

## \* 主成分分析 (principal component analysis: PCA)

・ データセット  $\mathcal{D} = \{x_1, \dots, x_N\}$  : given.

$$x_i = \begin{pmatrix} x_{i,1} \\ \vdots \\ x_{i,D} \end{pmatrix} \in \mathbb{R}^D \quad (i=1, \dots, N) \quad \text{とす.}$$

(サンプル数  $N$  個, 特徴量  $D$  個.)

・ 扱うサンプルは全て標準化されているとする.

やりたいこと

サンプルデータの情報が大きく失われない程度に

サンプルの特徴量をいい感じにまとめて,

特徴量の数を  $D$  個から  $K$  個に減らしたい.

(情報の圧縮, データの要約)

→ データの可視化や特徴量の選択に使える!

例えば

5教科のテスト点数を

総合点一つにまとめるのも

一種のデータ要約.

Q. どんな感じでサンプルの特徴量をまとめる?

A. とりあえず特徴量の線形変換でいいのでは?

→ サンプル  $x_i \in \mathcal{D}$  に対して,  $k$  番目の新特徴量 ( $k=1, \dots, K$ ) を

$$t_{i,k} := \sum_{j=1}^D w_{k,j} x_{i,j} \quad (w_{k,j} \in \mathbb{R}, j=1, \dots, D)$$

と定めることにしよう!

$$w_k := \begin{pmatrix} w_{k,1} \\ \vdots \\ w_{k,D} \end{pmatrix} \in \mathbb{R}^D \quad (k=1, \dots, K) \text{ とすると, 先の式は}$$

$t_{i,k} = \alpha_i^T w_k$  と書ける. これを全サンプルについてまとめて書くと,

$$\tilde{t}_k := \begin{pmatrix} t_{1,k} \\ \vdots \\ t_{N,k} \end{pmatrix} \in \mathbb{R}^N \quad (k=1, \dots, K) \text{ とし,$$

$$\tilde{t}_k = \begin{pmatrix} \alpha_1^T w_k \\ \vdots \\ \alpha_N^T w_k \end{pmatrix} = X w_k \text{ と書ける.}$$

さらにこれを全ての新特徴量についてまとめて書くと,

$$T := \left( \overbrace{\tilde{t}_1 \ \dots \ \tilde{t}_k}^K \right)_N \in M_{N,K}(\mathbb{R}),$$

$$W := \left( \overbrace{w_1 \ \dots \ w_k}^K \right)_D \in M_{D,K}(\mathbb{R})$$

とし,

$$T = (X w_1 \ \dots \ X w_k) = X (w_1 \ \dots \ w_k) = XW$$

と書ける.  $T$  を

$$T = \left( \tilde{t}_1 \ \dots \ \tilde{t}_k \right) = \begin{pmatrix} t_1^T \\ \vdots \\ t_N^T \end{pmatrix}, \quad t_i \in \mathbb{R}^K$$

$$W^T = \begin{pmatrix} w_1^T \\ \vdots \\ w_k^T \end{pmatrix}$$

$\alpha_i$  の  $W^T$  による  
線形変換

とも書くことにすると,  $T = XW$  より  $t_i^T = \alpha_i^T W$  なので  $t_i = W^T \alpha_i$ .

• ということで、やりたこと が少し具体的になった:

いい感じの線形変換  $W^T$  をみつけて、データセットの情報量をできるだけ残した次元をおとしたデータセットを得たい。

• とことで、線形変換  $W^T$  は図形的にはどんなことをしているのか?

$$\rightarrow t_{i,k} = w_k^T x_i \text{ について}$$

$\|w_k\| = 1$  であれば  $w_k^T x_i$  は

$x_i$  の  $w_k$  方向への正射影の長さ。



→ つまり、線形変換  $W^T$  は、サンプル  $x$  を  $w_1, \dots, w_k$  のそれぞれ  
の方向に正射影する射影変換。

• そもそも  $w_k$  は  $t_{i,k}$  を作るために

$$t_{i,k} = \sum_{j=1}^D w_{k,j} x_{i,j} \quad (w_{k,j} \in \mathbb{R}, j=1, \dots, D)$$

と導入された量で、重要なのは

各  $j$  に対し  $x_{i,j}$  をどの程度足し合わせることで新しい特徴量  $t_{i,k}$  を  
つくるか

ということ。つまり、 $w_k$  の各成分  $w_{k,j}$  の比率のみが重要!


