2 = \frac{1}{T} \sum_{i=1}^n \sum_{t=1}^T s_i(t) s_i(t)^* \quad \text{式(26)}$$

という分解が成り立つ



PCAとICAの共通点と違い

■ 共通点

$$x(t) = s_1(t)\gamma_1 + s_2(t)\gamma_2 + \cdots + s_n(t)\gamma_n$$

という形で確率変数ベクトルの分解を考える

■ 違い

- 分解のために採用する基準
 $\gamma_1, \dots, \gamma_n$ が線形独立ならどんな分解も可能
- ICAは基底が直交してなくてもよいが
分解の係数が独立になるように基底を選ぶ
- PCAは γ として互いに直交する方向への分解を考え、
分解の係数が無相関になるように基底を選ぶ