


## Clustering


Unsupervised learning

Training set  $\{x^{(1)}, x^{(2)}, \dots, x^{(m)}\}$ 

## 講義中の Quiz

- ① unsupervised learning では training set は  $\{x^{(1)}, x^{(2)}, \dots, x^{(m)}\}$  であり  $y^{(i)}$  はない。 ○
- ② Clustering は unsupervised learning の 1 つ。 ○
- ③ unsupervised learning では, unlabeled dataset が与えられるので、データの構造を見出すように依頼される。 ○
- ④ Clustering は unsupervised learning algorithm ではない。 X

K-Means アルゴリズム



2点の clustering center を置く

どっちに近いかで色分けする



それぞれのグループの中心に移動する

Input :

$K$  クラスターの数

Training set  $\{x^{(1)}, x^{(2)}, \dots, x^{(m)}\}$

$x^{(i)} \in \mathbb{R}^n$

( $x^{(0)} = 1$  を数え直しの初期値)

$K$  個の clustering center  $\mu_1, \mu_2, \dots, \mu_K$  をランダムに配置する

Repeat ↓

各点をクラスターに割り当てる

for  $i=1$  to  $m$   
 $C^{(i)} = x^{(i)}$  に最も近い cluster center の index

クラスター中心を動かす

for  $k=1$  to  $K$   
 $\mu_k =$  クラスター  $k$  に割り当てられた点の平均


[Quiz] k-mean が収束した時  $C^{(1)} = 3, C^{(2)} = 3, C^{(3)} = 5, \dots$  となった。

- ① 3番目の example  $x^{(3)}$  は クラスター 5 に属する ○
- ②  $x^{(1)}$  と  $x^{(2)}$  は 同じクラスターに割り当てられた ○ クラスター 3 に同じ
- ③ 2番目と3番目の example が 同じクラスターに割り当てられた  $\times$  クラスター 3 と 5 に属する
- ④  $k \in \{1, 2, \dots, K\}$  の全ての  $k$  について,  $k=3$  が  $\|x^{(2)} - \mu_k\|^2$  を最小化した ○  $x^{(2)}$  に  $k=3$  が最も近い

Optimization Objectives

K-means optimization objectives

[Quiz]



- ① learning rate が大きすぎる  $\times$  learning rate を小さくする。
- ② このアルゴリズムは正しく動作している  $\times$  収束していない。
- ③ このアルゴリズムは動作しているが  $\times$  大きすぎる  $\times$  ~~これは  $\mu$  と  $\mu_j$  とを和で  $\mu$  とする~~
- ④ cost function が 時々大きくなるのは無理である。2-nd order だ。  $\times$  ○

Random Initialization

for  $i = 1$  to 100 {

    ランダムに K-means を初期化する

$c^{(1)}, c^{(2)}, \dots, c^{(m)}, \mu_1, \mu_2, \dots, \mu_k$  を得る

    cost function  $J(c^{(1)}, \dots, c^{(m)}, \mu_1, \dots, \mu_k)$  を計算する

}



最も  $J$  が小さいものを選択する

[Quiz]  $i_1, \dots, i_k$  を  $\{1, \dots, m\}$  の異なる値から選ぶ  
 $\mu_1 = x^{(i_1)}, \dots, \mu_k = x^{(i_k)}$  とする ○

# Choosing the Number of Clusters

## Elbow method

Jの減少が緩やかにあるところを elbow



elbow 方法は、正しい時もある。

[Quiz] K-means,  $k=3 < k=5$   $J_{k=5} > J_{k=3}$  とした。理由は?

- ① 数学的に正しい。bug X
- ②  $k=3$  が正しいから X
- ③  $k=5$  の時 local minimum におちた。複数の random initialization で再 try せよ O
- ④  $k=3$  の時おちたから。  $k=3$  でも、悪い初期の  $k=5$  のときと同じく複数の random initialization で再 try せよ X

クラスターの数は、分け方によって変わることがある。

例 T-shirt サイズ

S, M, L →  $k=3$

XS, S, M, L, XL →  $k=5$

Week 8 5

Motivation : Data Compression

Reduce data from 2D to 1D  
3D 2D

[講義中の Quiz]

$m$  個  $n$ -次元ベクトル  $\{x^{(1)}, \dots, x^{(m)}\}$   $x^{(i)} \in \mathbb{R}^n$

dimensionality reduction

↓

$\{z^{(1)}, \dots, z^{(m)}\}$   $z^{(i)} \in \mathbb{R}^k$  where  $k \leq n$  答

Motivation : Visualization

[講義中の Quiz]

