

# 情報認識

## 「最近傍密度推定法(第13章)」

- 担当教員: 杉山 将 (計算工学専攻)
- 居室: W8E-505
- 電子メール: [sugi@cs.titech.ac.jp](mailto:sugi@cs.titech.ac.jp)

- 識別関数のよさを測る規準
- 条件付き確率の推定
  - パラメトリック法
    - 最尤推定法, EMアルゴリズム
    - ベイズ推定法, 最大事後確率推定法
  - ノンパラメトリック法
    - カーネル密度推定法
    - 最近傍密度推定法
- 手書き文字認識の計算機実習

# ノンパラメトリック法の表記

160


- ある注目点  $x'$  での確率密度  $p(x')$  を推定する
- $R$ :  $x'$  を含むパターン空間  $D$  内のある領域(region)
- $V$ :  $R$  の体積(volume)

$$V = \int_R dx$$

- $P$ : あるパターン  $x$  が  $R$  に入る確率

$$P = \int_R p(x) dx$$

- $k$ :  $n$  個の訓練標本のうち  
 $R$  に入っている個数



# ノンパラメトリック法の基礎

161

- 確率  $P$  を二つの方法で近似する.

A)  $k, n$  を用いれば,


$$P \approx k/n$$

B) 領域  $R$  内のある点  $x'$  を用いれば,

$$P \approx Vp(x')$$

- これらより

$$p(x) \approx \frac{k}{nV}$$



# ノンパラメトリック法

162

$$p(x) \approx \frac{k}{nV}$$

■ 訓練標本を用いて領域  $R$  を決める.

● パーゼン窓法, カーネル密度推定法:

$R$  の形を決め  $V$  を固定したもとの  $k$  を標本から決定

● 最近傍密度推定法:


$R$  の形を決め  $k$  を固定したもとの  $V$  を標本から決定

## ■ k-最近傍密度推定法 (k-nearest neighbor density estimation):

- 領域  $R$  として, ある点  $x'$  を中心とする超球 (hypersphere) を用いる.
- 超球の半径  $r$  : 訓練標本が  $k$  個含まれる最小の大きさに設定

- 超球の体積:

$$V = \frac{\pi^{\frac{d}{2}} r^d}{\Gamma(\frac{d}{2} + 1)}$$



- $\hat{p}(x) = \frac{k\Gamma(\frac{d}{2} + 1)}{n\pi^{\frac{d}{2}} r^d}$


$$p(x) \approx \frac{k}{nV}$$

# ガンマ関数

164

## ■ ガンマ関数(gamma function):

$$\Gamma(\lambda) = \int_0^{\infty} x^{\lambda-1} e^{-x} dx$$



# ガンマ関数の性質

165

$$\Gamma(\lambda) = \int_0^{\infty} x^{\lambda-1} e^{-x} dx$$

- **階乗の一般化**: 正の整数  $n$  に対して

$$\Gamma(n+1) = n!$$

- **その他の性質**

- $\Gamma(t) = (t-1)\Gamma(t-1), \forall t \in \mathbf{R}$
- $\Gamma(\frac{1}{2}) = \sqrt{\pi}$


- **演習**:

- $d = 2$  のとき  $V = \pi r^2$
- $d = 3$  のとき  $V = \frac{4}{3} \pi r^3$


$$V = \frac{\pi^{\frac{d}{2}} r^d}{\Gamma(\frac{d}{2} + 1)}$$

# 最近傍密度推定法の例

166



真の確率密度関数



1-最近傍密度推定法で推定した確率密度関数

## ■ カーネル密度推定法

- 滑らかなカーネルを使えば, 滑らかな確率密度推定量が得られる

## ■ 最近傍密度推定法

- 得られる確率密度推定量は比較的ギザギザしている?
- パターン認識との相性がよい(次ページ参照)


- 各カテゴリに対して、条件付き確率  $p(x|y)$  を 1-最近傍密度推定法により推定.

