

n 人を対象として、2つの質問 (X, Y) をした (それぞれの質問を変数 X, Yとする)。

2つの質問はそれぞれ「はい」か「いいえ」のいずれかを回答するものとする。

得られたデータを分析するとき、各対象者がそれぞれの質問に「いいえ」と答えている場合は0、「はい」と答えている場合は1を対応させる。

例えば、 k 番目の対象が質問 X に「はい」、質問 Y に「いいえ」と答えているときには、 $X_k = 1, Y_k = 0$ となる。表1ではこのようなデータを (1, 0) と表している。

調査の結果得られたデータ $(X_i, Y_i), i = 1, 2, \dots, n$ をまとめると、表1のようになったとする。

表1 2変数データ (X_i, Y_i)

(X_i, Y_i)	
(0, 0)	} 質問 X への回答が「いいえ」で、かつ質問 Y への回答が「いいえ」のものが a 人
⋮	
(0, 0)	
(0, 1)	} 質問 X への回答が「いいえ」で、かつ質問 Y への回答が「はい」のものが b 人
⋮	
(0, 1)	
(1, 0)	} 質問 X への回答が「はい」で、かつ質問 Y への回答が「いいえ」のものが c 人
⋮	
(1, 0)	
(1, 1)	} 質問 X への回答が「はい」で、かつ質問 Y への回答が「はい」のものが d 人
⋮	
(1, 1)	

このとき、変数 X と変数 Y のピアソンの積率相関係数は、(1) 式で定義できる。

$$(1) \quad r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad \text{ただし, } \bar{X} = \frac{1}{n} \sum_{i=1}^n X_i, \quad \bar{Y} = \frac{1}{n} \sum_{i=1}^n Y_i$$

一方、得られたデータを 2×2 分割表として集計すると、表2のようになる。

表2 2×2 分割表における記号の定義

質問 X への回答	質問 Y への回答		合計
	いいえ	はい	
いいえ	a	b	$e (= a + b)$
はい	c	d	$f (= c + d)$
合計	$g (= a + c)$	$h (= b + d)$	$n (= a + b + c + d)$

表2の分割表において、質問 X と質問 Y の間の属性相関係数 ϕ は (2) 式で与えられる。

$$(2) \quad \phi = \frac{|ad - bc|}{\sqrt{efgh}}$$

質問1: 変数 X の平均値 $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ を、表2の記号 (a, b, \dots, h, n) を使って表せ。

質問2: 変数 X の変動 $\sum_{i=1}^n (X_i - \bar{X})^2$ を表2の記号 (a, b, \dots, h, n) を使って表せ。

質問3: (1) 式で得られるピアソンの積率相関係数 r と (2) 式で得られる属性相関係数 ϕ において、 $\phi = |r|$ となることを示せ。