

はじめてのパターン認識

第3章 ベイズの識別規則

茨城大学大学院理工学研究科

菊池裕紀

3.1 ベイズの識別規則(1)

▶ 最大事後確率基準

観測データ： x

識別クラス： C_i ($i = 1, 2, \dots, K$)

$$\underbrace{P(C_i|x)}_{\text{事後確率}} = \frac{\overset{\text{尤度}}{p(x|C_i)}}{\underset{\text{周辺確率}}{p(x)}} \times \underbrace{P(C_i)}_{\text{事前確率}} \cdots \text{ベイズの定理}$$

事後確率が最大となるクラスに観測データを分類

3.1 ベイズの識別規則(2)

▶ クラスの識別境界

事後確率が等しくなるところ

$$P(C_i|\mathbf{x}) = \frac{p(\mathbf{x}|C_i)P(C_i)}{p(\mathbf{x})} = \frac{p(\mathbf{x}|C_j)P(C_j)}{p(\mathbf{x})} = P(C_j|\mathbf{x})$$

共通

$$\text{識別クラス} = \arg \max_i p(\mathbf{x}|C_i)P(C_i)$$

3.1 ベイズの識別規則(3)

▶ ベイズの識別規則の例

	サンプル数	喫煙する人 (S = 1)	飲酒する人 (T = 1)
健康な人 (G = 1)	800人	320人	640人
健康でない人 (G = 0)	200人	160人	40人

目的：この町の他の人の喫煙と飲酒の有無を情報から、その人の健康状態を予測する

$$P(S, T|G) = \frac{P(S, T|G)P(G)}{P(S, T)}$$

3.1 ベイズの識別規則(4)

▶ 事前確率

$$P(G = 1) = \frac{800}{1000} = \frac{4}{5}, \quad P(G = 0) = \frac{200}{1000} = \frac{1}{5}$$

▶ クラスの条件付き確率 (S,Tの条件付き独立を仮定)

$$P(S = 1|G = 1) = \frac{320}{800} = \frac{2}{5}, \quad P(S = 0|G = 1) = \frac{480}{800} = \frac{3}{5}$$

$$P(S = 1|G = 0) = \frac{160}{200} = \frac{4}{5}, \quad P(S = 0|G = 0) = \frac{40}{200} = \frac{1}{5}$$

▶ 周辺確率

$$P(S, T) = P(S, T, G = 1) + P(S, T, G = 0)$$

3.1 ベイズの識別規則(4)

	(S,T)			
	(1,1)	(0,1)	(1,0)	(0,0)
P(G=1,S,T)	8/9	48/49	1/3	3/4
P(G=0,S,T)	1/9	1/49	2/3	1/4
判断	G=1	G=1	G=0	G=1

クラス付き条件確率と事前確率の積の比較

$$P(\mathbf{x}|C_i)P(C_i) \{>, <\} p(\mathbf{x}|C_j)P(C_j) \rightarrow C_i \text{ or } C_j$$

尤度比

$$\frac{P(\mathbf{x}|C_i)}{P(\mathbf{x}|C_j)} \{>, <\} \frac{P(C_j)}{P(C_i)} = h_{ij} \rightarrow C_i \text{ or } C_j$$

3.2 受信者動作特性曲線

▶ 受信者動作特性曲線（ROC曲線）

性能評価法として利用されているもの

以下、2クラス問題の場合...

クラスに属していると判断 : $p(\text{positive})$

クラスに属していないと判断 : $n(\text{negative})$

$\{p^*, n^*\}$ で x の真のクラスを表すこととする。

3.2 受信者動作特性曲線(2)

		識別クラス		行和
		p	n	
真のクラス	p^*	True Positive 真陽性	False Negative 偽陰性	$P=TP+FN$
	n^*	False Positive 偽陽性	True Negative 真陰性	$N=FP+TN$