

データ解析

第十回「 k -近傍法」

鈴木 大慈
理学部情報科学科
西八号館 W707 号室
s-taiji@is.titech.ac.jp

7/7 は休講

今日の講義内容

- k -近傍法による密度推定
- k -近傍法による判別

- ① k -近傍法による確率密度推定
 - k -近傍法の推定手法
 - k の選択
 - 理論
- ② k -近傍法による判別
- ③ 実データでの実験

k -近傍法による確率密度推定の目的

ノンパラメトリック密度推定法の一つ
カーネル密度推定と類似

k -近傍密度推定法の長所・短所

- (長所) 計算が簡単. k -近傍への距離を計算すればよい.
- (長所) 漸近的な性質が理論的に導出可能.
- (長所) 分布に対する仮定が少ない. 滑らかさくらい.
- (短所) 推定した密度が積分して1になるとは限らない.
- (短所) 推定した密度関数は不連続になりえる.
- (短所) ノイズに弱い.
- (短所) 推定された分布は裾が重い.

- ① k -近傍法による確率密度推定
 - k -近傍法の推定手法
 - k の選択
 - 理論
- ② k -近傍法による判別
- ③ 実データでの実験

k -近傍密度推定量

$\{X_i\}_{i=1}^n$: データ (d 次元とする)

k -近傍密度推定量 (k -nearest neighbor)


- ① $k \geq 1$ を一つ固定.
- ② 点 x に一番近い k 個のサンプル点 $\{X_{(1)}, X_{(2)}, \dots, X_{(k)}\}$ を持つてくる. (距離が近い順に並んでいるとする. $X_{(k)}$ が一番遠い)
- ③ 密度を次のように推定:

$$\hat{p}(x) = \frac{k}{nV_d\|x - X_{(k)}\|^d}.$$

ただし, V_d は d 次元超球 ($\{x \in \mathbb{R}^d \mid \|x\| \leq 1\}$) の体積. $V_d = \frac{\pi^{d/2}}{\Gamma(d/2+1)}$.

x のまわりに多くのサンプルがあれば $\hat{p}(x)$ は大きく, 逆に少なければ $\hat{p}(x)$ は小さい.

k -近傍



$k = 10$ での k -近傍

k -近傍密度推定法の簡単な導出

x のまわりの半径 R の領域を S とする:

$$S := \{x' \in \mathbb{R}^d \mid \|x - x'\| \leq R\}.$$

S に点が含まれる確率 P は以下のように与えられる:

$$P = \int_S p(x') dx'.$$

すると、 n サンプルのうち k 個が S に落ちる確率は

$$P(|\{X_i \in S\}| = k) = \binom{n}{k} P^k (1 - P)^{n-k}$$

である。二項分布の平均と分散より

$$E\left[\frac{k}{n}\right] = P, \quad \text{Var}\left[\frac{k}{n}\right] = \frac{P(1-P)}{n}.$$

よって、サンプルサイズ n が十分大きければ、

$$P \simeq \frac{k}{n}$$

である。ただし、 k は領域 S に含まれるサンプルの数である。

一方, R が十分小さければ,

$$P = \int_S p(x') dx' \simeq V(S)p(x)$$

である (テイラー展開).
これらを合わせて,


$$V(S)p(x) \simeq \frac{k}{n} \Rightarrow p(x) \simeq \frac{k}{nV(S)}.$$

特に, R として $\|x - X_{(k)}\|$ としたものが k -近傍法である. V_d を単位球の体積とすると,

$$V(S) = V_d R^d$$

なので, 密度推定量を得る.


k -近傍法の様子




$k = 100, n = 10000$

k -近傍法の k と推定結果


$n = 100$



$k = 1$




$k = 10$




$k = 50$

k -近傍法の k と推定結果


$n = 10000$



$k = 1$




$k = 10$




$k = 50$

k -近傍法の k と推定結果

$n = 100000$



$k = 50$




$k = 500$

サンプルサイズが大きくなるにつれ、 k も大きくしたほうがよい。

- ① k -近傍法による確率密度推定
 - k -近傍法の推定手法
 - k の選択
 - 理論
- ② k -近傍法による判別
- ③ 実データでの実験

k -近傍密度推定と k の関係



カーネル密度推定のカーネルと同様に、 k は適切に選ぶ必要がある。
クロスバリデーションを使えばよい。

- ① k -近傍法による確率密度推定
 - k -近傍法の推定手法
 - k の選択
 - 理論
- ② k -近傍法による判別
- ③ 実データでの実験

$k \geq 1$ に対する, k -近傍密度推定量を

$$\hat{p}(x) = \frac{k}{nV_d \|x - X_{(k)}\|^d}$$

とする.

