

速修 確率統計

医者の藪野竹庵氏は自分のところへくる患者について

$$A: \begin{cases} A_1: \text{熱がある} \\ A_2: \text{熱がない} \end{cases} \quad B: \begin{cases} B_1: \text{風邪を引いている} \\ B_2: \text{風邪ではない} \end{cases}$$

の 2 種類の事象の割合を調べた。これらの事象を組み合わせると、4 通りの複合事象ができる。事象  $(A_i, B_j)$  の起こる割合は次表のようであった。この割合は、事象  $(A_i, B_j)$  の確率  $p(A_i, B_j)$  であると思ってさしつかえない。

	$B_1$ (風邪)	$B_2$ (風邪なし)	$p(A_i)$
$A_1$ (熱あり)	0.55	0.05	0.60
$A_2$ (熱なし)	0.10	0.30	0.40
$p(B_j)$	0.65	0.35	

この表からわかるように、熱があるかないかを知ってしまえば、風邪であるかないかはほぼ検討がつく。必要な確率の知識を整理しておこう。確率分布として次のものを考える。

$$\begin{cases} \text{同時確率分布: } & p(A_i, B_j) \\ \text{周辺確率分布: } & p(A_i), p(B_j) \\ \text{条件付確率分布: } & p(B_j|A_i), p(A_i|B_j) \end{cases}$$

$p(A_i, B_j)$  のように、 $A_i$  と  $B_j$  とが組になって同時に起こる確率を示すものを、同時確率分布と呼ぶ。そのうちの一方だけに着目した確率分布  $p(A_i)$  や  $p(B_j)$  は、上の表を行または列について加え合わせると出てくる。この  $p(A_i)$  や  $p(B_j)$  は、表の周辺に並んでいるので、周辺分布と呼ぶ。条件付確率分布  $p(B_j|A_i)$  とは  $A$  に関する事象が  $A_i$  であったときの  $B_j$  の確率である。 $p(A_i|B_j)$  は逆に  $B$  が  $B_j$  であることがわかっているときの  $A_i$  の確率である。これらの間には次の関係が成立する。

$$\sum_{i,j} p(A_i, B_j) = 1, \quad \sum_i p(A_i) = \sum_j p(B_j) = 1 \quad (1)$$

$$\sum_j p(B_j|A_i) = \sum_i p(A_i|B_j) = 1 \quad (2)$$

$$p(A_i) = \sum_j p(A_i, B_j), \quad p(B_j) = \sum_i p(A_i, B_j) \quad (3)$$

$$p(A_i, B_j) = p(A_i)p(B_j|A_i) = p(B_j)p(A_i|B_j) \quad (4)$$

$$p(B_j|A_i) = \frac{P(B_j)P(A_i|B_j)}{p(A_i)} = \frac{P(A_i, B_j)}{p(A_i)} \quad (5)$$

$$p(A_i|B_j) = \frac{P(A_i)P(B_j|A_i)}{p(B_j)} = \frac{P(A_i, B_j)}{p(B_j)} \quad (6)$$

式 (4) は、 $A_i$  と  $B_j$  との同時確率は、 $A_i$  の確率に  $A_i$  が起こるとい条件下での  $B_j$  の起こる確率を掛けたものであることを示す。式 (5,6) は Bayes の公式と呼ばれるもので、式 (4) から導き出せる。 $A$  と  $B$  が確率的に 独立な場合 (風邪と熱が無関係の場合) には

$$p(A_i, B_j) = p(A_i)p(B_j) \quad (7)$$

$$p(B_j|A_i) = p(B_j), p(A_i|B_j) = p(A_i), \quad (8)$$

という式が成立する。