ベクトルの言葉でいえば、 $w_k$  の向きが大事で長さはどうでもよいということ。

→ 以下では、 $\|w_k\| = 1$  ( $k=1, \dots, K$ ) としておけばよい!

ただし1のベクトルを正規ベクトルという。

Q. どの方向  $w$  を選ぶかは、データセットの情報量をできるだけ残せる?

A. 単純な例で考えてみよう.



異なるサンプルが同じ値に射影されてしまうと、片方のサンプルの持つ情報は完全に失われてしまてやばい.

$t_1$  と  $t_2$  は、2点  
 $x_1 = \begin{pmatrix} 1 \\ 1 \end{pmatrix}, x_2 = \begin{pmatrix} 1 \\ 2 \end{pmatrix}$   
 を  $x_1$  軸に射影すると  
 どちらも  $t_1 = t_2 = 1$  となってしまい.  
 もともと片方のサンプルしかなかったとまで同じ結果になる.

→ 異なるサンプルが同じ値に射影されにくいような方向  $w$  をみつけたい  
 データセットの情報量をできるだけ保持できよう.

→ 射影先の値が大きばらついていけばいいほど、同じ値には射影されにくそう!

• 値のばらつきを表す量 → 分散!

• 実際には、 $w_1, \dots, w_k$  の  $k$  本の方向を選ばなければならぬ。

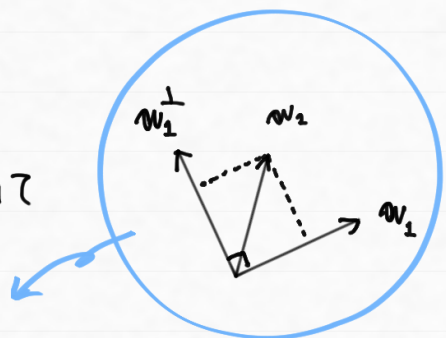
•  $w_1$  は  $\{t_{i,1}\}_{i=1}^N$  の分散が最大になるように選ぶのがよい。

•  $w_2$  はどう選ぶ？

•  $w_2 \in \mathbb{R}^D$  を適当に決めたとする。

→  $w_1$  と直交する適当な  $w_1^\perp \in \mathbb{R}^D$  を用いて

$w_2 = a w_1 + b w_1^\perp$  と表すことができる。



すると  $x_i$  に対して、 $t_{i,2} = a x_i^T w_2 + b x_i^T w_1^\perp = a t_{i,1} + b x_i^T w_1^\perp$ .

$t_{i,1}$  と  $t_{i,2}$  の  
相関が 0 でない  
ということ。

→  $t_{i,2}$  に  $t_{i,1}$  の項が入ってくると、1番目の新特徴量  $t_{i,1}$  への影響が 2番目の新特徴量  $t_{i,2}$  にもでてきてしまう。

$t_{i,1}$  の情報は既にある  $T$  から、冗長ではないか？

→  $a=0$  となるように  $w_2$  の方向を決めよう。つまり、 $w_2$  は  $w_1$  と直交する方向からとれるようにすればよいぞ！

• しかも  $\{t_{i,2}\}_{i=1}^N$  の分散が最大になるように選ぶ。

• 同様に、 $w_k$  ( $k=3, \dots, k$ ) も、 $\{w_1, \dots, w_{k-1}\}$  と直交する方向

から、 $\{t_{i,k}\}_{i=1}^N$  の分散が最大になるように選ぶのがよい。

- 以上より, やりた=11=と が (おもしろいので), 手とめる:

やりた=11=と

"大きさを1で互いに直交する" ということ

正規直交する 1"7H  $\{w_1, \dots, w_k\} \subseteq \mathbb{R}^D$  で, 各  $k$  に対し

$\{t_{z,k} = x_z^T w_k\}_{z=1}^N$  の分散が最大になるものを見つけたい.