- 推定量 \hat{p} の点 x における平均二乗誤差 (**Mean Squared Error**) :

$$\text{MSE}(\hat{p}(x), k) := E[(\hat{p}(x) - p(x))^2].$$

ただし, 期待値 $E[\cdot]$ はサンプル $\{X_i\}_{i=1}^n$ の出方についてとる.

Q: k に対して平均二乗誤差はどのように振る舞うか?

平均二乗誤差の漸近的振る舞い

$n \rightarrow \infty$ に伴い、 $k \rightarrow \infty$ とする。その時、

$$\text{MSE}(\hat{p}(x), k) = \frac{p^2(x)}{k} + \frac{c^2(x)}{p^{4/d}(x)} \left(\frac{k}{n}\right)^{4/d} + o\left(\frac{1}{k} + \left(\frac{k}{n}\right)^{4/d}\right),$$

ただし、

$$c(x) = \frac{1}{2(d+2)\pi} \Gamma^{2/d} \left(\frac{d+2}{2}\right) \text{Tr}[\nabla \nabla^\top f(x)].$$

証明は省略。例えば Biau et al. (2011) を参照。

これより最適な k は

$$k^* = \left\lceil \frac{f^{2+4/d}(x)d}{4c^2(x)} n^{4/(d+4)} \right\rceil \propto n^{4/(d+4)}$$

で、このとき

$$\text{MSE}(\hat{p}(x), k^*) = O(n^{-\frac{4}{d+4}}).$$

カーネル密度推定と同じオーダー (二回微分可能な pdf 推定の最適オーダー)。

次元の呪い

カーネル密度推定と同様に

$$\text{MSE}(\hat{p}(x), k^*) = O\left(n^{-\frac{4}{d+4}}\right)$$

は、 d が大きくなると収束レートが遅くなる。

「次元の呪い」はノンパラメトリック推定において必ず現れる。

- ① k -近傍法による確率密度推定
 - k -近傍法の推定手法
 - k の選択
 - 理論
- ② k -近傍法による判別
- ③ 実データでの実験

k -近傍法による判別

- 密度推定はそこまで安定していない.
- カーネル密度推定を用いたほうが良さそう.
- k -近傍法は, むしろ判別でよく用いられている.
- 機械学習などで用いられる最も初等的な判別器の一つ.
- へたに凝った方法を用いるより精度が出たりする.

k-近傍法による判別

サンプル : $\{(X_i, Y_i)\}_{i=1}^n \in \mathbb{R}^d \times \{1, \dots, Q\}$

ただし, $Y_i \in \{1, 2, \dots, Q\}$. つまり Q 個のカテゴリへの分類.

やりたいこと : サンプルから新しい点 x を Q 個のカテゴリへ判別したい.

(例 : 手書き文字認識)

n_1, n_2, \dots, n_Q : カテゴリ q のサンプルの数とする ($\sum_{q=1}^Q n_q = n$).

- ① 点 x に最も近い k 個のサンプルを取ってくる. それを $\{(X_{(1)}, Y_{(1)}), (X_{(2)}, Y_{(2)}), \dots, (X_{(k)}, Y_{(k)})\}$ とする.
- ② この k 個の内, 最も数が多かったカテゴリへ x を判別: k_q を k 個のサンプルのうち, カテゴリ q であるものの数として ($\sum_{q=1}^L k_q = k$),

$$\hat{q}(x) = \operatorname{argmax}_{q=1, \dots, Q} k_q.$$

判別の解釈

直観：近くに沢山あるカテゴリがもっとも確からしいだろう。

点 x がカテゴリ q である確率を $P(q|x)$ とする。ベイズの定理より、

$$P(q|x) = \frac{p(x|q)P(q)}{\sum_{q=1}^Q p(x|q)P(q)} = \frac{p(x|q)P(q)}{p(x)}$$