$n$ -次元ベクトル  $\{x^{(1)}, \dots, x^{(m)}\}$  where  $x^{(i)} \in \mathbb{R}^n$

$\{z^{(1)}, \dots, z^{(m)}\}$  where  $z^{(i)} \in \mathbb{R}^k$ ,  $k \leq n$

①  $k > n$  ×

②  $k \leq n$  ○

③  $k \geq 4$  × visualize (1, 2, 3)


④  $k = 2$  or  $3$  ○ 2次元か3次元まで視覚化できる

## Principal Component Analysis (主成分分析)

2次元から1次元への reduction

projection error が最小になる方向ベクトル  $u^{(1)} \in \mathbb{R}^n$  を見つける  
(射影誤差) $n$ 次元から  $k$ 次元への reduction $u^{(1)}, u^{(2)}, \dots, u^{(k)}$  where  $u^{(i)} \in \mathbb{R}^n$ 


PCA と linear regression は異なることに注意



[講義中の Quiz]

単位ベクトル  $u^{(1)}$  の2つ

$$u^{(1)} = \frac{1}{\sqrt{2}}(1, -1) \text{ or } \frac{1}{\sqrt{2}}(-1, 1)$$



# Principal Component Analysis Algorithm

## Data Processing

training set  $\{x^{(1)}, \dots, x^{(m)}\}$

前処理 (feature scaling / mean normalization)

$$\mu_j = \frac{1}{m} \sum_{i=1}^m x_j^{(i)} \quad \text{平均}$$

Replace: 各  $x_j^{(i)}$  を  $x_j^{(i)} - \mu_j$  に ← 中心を原点にもってくる

feature によらず scale が異なる時は 比較可能な範囲に存在するようにスケールする


$$x_j^{(i)} \text{ を } \frac{x_j^{(i)} - \mu_j}{S_j} \text{ に置き替える}$$

$$S_j = \max_i (x_j^{(i)}) - \min_i (x_j^{(i)})$$

## PCAを採るアルゴリズム

1.  $n$ 次元を  $k$ 次元に落とす (reduce)
2. covariance matrix (共分散行列)  $\Sigma$  を求める

$$\Sigma = \frac{1}{m} \sum_{i=1}^m (x^{(i)})(x^{(i)})^T$$



3.  $\Sigma$  行列の eigenvectors (固有ベクトル) を求める

$$[U, S, V] = \text{svd}(\Sigma) \quad n \times n$$

singular value decomposition  
(特異値分解)

(注)  $\text{eig}(\Sigma)$  でも計算できる

$$U = \begin{pmatrix} | & | & \dots & | \\ u^{(1)} & u^{(2)} & \dots & u^{(k)} \\ | & | & \dots & | \end{pmatrix}, \quad U \in \mathbb{R}^{n \times n}, \quad u^{(1)}, \dots, u^{(k)} \in \mathbb{R}^n$$

最初から  $k$ 個のベクトル  $u^{(1)}, \dots, u^{(k)}$  を取り出す

$$x \in \mathbb{R}^n \rightarrow z \in \mathbb{R}^k$$

$$z = \begin{pmatrix} | & \dots & | \\ u^{(1)} & \dots & u^{(k)} \\ | & \dots & | \end{pmatrix}^T \times \begin{pmatrix} | \\ \times \\ | \end{pmatrix} \rightarrow \begin{pmatrix} | \\ \times \\ | \end{pmatrix}$$

$n \times k$  行列  $U_{\text{reduce}}$

videoの説明が悪い。  
説明と裏表で 行と列が逆  
↑  
混乱の原因

Week 8 8

$$X = \begin{pmatrix} \text{---} x^{(1)T} \text{---} \\ \vdots \\ \text{---} x^{(m)T} \text{---} \end{pmatrix} \quad \text{と表現すると } \text{Sigma} = (1/m) * X' * X$$

$$\begin{matrix} m & n \\ \boxed{X'} & \boxed{X} \end{matrix} \rightarrow \begin{matrix} n \\ \boxed{\Sigma} \end{matrix}$$

$$U_{\text{reduce}} = U(:, 1:k);$$

↑  
全20行      1~k列

$$\begin{matrix} k \\ \boxed{U_{\text{reduce}}} \end{matrix}$$

$$Z = U_{\text{reduce}}' * X$$

$$\begin{matrix} n & 1 \\ \boxed{U_{\text{reduce}}'} & \boxed{X} \end{matrix} \rightarrow \begin{matrix} 1 \\ \boxed{Z} \end{matrix}$$

[講義中の Quiz]

