

② ベイズの定理の応用例)：迷惑メールの半分は

現在インターネット上には大量の迷惑メールが流れています。
それは受信側のフィルタリング、すなはちある種のレーティング
がメールが否かを判定し、迷惑メールならゴミ箱(またはゴミ箱)に捨てる

迷惑メール半分)には

- ある種のカードが含まれています。
- メールが書かれている文字コード(中国語、ロシア語等)
- メールの発信元が信頼できないサードパーティ
- メールのエンコードが開け式や添付ファイルや重複
- 条件(4)が用いらなければ、それらの条件から、率がメールが迷惑メールである確率をベースの定理から計算し、その値によると捨てるか捨てないかを決定するバイナリフィルタとなります。

じく単純な例でその原理を示す。

- 例) あるメールたち、
- ① 30%が正常で、残りは迷惑メール
 - ② 迷惑メールの8割(=「base64エンコード」等)が迷惑メール
 - ③ 正常メールで「base64エンコード」等が5%

であることが明らかになるとわかる。

このとき、新規に「base64エンコード」等がある迷惑メールは?

- ① ② ③は、メールで太多に聞けとすること(徐々にその精度が上がり、いくつもいる)で、いまいどもこのように複数登場する。重が下がる。

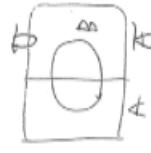
答) $\begin{cases} A = \text{迷惑メール} & (\bar{A} = \text{正常メール}) \\ B = \text{base64エンコード} \end{cases}$

とすると、 $P_B(A)$ は確率

$$\textcircled{1} \Rightarrow P(A) = \frac{7}{10}, \quad P(\bar{A}) = \frac{3}{10} \quad \text{--- (4)}$$

$$\textcircled{2} \Rightarrow \underbrace{P_A(B)}_{\textcircled{5}} = \frac{8}{10} \quad \text{--- (5)}$$

$$\textcircled{3} \Rightarrow \underbrace{\frac{P_B(B)}{P_A}}_{\textcircled{6}} = \frac{5}{100} \quad \text{--- (6)}$$



$$P(B) = P(B \cap A) + P(B \cap \bar{A})$$

$$\left. \begin{aligned} &= P(A) P_A(B) + P(\bar{A}) P_{\bar{A}}(B) \xrightarrow{\textcircled{4}, \textcircled{5}, \textcircled{6}} \\ &= \frac{7}{10} \times \frac{8}{10} + \frac{3}{10} \times \frac{5}{100} = \frac{560 + 15}{1000} = \frac{575}{1000} \\ &\cdot P(B \cap A) = P(A) P_A(B) = \frac{1}{10} \times \frac{8}{10} = \frac{56}{1000} \end{aligned} \right.$$

$$\therefore P_B(A) = \frac{\frac{56}{1000}}{\frac{575}{1000}} = \frac{560}{575} = \underline{\underline{97.4\%}}$$

(高い正確率で、迷惑メールの可能性が高い)