である。ただし、

- $p(x|q)$ はカテゴリ q に属するサンプルの確率密度関数。
- $p(x)$ は x の周辺確率密度関数。
- $P(q)$ はカテゴリ q が出る確率。

- $p(x)$ は k -近傍法で推定可能.
- $P(q)$ もサンプルから推定可能 (多項分布の最尤推定):

$$\hat{P}(q) = \frac{n_q}{n}.$$

- $p(x|q)$ も k -近傍法で推定可能 :

$$\hat{p}(x|q) = \frac{k_q}{n_q V_d \|X_{(k)} - x\|^d}$$


(半径 $\|X_{(k)} - x\|$ の球に k_q 個入っている).

以上をベイズの定理に代入すると,


$$\begin{aligned} \hat{P}(q|x) &= \frac{\hat{p}(x|q)\hat{P}(q)}{\hat{p}(x)} \\ &= \frac{\frac{k_q}{n_q V_d \|X_{(k)} - x\|^d} \times \frac{n_q}{n}}{\frac{k}{n V_d \|X_{(k)} - x\|^d}} \\ &= \frac{k_q}{k}. \end{aligned}$$

を得る. この最大値が $\hat{q}(x)$ である.

k -近傍法による判別の結果



k -近傍法による判別の結果



判別誤差のクロスバリデーション

Cross Validation

判別誤差を最小にする k 選びたい.

J-fold クロスバリデーション

- ① サンプルを J 個に等分割する.
- ② J 分割の j 番目のグループを \mathcal{I}_j とおく: $\{(X_i, Y_i)\}_{i \in \mathcal{I}_j}$ ($j = 1, \dots, J$).
- ③ $\hat{f}_{(j)} : \mathbb{R}^d \rightarrow \{1, 2, \dots, Q\}$ を j 番目のグループ \mathcal{I}_j を 除いて 推定された判別器とする.
- ④ 判別誤差の推定量 $\hat{E}(k)$ を計算:

$$\hat{E}(k) = \sum_{j=1}^J \left(\frac{1}{|\mathcal{I}_j|} \sum_{i \in \mathcal{I}_j} \mathbf{1}[\hat{f}_{(j)}(X_i) \neq Y_i] \right).$$

- ⑤ $\hat{E}(k)$ を最小にする k を採用.

データのスケールリング

d 次元データを用いる場合、座標ごとのスケールが大きく違う場合、推定結果が悪くなる場合がある。

講義で紹介した k -近傍法は等方的にユークリッドノルムによる球を用いているためである。

解決法

- 座標ごとの分散を揃える (座標ごと正規化する):

$$X_{i,j} \leftarrow X_{i,j}/\text{std}(X_{:,j}).$$

- 座標ごとに幅が異なる楕円や長方形を使う。その際、 $V_d \|x - X_{(k)}\|^d$ の代わりに楕円や長方形の体積を用いる。

- ① k -近傍法による確率密度推定
 - k -近傍法の推定手法
 - k の選択
 - 理論
- ② k -近傍法による判別
- ③ 実データでの実験

k -近傍法を行える R 関数


使い方はスクリプトを参照

k -近傍密度推定方のパッケージは見つからなかった。スクリプトに関数を定義してある。

- `knn(train, test, cl, k = 1, l = 0, prob = FALSE, use.all = TRUE)`: FNN パッケージに入っている。
 - `l` や `use.all` はタイを処理するための引数。
 - 同パッケージに入っている `knn.dist` などを用いれば KD 木（等）を用いた k -近傍の高速計算が可能。
- `kknn`: `kknn` パッケージに入っている。重み付き k -近傍法が使える。


世田谷区中古マンション価格データ

$k = 30$ を採用. 不安定.




世田谷区中古マンション価格データ

$k = 30$ を採用. 不安定.






世田谷区中古マンション価格データ

$k = 30$ を採用. 不安定.




カーネル密度推定の結果 (参考)



世田谷区中古マンション価格データの判別



1K, 1DK, 1LDK とそれ以外 (2LDK など) とを判別. $k = 10$. 赤が部屋数 1 で, 青がそれ以上.