- やっていくことにする.

$\|w\| = 1$  なる  $w \in \mathbb{R}^D$  を考える.  $\{t_i = x_i^T w\}_{i=1}^N$  の標本分散

を求めたい. まず  $\{t_i\}_{i=1}^N$  の標本平均  $\bar{t}$  は.

$$\bar{t} = \frac{1}{n} \sum_{i=1}^N t_i = \frac{1}{n} \sum_{i=1}^N x_i^T w = \left( \frac{1}{n} \sum_{i=1}^N x_i^T \right) w = \left( \frac{1}{n} \sum_{i=1}^N x_i \right)^T w$$

$$= 0^T w \quad (\because \text{標準化されていざから } \bar{x} = 0)$$

$$= 0.$$

なので, 標本分散  $\sigma_w^2$  は,

$$\sigma_w^2 = \frac{1}{n} \sum_{i=1}^N (t_i - \bar{t})^2 = \frac{1}{n} \sum_{i=1}^N t_i^2 = \frac{1}{n} \sum_{i=1}^N w^T x_i x_i^T w$$

$$= w^T \left( \frac{1}{n} \sum_{i=1}^N x_i x_i^T \right) w$$

$$= w^T \left( \frac{1}{n} \sum_{i=1}^N (x_i - \bar{x})(x_i - \bar{x})^T \right) w \quad (\because \bar{x} = 0)$$

$$= w^T \Sigma w. \quad (\Sigma: \text{標本共分散行列}).$$

$$\Sigma = \frac{1}{n} \sum_{i=1}^N (x_i - \bar{x})(x_i - \bar{x})^T.$$

$\Sigma$  は対称行列.

→ 関数  $f(w) = w^T \Sigma w$  を, 制約条件  $\|w\| = 1$  のもとで

最大化する  $w$  を求める.

これを

$$(P) \quad \begin{aligned} \max \quad & f(w) = w^T \Sigma w \\ \text{s.t.} \quad & \|w\| = 1 \end{aligned}$$

← 等式制約つき  
最適化問題

と書く.

•  $\|w\| > 0$  ならば,  $\|w\| = 1 \Leftrightarrow \|w\|^2 = 1$  であるから,

$$(P') \quad \begin{aligned} \max \quad & f(w) = w^T \Sigma w \\ \text{s.t.} \quad & \|w\|^2 = 1 \end{aligned}$$

とすると, 問題  $(P')$  は  $(P)$  と等価.

Lagrange の不定乗数法により

制約なし  
最適化問題

$$(L) \quad \max \quad \mathcal{L}(w, \lambda) := f(w) - \lambda (\|w\|^2 - 1)$$

とすると,  $(L)$  は  $(P')$  と等価. 結局  $(L)$  をとけばよい.

•  $\mathcal{L}(w, \lambda)$  の最適解の候補は,

$$\frac{\partial \mathcal{L}}{\partial w} = 0, \quad \frac{\partial \mathcal{L}}{\partial \lambda} = 0 \quad \text{を満たす } w, \lambda \text{ である.}$$

(最適性の必要条件)

$$\frac{\partial L}{\partial \lambda} = 0 \text{ より } \|w\|^2 = 1 \Leftrightarrow \|w\| = 1. \rightarrow \text{大抵は } 1 \text{ に } \rightarrow$$

$$\frac{\partial L}{\partial w} = 2 \sum w - 2\lambda w \quad \left( \begin{array}{l} \text{対称行列 } A \text{ について} \\ \frac{\partial}{\partial w} w^T A w = 2Aw \text{ を用いた.} \end{array} \right)$$

となる。

$$\sum w = \lambda w \quad (*)$$

$\|w\| = 1$  より  $w \neq 0$  となる。(\*)は  $w$  による  $\sum$  の固有ベクトルであることの意味する!

•  $\sum$  の固有ベクトルは  $\dim \sum = D$  がある。どれを選ぶ?

