

PCR検査における統計学的考察

2020年6月7日
(改訂 2020年6月30日)

杉本末雄
立命館大学 名誉教授

本測位技術振興会の活動も含め、新型コロナウイルスの感染に伴う社会的影響は甚大である。感染拡大の克服が重要であることについては論を待たない。そのために、PCR検査、抗体検査などが、注目を集めている。

しかし、この検査には、本当は感染している（陽性である）のに、陰性と検査結果が出る（偽陰性）、また逆に、本当は感染していない（陰性である）のに、陽性と検査結果が出る（偽陽性）という、検査に伴う誤りがある。このことを常に考慮しておくことが大変重要なことを示したい。

本論文では、統計学見地からPCR検査（抗体検査なども含め）について考察する。PCR検査については、その検査結果を、誤り確率を明確にしたうえで、被検査者に伝えることが大切であることを示す。そのために、検査対象者にとって、PCR検査結果がどの程度信用できるかについて、統計学での(S1)ベイズの定理を用いて検証する。

また、ランダムサンプリングにより、全国で1万人、大阪府では5千人と、PCR検査対象者を増加させ、感染率を推定したいとの現下の要請がある。ここでは、(S2)比率の最尤推定法について考察し、単なる比率の推定問題として取り扱うことでは、推定精度に大きな問題が生じることを示し、PCR検査の誤り確率の推定値が非常に重要なことを示す。(S1), (S2)のいずれの場合においても、PCR検査の誤り確率を、統計学的に考慮することが重要である。

1. 確率・統計学の基礎

1.1 条件付き確率

A, B を不規則現象での事象とし、 $P(B) > 0$ と仮定する。この時、事象 B が生じたという条件のもとでの、事象 A が生じる確率を $P(A|B)$ と記す。この時、 $P(A|B)$ （事象 B が起こったという条件のもとでの事象 A の起こる確率）は

$$P_B(A) \equiv P(A|B) \equiv \frac{P(A \cap B)}{P(B)} = \frac{P(A, B)}{P(B)}$$

と定義する、あるいは

$$P(A \cap B) = P(A|B)P(B)$$

と定義する。また $P(A|B)$ は事象 B が与えられたもとでの A の条件付確率 (conditional probability of A given B) という。

条件付き確率の計算例

サイコロを1回投げたとき,

(a) 4以下の目が出る(事象A)確率を求めよ.

(b) 投げた結果が奇数の目である(事象B)ことを知ったもとで、4以下の目が出る(事象A)確率を求めよ.

ただし、1の目～6の目は等確率 $\frac{1}{6}$ で生じるものとする.

(解)

サイコロを1回投げたとき、見本空間は $\Omega = \{1\text{の目}, 2\text{の目}, \dots, 6\text{の目}\}$

$\equiv \{\omega_1, \dots, \omega_6\}$ となり、いま、「奇数の目ができる」という事象を B , 「4以下の目ができる」という事象を A とすると、 $\omega_i \cap \omega_j = \emptyset$ ($i \neq j$) であるので

(a)

$$P(A) = P(\{\omega_1, \dots, \omega_4\}) = P(\omega_1) + P(\omega_2) + P(\omega_3) + P(\omega_4) = \frac{4}{6} = \frac{2}{3}$$

は明らか、また

$$P(B) = P(\{\omega_1, \omega_3, \omega_5\}) = P(\omega_1) + P(\omega_3) + \dots + P(\omega_5) = \frac{3}{6} = \frac{1}{2}$$

(b)

$$P(A \cap B) = P(\{\omega_1, \omega_3\}) = P(\omega_1) + P(\omega_3) = \frac{2}{6} = \frac{1}{3}$$

であるので、

$$P(A|B) = \frac{P(A \cap B)}{P(B)} = \frac{\frac{1}{3}}{\frac{1}{2}} = \frac{2}{3}$$

以上の条件付き確率の定義から、次の定理を示すことができる。

1.2 ベイズの定理

ベイズの定理 (Bayes' Theorem (Rule))

いま、事象 A_1, A_2, \dots, A_n が互いに排反、かつそれらの合併(和)集合が見本空間 Ω となるとき、すなわち、事象 A_1, A_2, \dots, A_n は見本空間 Ω の分割であるとき、事象 B のもとでの条件付確率について

$$P(A_k|B) = \frac{P(A_k \cap B)}{P(B)} = \frac{P(A_k)P(B|A_k)}{P(B \cap \Omega)} = \frac{P(A_k)P(B|A_k)}{\sum_{j=1}^n P(A_j)P(B|A_j)}$$

が成立する。

上記の定理は、与えられた条件(原因)となる事象 B のもとでの、事象 A_k が起こる(結果)の確率が、条件(原因)と結果が逆転した確率 $P(B|A_j)$ の計算により求められることを示しており、原因確率の定理(a theorem of probability of cause)とも呼ばれる。

2. コロナ感染とPCR検査

ある地区(または、あるグループ)での、病気 B の患者の割合は、 $\beta = 1\%$ といわれている。

病気の検査を行うと、病気 B であるのに病気と判断されない事象 K_{NB} (偽陰性) が起こる確率は 0.3 (第 2 種の過誤; のんびり者の過誤; 1-感度) である。

