

パターン認識と学習


岡山大学大学院 竹内孔一

本日の内容

- 識別部の設計

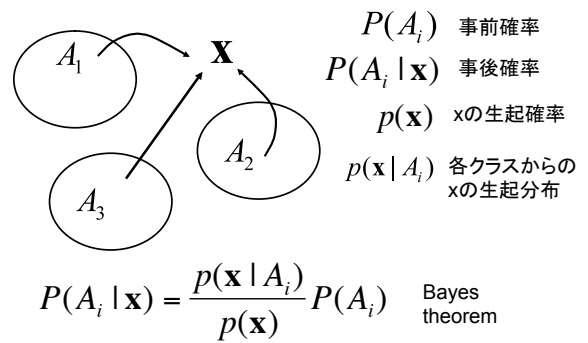
情報源の仮定

- 事例が統計的な分布に従う



前提: 事例 x は各クラス A_i に対してある確率密度分布に従って生起していると仮定する

情報源の仮定



識別関数

- 事後確率を最大にするクラスを判別結果とする

$$\max_i \{P(A_i | \mathbf{x})\} = P(A_l | \mathbf{x})$$


未知の入力 x はクラス A_l に分類される

→ つまり, $P(A_i | \mathbf{x})$ を識別関数と同じと見なす

$$g_i(\mathbf{x}) = \frac{p(\mathbf{x} | A_i)}{p(\mathbf{x})} P(A_i)$$


def
 $= p(\mathbf{x} | A_i) P(A_i)$ $p(\mathbf{x})$ はクラス A_i を選択するときは固定なので省略

事後確率の最大化とは?



練習

- 各クラス A_i 内である特徴量 \mathbf{x} が生起する確率は正規分布であるとする
 - 平均ベクトル μ_i
 - 共分散行列 Σ_i
 とするとき、下記の図にその様子を書き込め (μ_i, Σ_i を使うこと)



- 共分散行列 $\Sigma_i = \Sigma_0$ とはどのような状況か説明せよ
- 共分散行列 $\Sigma_0 = I$ (単位行列) とはどのような状況か説明せよ

例題

- 入力が各クラスの正規分布で発生していると仮定したとき、NN法(最小距離識別法)はどういう特殊な条件であるか答えよ

識別部の設計

- 確認
 - 前提としてある事例 \mathbf{x}_p はクラス A_i からどのように生成されていると考えられるか
 - 共分散行列 (covariance matrix)はどのようなものか説明せよ
 - マハラノビス距離 (Mahalanobis distance)はどのような特徴を測ったものか

生成モデルと判別モデル

- 仮定と事後確率

判別モデル $p(A_i | \mathbf{x})$ $\xrightarrow{\text{事後確率}} \text{識別関数}$

生成モデル $p(\mathbf{x} | A_i)$ 仮説としておいた分布

やろうと思えば学習データから直接どちらも求まる

Bayesの定理を利用して $p(A_i | \mathbf{x})$ を通して $p(A_i | \mathbf{x})$ を求める方法を生成モデルと呼ぶ。Hidden Markov Modelなど。

直接学習データから $p(A_i | \mathbf{x})$ を求める方法もある。事後確率を直接求めると分母が疎なので推定が(普通)よくないが、Conditional Random Fieldなどでは $\exp()$ を分布として仮定して疎なデータに対して良い予測を与える。判別モデルと呼ばれる。

パラメータ推定

- 下記の式の意味を答えなさい

$$p(X; \phi) = \prod_{j=1}^n p(\mathbf{x}_j; \phi)$$

$$p(X | A_i; \phi_i) = \prod_{j=1}^n p(\mathbf{x}_j | A_i; \phi_i)$$

- パラメトリックな学習とは何か?

最尤推定

- 全学習データ X に対して下記の式が最大になるようにパラメータ ϕ を学習する

– そもそもなぜ最大にするのだから? $p(X; \phi) = \prod_{j=1}^n p(\mathbf{x}_j; \phi)$

$p(X; \phi)$ は ϕ によって $p(\mathbf{x})$ の形が決まり、全学習データ X の確率値を書けた確率値(いつものパターン!)

$p(\mathbf{x}; \phi)$ は未知だけど、実際にデータ $X = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}$ は出現した \rightarrow これが出てきたのだからデータ X を $p(\mathbf{x}; \phi)$ はうまく説明して欲しい


今、 \mathbf{x} は分布 $p(\mathbf{x}; \phi)$ に依存して出力してると考えている。ならば、 $p(\mathbf{x}; \phi)$ から X が出力したと考えると、その p で全データ X に対して確率値 $p(X; \phi)$ を求めれば、最大の値になるはず

具体例


学習データ $X = \{x_1, x_2, x_3, x_4, x_5\}$
が下記のように分布しているとす

最尤推定 →
密なところに大きな
確率値を割り当てる
ように ϕ を決定

良い推定
(良い当てはめ)



悪い推定
(わるい当てはめ)



最尤推定(確率最大化 → 数を数える)

- 推定対象の確率変数 $\{\theta_1, \dots, \theta_N\}$ P(sj|si-1)の場合
 θ_i は 例えば s_{i-1}
- N個の事象 $\{N_1, \dots, N_n\}$ N_i は s_{i-1} から s_i の遷移
- 事象 N の出現回数が n_i n_i は s_{i-1} から s_i の遷移の回数
C($s_{i-1} \rightarrow s_i$)
- 事象の生起確率

$\{P(\theta_1), \dots, P(\theta_N)\} \rightarrow$ これを最尤推定
次の式を以下の制約のもとに最大化する

$$L = \sum_{i=1}^N n_i \log P(\theta_i)$$

制約 $\sum_{i=1}^N P(\theta_i) = 1$ Lanrange 未定乗数法

最尤推定

Lagrange 関数

$$F = \sum_{i=1}^N n_i \log P(\theta_i) + \lambda \sum_{i=1}^N P(\theta_i)$$

これを θ_i で偏微分する

$$\frac{\partial F}{\partial P(\theta_i)} = \frac{n_i}{P(\theta_i)} + \lambda = 0 \quad \text{よって} \quad P(\theta_i) = -\frac{n_i}{\lambda} \quad \textcircled{1}$$

制約式に代入して

$$1 = \sum_{i=1}^N P(\theta_i) = -\frac{1}{\lambda} \sum_{i=1}^N n_i \quad \lambda = -\sum_{i=1}^N n_i$$

よって λ を $\textcircled{1}$ に代入して

$$P(\theta_i) = \frac{n_i}{\sum_{k=1}^N n_k}$$

参考: 奈良先端大:
音声情報処理講義録
鹿野先生 1994年

ラグランジュ未定乗数法

- 制約の中で式を解く
 - M個の制約条件 $g_i(x) = 0$ ($i=1, 2, \dots, M$)
 - $f(X)$ の極値をとりたい (極大 or 極小)
- ラグランジュ乗数 $\mathbf{a} = [\alpha_1, \dots, \alpha_M]^T$ を使って

$$L(X, \mathbf{a}) = f(X) - \sum_{i=1}^M \alpha_i g_i(X)$$

$$\frac{\partial L}{\partial x_k} = 0 \quad \frac{\partial L}{\partial \alpha_i} = 0$$

$$(k=1, 2, \dots, N) \quad (i=1, 2, \dots, M) \quad \text{を解けばよい.}$$