→ (L) はもとの問題 (P) と等価だから、(P) の最適解も

(\*) をみたす。よって、(L) の最適解を  $(w^*, \lambda^*)$  とすると、(P) の最適値は、

$$f(w^*) = w^{*T} \sum w^* = w^{*T} (\lambda^* w^*) \quad (\because (*))$$

$$= \lambda^* \|w^*\|^2$$

$$= \lambda^*. \quad (\because \|w^*\| = 1)$$

となる。つまり、(P) の最適値は  $\sum$  の最大固有値  $\lambda^*$  であり

最適解は  $\lambda^*$  に対応する固有ベクトル  $w^*$  である!



- ここでもう一度  $\text{やり直し}$  を確認してみよう:

$\text{やり直し}$

正規直交するベクトル  $\{w_1, \dots, w_k\} \subseteq \mathbb{R}^D$  で、各  $k$  に対して  $\{t_{z,k} = x_z^T w_k\}_{z=1}^N$  の分散が最大になるものを見つけたい。

$k$  の正規直交するベクトル  $\{w_1, \dots, w_k\} \subseteq \mathbb{R}^D$  をみつければ必要が  
あるのだ。

- 線形代数の次の定理を思い出そう:

Thm.  $n$  次実対称行列  $A \in M_n(\mathbb{R})$  の  $n$  個の固有値は非負である。

さらに、 $n$  個の固有ベクトルは正規直交するようにとれる。  $\square$

- $\Sigma$  は  $D$  次実対称行列なので、 $D$  個の非負固有値  $\lambda_i$  とれる。これを

$$\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_D (\geq 0)$$

と降順に並べ、対応する固有ベクトルを  $w_1, w_2, \dots, w_D$  としよう。

→ 先の議論により、 $w_1$  は変換後の座標の分散が最大 ( $\lambda_1$ ) になる方向。次に分散が大きくなるのは  $w_2$  の方向、以下同様。

→ 固有値を降順に並べ、対応する固有値を前から  $k$  個とった

$\{w_1, \dots, w_k\}$  が求めているベクトル!

- 具体的に, PCA は以下のようにできる:

### Alg. (PCA)

Input: 標準化済みのデータからなるデータ行列  $X = \begin{pmatrix} x_1^T \\ \vdots \\ x_N^T \end{pmatrix} \in M_{N,D}(\mathbb{R})$

正整数  $K \in \mathbb{Z}_{>0}$

Output: 次元削減したデータからなる行列  $T = \begin{pmatrix} t_1^T \\ \vdots \\ t_N^T \end{pmatrix} \in M_{N,K}(\mathbb{R})$

1. 標本平均の計算:  $\bar{x} \leftarrow \frac{1}{N} \sum_{i=1}^N x_i$  ;
2. 標本共分散行列の計算:  $\Sigma \leftarrow \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})(x_i - \bar{x})^T$  ;
3. 固有値, 固有ベクトルの計算:

$\Sigma$  の固有値, 固有ベクトルを  $\lambda_1 \geq \dots \geq \lambda_D$   
対応 ↓  $w_1, \dots, w_D$  とする;

4. 変換行列の計算:  $W \leftarrow (w_1 \dots w_K)$  ;

5. 変換:  $T \leftarrow XW$  ;

6. return  $T$ . □

こうして  $x_i$  を変換して得られる  $t_i$  の第  $k$  成分を, **第  $k$  主成分**

という ( $k = 1, \dots, K$ ).

Q. D次元からK次元に次元削減した時、どの程度の情報が表現できているのだろうか？

A. 変換後の座標の分散が全分散に占める割合がその主成分軸で表現できている情報の割合を反映していると考えられる。

全分散は固有値の和で

$$V_{\text{total}} := \sum_{k=1}^D \lambda_k \quad (= \sigma^2 \Sigma)$$

となる。第k主成分が表現している情報の割合は

$$c_k := \frac{\lambda_k}{V_{\text{total}}} \quad (k=1, \dots, D)$$

であり、これを第k成分の**寄与率**という。

第k主成分まで用いることで表現できる情報の割合は

$$r_k := \frac{1}{V_{\text{total}}} \sum_{k=1}^k \lambda_k$$

となり、第k成分までの**累積寄与率**という。

結局、K次元に次元削減することで、元の情報の $r_k$ 倍の情報が表現されていることになる。