逆に病気 B でないのに病気と判断する事象 K_B (偽陽性) が起こる確率は 0.01 (第 1 種の過誤; あわて者の過誤; 1-特異度) である。

R さんは、検査の結果 K_B と判断された。

R さんが、病気 B である、確率を求めよ。

また検査の結果 K_{NB} と判断されたとき、R さんが、 NB である確率を求めよ。

(陽性の先駆確率: $\beta = 0.01$),

偽陰性者の確率: 0.3, 偽陽性者の確率: 0.01, と仮定する。

(解) $P(B) \equiv \beta = 0.01, P(K_{NB}|B) = 0.3, P(K_B|NB) = 0.01$ であるので,

$$\begin{aligned} & P(B|K_B) \\ &= \frac{P(K_B, B)}{P(K_B)} = \frac{P(K_B|B)P(B)}{P(K_B)} \\ &= \frac{P(K_B|B)P(B)}{P(K_B|B)P(B) + P(K_B|NB)P(NB)} \\ &= \frac{0.7 \times \beta}{0.7 \times \beta + 0.01 \times (1 - \beta)} \\ &= \frac{0.7\beta}{0.01 + 0.69\beta} \approx 0.414 \quad (\beta = 0.01) \end{aligned}$$

$$\begin{aligned} & P(NB|K_{NB}) \\ &= \frac{P(K_{NB}, NB)}{P(K_{NB})} = \frac{P(K_{NB}|NB)P(NB)}{P(K_{NB})} \\ &= \frac{P(K_{NB}|NB)P(NB)}{P(K_{NB}|NB)P(NB) + P(K_{NB}|B)P(B)} \\ &= \frac{0.99 \times (1 - \beta)}{0.99 \times (1 - \beta) + 0.3 \times \beta} \\ &= \frac{0.99 - 0.99\beta}{0.99 - 0.69\beta} \approx 0.997 \quad (\beta = 0.01) \end{aligned}$$

病気 B の患者の割合 ($\beta = P(B)$) は、 $\beta = 0.1\% = 10^{-3}$, ではなく、 $10^{-2}\% = 10^{-4}$ などの場合は、以下の表 1 となる。

表 1: 先駆確率: β と 真の確率

先駆確率 β	真陽性確率 $P(B K_B)$	真陰性確率 $P(NB K_{NB})$
0.2	0.9459	0.9296
0.1	0.8861	0.9674
0.01	0.4142	0.9969
0.001	0.0655	0.9997
0.0001	0.0070	1.0000

3. PCR 検査によるコロナ感染者率の推定

日本全国で、ランダムサンプリング(無作為抽出)により、抗体検査、PCR検査が行われる予定である。しかし品質管理のために、不良品の比率(p)の推定検査のように、検査における、良品、不良品の決定に誤りがなければ、サンプルサイズ、 n に対して、不良品数が $X=x$ であれば、最尤推定法では、 $X \sim B(n, p)$ であり、 X は 2 項分布:

$$P(X = x) = {}_n C_x p^x (1 - p)^{n-x}$$

に従い、

$$\arg \max_p \ln[{}_n C_x p^x (1 - p)^{n-x}] = \frac{x}{n}$$

となり、最尤推定値 \hat{p} は

$$\hat{p} = \frac{x}{n}$$

となる。次に、検査結果に誤りがある場合の、比率の推定問題について考察する。

実際には、検査対象者の感染率を p_o とするが、検査での誤り確率を考慮すると検査結果で陽性となる確率は

$$\begin{aligned} p_K &\equiv p_o(1 - e_{NB}) + (1 - p_o)e_B = (1 - e_{NB} - e_B)p_o + e_B \\ &\equiv ap_o + e_B; \quad a \equiv (1 - e_{NB} - e_B) \end{aligned} \tag{1}$$

となる。ただし、 e_{NB} は、陽性者に対する偽陰性の起こる誤り確率、 e_B は、陰性者に対する偽陽性の起こる誤り確率とする。このとき、ランダムサンプリングにより n 人に対して、PCR 検査(あるいは抗体検査など)を行い、検査結果が陽性とになった人数を $X = x$ とする。このデータから、 p_o の最尤推定値 \hat{p}_o は

$$\hat{p}_o = \arg \max_{p_o} P(X = x; p_o)$$

あるいは、対数尤度関数を用いて。

$$\begin{aligned} \hat{p}_o &= \arg \max_{p_o} \ln P(X = x; p_o) \\ &= \arg \max_{p_o} \ln[{}_n C_x p_K^x (1 - p_K)^{n-x}]; \quad (p_K \equiv p_o(1 - e_{NB}) + (1 - p_o)e_B = ap_o + e_B) \\ &= \frac{\frac{x}{n} - e_B}{1 - e_{NB} - e_B} \end{aligned}$$

となる事を以下に示す。(1)式より

$$\begin{aligned} &\frac{d}{dp_o} \ln[{}_n C_x p_K^x (1 - p_K)^{n-x}] \\ &= x \frac{a}{ap_o + e_B} + (n - x) \frac{-a}{1 - p_o - e_B} = 0 \end{aligned}$$

したがって、

$$x(1 - ap_o - e_B) - (n - x)(ap_o + e_B) = 0$$

すなわち、

$$x - nap_o + ne_B = 0$$

より

$$\begin{aligned} \hat{p}_o &= \frac{x - ne_B}{n(1 - e_{NB} - e_B)} \\ &= \frac{\frac{x}{n} - e_B}{1 - e_{NB} - e_B} \\ &= \frac{\text{検査陽性率} - \text{偽陽性率}}{\text{感度} - \text{偽陽性率}} \end{aligned} \tag{2}$$

したがって、上記の感染率推定値 \hat{p}_o は、偽陽性率 (=1-特異度)、感度、の推定値がしっかりと、推定できなければ、検査での陽性率 $\frac{x}{n}$ は、ほとんど意味をもたないことになり、検査対象者群の感染率の推定精度、あるいは推定精度の信頼区間も求めることができない。

すなわち、(2) 式より、PCR 検査の感度 (sensitivity)，特異度 (specificity) の正確な値を知ることが、感染率の推定のために、最も重要なとなる。