PCAにより  $x \in \mathbb{R}^n$  から  $z \in \mathbb{R}^k$  を得る.


$$z = \begin{pmatrix} z_1 \\ \vdots \\ z_k \end{pmatrix} = \begin{pmatrix} \text{---} u^{(1)T} \text{---} \\ \vdots \\ \text{---} u^{(k)T} \text{---} \end{pmatrix} \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix}$$

$$\therefore \underline{z_j = u^{(j)T} \cdot x} \quad (\text{答})$$



compress したデータを元の次元に戻す

$$X_{\text{approx}} = U_{\text{reduce}} \cdot Z$$



[講義中の Quiz]

次元 reduction された  $k=n$  の PCA を実行した場合、

variance の percent / fraction は  $\frac{\sum_{i=1}^k S_{ii}}{\sum_{i=1}^n S_{ii}}$  で与えられる。

正しいのはどれか？

①  $U_{\text{reduce}}$  は  $n \times n$  行列

②  $X_{\text{approx}} = X$  が全ての  $X$  に成り立つ


$U$  は同じ次元の別の座標系での座標を元の次元に戻せる

③ percentage of variance = 100%

$\because k=n$  全ての成分を分子に含む

④  $\frac{\sum_{i=1}^k S_{ii}}{\sum_{i=1}^n S_{ii}} > 1$    $\because$  1 未満

$$[U, \underbrace{S}_{\downarrow}, V] = \text{svd}(\text{Sigma})$$



$S_{ii}$  は  
固有値か?  
(eigen value)

PCA component の数  $k$  を選ぶ

$k$  は次の条件を満たす中で最小の値

$$\frac{\frac{1}{m} \sum_{i=1}^m \|x^{(i)} - x_{\text{approx}}^{(i)}\|^2}{\frac{1}{m} \sum_{i=1}^m \|x^{(i)}\|^2} \leq 0.01 \quad (1\%) \quad \dots \textcircled{1}$$

← 2乗誤差の和      ← variance の 2乗和

“99% of variance is retained”

「99% の分散が保持されている」

← 他人に説明する時は、この表現を使う

$k$  を用いた方法

$k=1$  で PCA を実行して ① が満たされているかを check する。

↓

$k$  を増やしていく

$$\textcircled{1} \text{ の左辺} = 1 - \frac{\sum_{i=1}^k S_{ii}}{\sum_{i=1}^n S_{ii}} \quad \text{である。} \quad \therefore \textcircled{1} \text{ は } \frac{\sum_{i=1}^k S_{ii}}{\sum_{i=1}^n S_{ii}} \geq 0.99 \text{ と同じ}$$

[講義中の Quiz]

PCA は projection error を小さくするために  $u^{(1)}$  を選ぶこと。

同じ意味の式は


$$\frac{1}{m} \sum_{i=1}^m \|x^{(i)} - x_{\text{approx}}^{(i)}\|^2$$

Advice for Applying PCA

feature の数を減らすのに使える。

Supervised learning speedup

$(x^{(1)}, y^{(1)}), \dots, (x^{(m)}, y^{(m)})$ , where  $x^{(i)} \in \mathbb{R}^{10,000}$



unlabeled dataset  $\{x^{(1)}, \dots, x^{(m)}\}$  where  $x^{(i)} \in \mathbb{R}^{10,000}$

↓ PCA

$\{z^{(1)}, \dots, z^{(m)}\}$  where  $z^{(i)} \in \mathbb{R}^{1,000}$

新しい特徴量

training set:  $(z^{(1)}, y^{(1)}), \dots, (z^{(m)}, y^{(m)})$

[Note]  $x^{(i)} \rightarrow z^{(i)}$  への mapping は training set のみに対して実行した PCA で定義しておくべき。

その mapping を cross validation や test の時にも使うべき。

PCA を適用する利点

Compression

- 行列を千倍より千倍の節約
- 学習の speed up

Visualization

$k=2$  or  $3$  ならば視覚化しやすい

注意 overfitting を直すには使えない (features を減らすと)。本質的な feature は減っていないので。

overfitting を直すには regularization の  $\lambda \rightarrow 大$  を使うべき

注意

最初 PCA を使わずにやる。それで駄目なら PCA を適用してみる

Week 8 12

[講義中の Quiz]

PCA を使うのに適切なものは?

- ① メモリやディスクの節約のために compression する ○
- ② 学習を speed up するために特徴の次元を減らす ○
- ③ regularization のために、feature を減らして overfit を避ける ×
- ④  $k=2$  或  $3$  にして visualizing する ○