$$\hat{p}(x|y) = \frac{\Gamma(\frac{d}{2} + 1)}{n_y \pi^{\frac{d}{2}} r_y^d}$$

$r_y$ : カテゴリ  $y$  に属する標本のうち  $x$  に最も近いものと,  $x$  との距離

- $p(y) \approx n_y / n$  を用いれば、事後確率  $p(y|x)$  は、

$$p(y|x) \propto p(x|y)p(y) \approx \frac{\Gamma(\frac{d}{2} + 1)}{n_y \pi^{\frac{d}{2}} r_y^d} \frac{n_y}{n} \propto \frac{1}{r_y^d}$$




$r_y$  が小さいほうが  
事後確率が大きい!

# 最近傍識別器

169

- 事後確率が最大のカテゴリ  
=  $x$  に一番近い訓練標本が属するカテゴリ
- このような識別法を, **最近傍識別器(nearest neighbor classifier)**とよぶ.




- 実用的には,  $x$  の近傍  $k$  個の訓練標本が属するカテゴリの多数決で,  $x$  の属するカテゴリを決める  $k$ -最近傍識別器(k-nearest neighbor classifier)がよく用いられる.
- 注:  $k$ -最近傍密度推定法で確率密度関数を推定するのと少し異なる

- $k$ -最近傍識別器では近傍数 $k$ を適切に決める必要がある.
  1. 値の候補を用意する. 例えば,  $k = 1, 2, \dots, 10$
  2. それぞれのモデルに対して, **パターンの誤認識率**を推定する.
  3. 誤認識率の推定値を最小にするモデルを選ぶ.
  
- どうやってパターンの誤認識率を推定するか？

## ■ 交差確認法(cross validation)

- 訓練標本  $\{x_i\}_{i=1}^n$  を  $t$  個の重なりの無い、(ほぼ)同じ大きさの部分集合  $\{T_i\}_{i=1}^t$  に分ける.
- $j$  番目の部分集合  $T_j$  に含まれる訓練標本を使わずに識別器を学習する.
- $T_j$  に含まれる標本の誤認識率を計算する(訓練標本なので答えを知っている!).
- これを全ての  $j$  に対して繰り返し平均する.



- 1次元の入力に対する最近傍密度推定法を実装し、適当なデータを用いて確率密度関数を推定せよ.
- データ標本数, 真の確率分布, 近傍数などの条件を変化させたとき, どのように推定結果が変わるかを考察せよ.
- 余力のある学生は, 入力が2次元の場合に対しても同様の実験を行え. また, 次元が増えたことによりどのような変化が生じたかを考察せよ.

# Octaveのサンプルプログラム 174

nnde.m

```
clear all

n=10000; x=myrand(n); k=200;
xx=0:0.01:5; m=length(xx);
dist= repmat(xx',[1 n])-repmat(x,[m 1]);
sort_dist=sort(abs(dist),2);
r=sort_dist(:,k)';
pxh=k*gamma(3/2)./(n*pi^(1/2)*r);

figure(1); clf;
hist(x,0:0.1:5,10);
figure(2); clf;
plot(xx,pxh,'r-');
legend('true','estimated')
print -depsc nnde.eps
```

myrand.m

```
function x=myrand(n)

x=zeros(1,n);
u=rand(1,n);

flag=(0<=u & u<1/8);
x(flag)=sqrt(8*u(flag));
flag=(1/8<=u & u<1/4);
x(flag)=2-sqrt(2-8*u(flag));
flag=(1/4<=u & u<1/2);
x(flag)=1+4*u(flag);
flag=(1/2<=u & u<3/4);
x(flag)=3+sqrt(4*u(flag)-2);
flag=(3/4<=u & u<=1);
x(flag)=5-sqrt(4-4*u(flag));
```

# 今後の予定

175

- 12月9日: 計算機演習
- 12月16日: 通常の講義
  - ガウス混合モデル(第8章)
- 12月23日: 計算機演習

計算機演習は出欠を取らないので、各自好きな時間に演習を行なって良い。  
課題はOCWで事前に公開する。  
12月2日の宿題は12月16日に提出すること。