

データ解析

<http://coconut.sys.eng.shizuoka.ac.jp/data/>

静岡大学工学部
安藤和敏

2005.11.09

質的変数の取り扱い

No	広さ(平米)	住所 u	価格(千万円)
1	51	田町	3.0
2	38	鍛冶町	3.2
3	57	鍛冶町	3.3
4	51	肴町	3.9
5	53	板屋町	4.4
6	77	田町	4.5
7	63	板屋町	4.5
8	69	鍛冶町	5.4
9	72	板屋町	5.4
10	73	肴町	6.0

ダミー変数

住所を表す変数 u は, 田町, 鍛冶町, 肴町, 板屋町のいずれかの値をとる.

住所を表す変数 u の取りうる値のそれぞれに対して, 0か1の値をとる変数を導入する.

$u_{田}, u_{鍛冶}, u_{肴}, u_{板屋}$

そして, 例えば, $u_{鍛冶}$ は以下のように定義する.

$$u_{鍛冶} = \begin{cases} 1 & (u = \text{鍛冶町の時}) \\ 0 & (u \neq \text{鍛冶町の時}) \end{cases}$$

質的変数の取り扱い

No	面積 (平米)	住所				価格 (千万円)
		田町	鍛冶町	肴町	板屋町	
1	51	1	0	0	0	3.0
2	38	0	1	0	0	3.2
3	57	0	1	0	0	3.3
4	51	0	0	1	0	3.9
5	53	0	0	0	1	4.4
6	77	1	0	0	0	4.5
7	63	0	0	0	1	4.5
8	69	0	1	0	0	5.4
9	72	0	0	0	1	5.4
10	73	0	0	1	0	6.0

ダミー変数の問題点とその解決

この多変量データに対して重回帰分析を行うと, 偏回帰係数は一意に定まらない.

なぜならば, こうして導入されたダミー変数 $u_{田}, u_{鍛冶}, u_{肴}, u_{板屋}$ は以下の式を必ず満たしている.

$$u_{田} + u_{鍛冶} + u_{肴} + u_{板屋} = 1$$

このように変数の間に線型従属性が存在するときは, 偏回帰係数は一意に定まらない.

ダミー変数を1つ削除してしまえばよい.

質的変数の取り扱い

No	面積 (平米)	住所			価格 (千万円)
		鍛冶町	肴町	板屋町	
1	51	0	0	0	3.0
2	38	1	0	0	3.2
3	57	1	0	0	3.3
4	51	0	1	0	3.9
5	53	0	0	1	4.4
6	77	0	0	0	4.5
7	63	0	0	1	4.5
8	69	1	0	0	5.4
9	72	0	0	1	5.4
10	73	0	1	0	6.0

質的変数の取り扱い

一般にある質的変数 u が、 R 個の値をとるときには、 $R-1$ 個のダミー変数

$$u_1, u_2, \dots, u_{R-1}$$

を

$$u_j = \begin{cases} 1 & (u = j \text{ のとき}) \\ 0 & (u \neq j \text{ のとき}) \end{cases}$$

で定義して u の代わりに置き換えればよい。

質的変数の取り扱い

このようにして、質的変数 u を $R-1$ 個のダミー変数で置き換えたデータに対して前回までと同様にして、重回帰分析を行えばよい。

2個以上の質的変数が存在する場合は、それぞれの質的変数に対して、上で述べたようにダミー変数を導入すればよい。