手書き文字認識


MNIST 手書き文字データ:

- 28 × 28 のグレースケール画像.
- 6000 個の訓練サンプル, 10000 個のテストサンプル.



※ 講義情報ページから csv ファイルを入手可能.

データ形式



輝度値は 0 から 255 の整数値.


k-近傍判別

$k = 10$ で 96.65%の正答率.


```
> res = knn(data.train_origin[,1:dimx], data.test[,1:dimx],
            data.train_origin[,dimy], k = 10, prob=FALSE)
> (clerr = mean(res!=data.test[,dimy])) #0.0335, 96.65%の確率で正解.
[1] 0.0335
> table(res,data.test[,dimy])
```

res	0	1	2	3	4	5	6	7	8	9
0	972	0	13	0	2	4	6	0	6	7
1	1	1132	12	3	11	0	4	27	4	6
2	1	2	982	3	0	0	0	4	5	3
3	0	0	2	976	0	12	0	0	11	7
4	0	0	1	1	940	1	3	2	7	10
5	2	0	0	10	0	863	2	0	9	3
6	3	1	2	1	4	6	943	0	4	1
7	1	0	17	7	1	1	0	983	7	10
8	0	0	3	6	1	1	0	0	914	2
9	0	0	0	3	23	4	0	12	7	960


誤判別例



判別結果 9
正解 4



判別結果 4
正解 9



判別結果 7
正解 2

k -近傍法によるデータ解析

- ① 密度推定
- ② 判別

k の選択は重要であった.

レポート問題 (第四回)

- 1 自分の興味のあるデータで講義第八回に紹介した検定手法を当てはめてみよう。もしデータが見つからなければ「autopoll.csv」で分散分析を行ってみよう。
- 2 講義第七回に説明した主成分分析を実装せよ。具体的には、データ x を受け取って第 k 番目までの主成分スコア、対応する主成分負荷 (λ_j) および主成分のリストを返す関数を作成せよ。
 - Y_k : k 番目までの主成分スコア
 - L_k : k 番目までの主成分負荷 ($\lambda_1, \dots, \lambda_k$)
 - V_k : k 番目までの主成分ベクトルを並べた行列
- 3 上で得た自作の関数と R の組み込み関数 `princomp` の返り値とを比較せよ。
- 4 「ken-c-kakou.csv」にあるデータを用いて主成分分析を行え（データは講義七回目の zip ファイルに入っている）。なお、このデータは総務省統計局「統計でみる都道府県のすがた。経済基盤」から抜粋した：
<http://www.stat.go.jp/data/k-sugata/index.htm>
<http://www.e-stat.go.jp/SG1/estat/List.do?bid=000001052235&cycode=0>
データの読み込みは `x <- read.csv("ken-c-kakou.csv", header=TRUE)` で可能。
- 5 (optional) 自分が興味のあるデータで主成分分析を行え。

レポートの提出方法

- 私宛にメールにて提出。
- 件名に必ず「データ解析第 n 回レポート」と明記し、R のソースコードと結果をまとめたレポートを送付のこと。
- 氏名と学籍番号も忘れず明記すること。
- レポートは本文に載せても良いが、pdf などの電子ファイルにレポートを出力して添付ファイルとして送付することが望ましい (これを期に tex の使い方を覚えることを推奨します)。
- 出力結果をただ提示するだけでなく、必ず考察を入れること。
- 提出期限は講義最終回まで。

※相談はしても良いですが、コピーは厳禁です。

講義情報ページ

<http://www.ocw.titech.ac.jp/index.php?module=General&action=T0300&GakubuCD=100&GakkaCD=15&KougiCD=5522&Nendo=2015&Gakki=1&lang=JA&vid=03>

<http://www.is.titech.ac.jp/~s-taiji/lecture/2015/dataanalysis/dataanalysis.html>

G. Biau, F. Chazal, D. Cohen-Steiner, L. Devroye, and C. Rodríguez. A weighted k-nearest neighbor density estimate for geometric inference. *Electron. J. Statist.*, 5:204–237, 2011. doi: 10.1214/11-EJS606. URL <http://dx.doi.org/10.1214/11-EJS606>.