

§5 クラスタリング (1) 演習問題 解答

📎 問題の難易度の目安【易】☆☆☆ 【基礎】★★☆ 【標準】★★★

1 (☆☆☆)(クロス集計表)

属性 A のカテゴリーを A_1, \dots, A_k , 属性 B のカテゴリーを B_1, \dots, B_ℓ とする. 調査・実験したときのサンプルサイズ (試行回数) を n とし, $A_i \cap B_j$ の観測度数 (確率変数と考える) を X_{ij} とする. 以下の表を $k \times \ell$ -クロス表という.

	B_1	B_2	\dots	B_ℓ	計
A_1	X_{11}	X_{12}	\dots	$X_{1\ell}$	F_1
A_2	X_{21}	X_{22}	\dots	$X_{2\ell}$	F_2
\dots	\dots	\dots	\dots	\dots	\dots
A_k	X_{k1}	X_{k2}	\dots	$X_{k\ell}$	F_k
計	G_1	G_2	\dots	G_ℓ	n

ここで,

$$\sum_{j=1}^{\ell} X_{ij} = F_i, \quad \sum_{i=1}^k X_{ij} = G_j \quad \text{for } i = 1, \dots, k; j = 1, \dots, \ell$$

$$\sum_{i=1}^k F_i = \sum_{j=1}^{\ell} G_j = n.$$

このとき, 次の問いに答えよ.

- (1) クロス集計表において項目数を増やす, すなわち k, ℓ を増やすことにより生じるデメリットを答えよ.
- (2) 有病率が10%の集団に, 感度90%, 特異度75%のスクリーニング検査を実施した. このとき, 陽性適中率を 2×2 クロス集計表を作成して求めよ.

解 (1) k, ℓ を大きくすると詳細な分析が行える一方で, 各項目に含まれるデータの数が少なくなってしまう, 分析結果の信頼性が低くなる可能性がある点.

(2) スクリーニング検査における 2×2 -クロス集計表は以下ようになる:

	病気に罹患している人	病気に罹患していない人	計
陽性	x	z	$x + z$
陰性	y	w	$y + w$
計	$x + y$	$z + w$	$x + y + z + w$

有病率 = $\frac{x+y}{x+y+z+w} = \frac{1}{10}$, 感度 = $\frac{x}{x+y} = \frac{9}{10}$, 特異度 = $\frac{w}{z+w} = \frac{3}{4}$ であるから,

$$\begin{cases} 10(x+y) = x+y+z+w \\ 10x = 9(x+y) \\ 4w = 3(z+w) \end{cases} \iff \begin{cases} 9(x+y) - z - w = 0 & \dots \textcircled{1} \\ x = 9y & \dots \textcircled{2} \\ w = 3z & \dots \textcircled{3} \end{cases}$$

②, ③を①へ代入して, $10x - 4z = 0$, すなわち $z = \frac{5}{2}x$. したがって

$$\text{陽性適中率} = \frac{x}{x+z} = \frac{x}{x+\frac{5}{2}x} = \frac{2}{7} \approx 29\%.$$

2 (★★☆)(決定木分析)

以下はクーポン配布と商品購入に関するクロス集計表である:


	商品購入	商品未購入	計
クーポン配布済男性	12	38	50
クーポン配布済女性	8	42	50
クーポン未配布男性	20	100	120
クーポン未配布女性	10	70	80
計	50	250	300

ノード A に関する Gini 指標 $\mathcal{I}_G(A)$ を

$$\mathcal{I}_G(A) := \frac{m}{m+n} \mathcal{I}_G(p_1) + \frac{n}{m+n} \mathcal{I}_G(p_2)$$

で定める. ただし,

$$\mathcal{I}_G(p_i) := 2p_i(1-p_i), \quad i = 1, 2.$$



このとき, 次の問いに答えよ.

- (1) 性別によるノードの Gini 指標を求めよ.
- (2) クーポン配布によるノードの Gini 指標を求めよ.
- (3) (1),(2)より, このクロス集計表に関する決定木を作成せよ.

解 (1) 男性の商品購入率を p_1 , 女性の商品購入率を p_2 とすると, 与えられたクロス集計表により,

$$p_1 = \frac{32}{170} = \frac{16}{85}, \quad p_2 = \frac{18}{130} = \frac{9}{65}$$

であるから、性別に関するノードの Gini 指標は

$$\mathcal{G}_G(S) = \frac{170}{300} \mathcal{G}_G\left(\frac{16}{85}\right) + \frac{130}{300} \mathcal{G}_G\left(\frac{9}{65}\right) = \frac{1528}{5525} \approx 0.28.$$

(2) クーポン配布済の商品購入率を q_1 、クーポン未配布の商品購入率を q_2 とすると、与えられたクロス集計表により、

$$q_1 = \frac{20}{100} = \frac{1}{5}, \quad q_2 = \frac{30}{200} = \frac{3}{20}$$

であるから、クーポン配布に関するノードの Gini 指標は

$$\mathcal{G}_G(C) = \frac{100}{300} \mathcal{G}_G\left(\frac{1}{5}\right) + \frac{200}{300} \mathcal{G}_G\left(\frac{3}{20}\right) = \frac{83}{300} \approx 0.28.$$

(3) (1),(2) より

$$\mathcal{G}_G(C) = \frac{18343}{66300} > \frac{18336}{66300} = \mathcal{G}_G(S)$$

であるから、性別に関する Gini 指標 $\mathcal{G}_G(S)$ がクーポン配布に関する Gini 指標 $\mathcal{G}_G(C)$ よりも (わずかに) 小さい。したがって、決定木の最上段には性別に関するノードを配置し、2 段目にクーポン配布に関するノードをつける。以上より、求める決定木は以下の通り：

