

**COVID-19で全数検査した場合と
事前診断で抽出検査した場合は
どう違うのか**

COVID-19による罹病判定

前提:

COVID-19に感染している割合: 0.002

病気にかかっている人が 検診を受けると、8割の確率で陽性と判定される。

病気にかかっていない人が検診を受けると、9割の確率で陰性と判定される。

10000人の集団を考える

- ・ 感染者数 20人: **入院する必要のある人数**
- ・ 非感染者数 9980人

(1) 10000人が無差別に検診を受ける場合

- ・ 感染者で 陽性と判定される $20 * 0.8 = 16$ 人: **正常判定で入院させられる人数**
- ・ 非感染者で陰性と判定される $9980 * 0.9 = 8982$ 人: 正、陰性判定
- ・ 感染者で 陰性と偽判定される $20 - 16 = 4$ 人: 誤、**野放しになっている感染者数**
- ・ 非感染者で陽性と判定される $9980 - 8982 = 998$ 人: 誤、**無駄に使われている病床**

結果: 陽性と判定された人のうち、正しく判定された人はたったの1.6%

20人しか入院の必要がないのに、998床のベッドが無駄遣いされる

感染しているのに野放しにされる人は4人

COVID-19による罹病判定

前提:

COVID-19に感染している割合: **0.002**

病気にかかっている人が 検診を受けると、 **$1 - 0.002$** の確率で陽性と判定される。

病気にかかっていない人が検診を受けると、 **$1 - 0.002$** の確率で陰性と判定される。

10000人の集団を考える

- ・ 感染者数 20人: **入院する必要のある人数**
- ・ 非感染者数 9980人

(1') 10000人が無差別に検診をうける場合

- ・ 感染者で 陽性と判定される $20 * 0.998 = 20$ 人: **正常判定で入院させられる人数**
- ・ 非感染者で陰性と判定される $9980 * 0.998 = 9960$ 人: 正、陰性判定
- ・ 感染者で 陰性と偽判定される $20 - 20 = 0$ 人: 誤、**野放しになっている感染者数**
- ・ 非感染者で陽性と判定される $9980 - 9960 = 20$ 人: 誤、**無駄に使われている病床**

結果: 陽性と判定された人のうち、正しく判定された人はやっと50%

検診の精度を0.998まで上げて、半数のベッドが無駄遣いされる

感染しているのに野放しにされる人はいない

COVID-19による罹病判定

(1) 10000人が無差別に検診を受ける場合

- ・感染者で 陽性と判定される $20 * 0.8 = 16$ 人: 正、正常判定で入院させられる人数
- ・非感染者で陰性と判定される $9980 * 0.9 = 8982$ 人: 正、陰性判定
- ・感染者で 陰性と偽判定される $20 - 16 = 4$ 人: 誤、野放しになっている感染者数
- ・非感染者で陽性と判定される $9980 - 8982 = 998$ 人: 誤、無駄に使われている病床

結果: 陽性と判定された人のうち、正しく判定された人はたったの1.6%

20人しか入院の必要がないのに、998床のベッドが無駄遣いされる

感染しているのに野放しにされる人は4人

(2) 他の症状や診断（事前診断）で、感染可能性が高い人を100人選択して検診をする場合

前提: 事前診断で選択した集団のうち、感染者の割合 10%

- ・選択した集団のうち感染者 10人
- ・選択した集団にとらえられなかった感染者 10人 野放しになっている感染者数

選択した集団のうち:

- ・感染者で 陽性と判定される $10 * 0.8 = 8$ 人: 正、正常判定で入院させられる人数
- ・非感染者で陰性と判定される $90 * 0.9 = 81$ 人: 正、陰性判定
- ・感染者で 陰性と偽判定される $10 - 8 = 2$ 人: 誤、野放しになっている感染者数
- ・非感染者で陽性と判定される $90 - 81 = 9$ 人: 誤、無駄に入院している健常者数

結果: 陽性と判定された人のうち、正しく判定された人は47%に増加

無駄遣いされるベッドは9床に減る

感染しているのに野放しにされる人は12人に増える

**事前診断で、感染可能性が高い人を
100人程度抽出する条件**

N 人から確率 θ で x 人を選ぶ場合の期待値

豊田秀樹著、基礎からのベイズ統計学、朝倉書店(2015)

ベルヌイ分布 (Bernoulli distribution)

2値の事象: 確率 θ で $x = 0$ 、 $1 - \theta$ で $x = 1$ が出る確率。

$f(x|\theta) = \theta^x(1 - \theta)^{1-x}$, $x = 0, 1$: 確率質量関数 (probability mass function), 確率関数

θ : 母数 (parameter): 確率関数に含まれる定数

$$E[X] = \theta, V[X] = \theta(1 - \theta)$$

事前診断 x 回で θ の割合で感染候補者を抽出 => 2項分布 (binomial distribution)

$$f(x|\theta) = {}_n C_x \theta^x (1 - \theta)^{1-x} = \frac{n!}{x!(n-x)!} \theta^x (1 - \theta)^{1-x}$$

$$\text{期待値 } E[X] = n\theta \quad \text{分散 } V[X] = n\theta(1 - \theta)$$

期待値 $E[X] = n\theta = 100$ を抽出するには、 $\theta \sim 0.01$ が必要

$\theta \sim 0.01$ となる事前診断の前提

全体の人数 N

感染者の割合 k_{inf}

感染者のうち、何らかの発症があつて事前診断で判定可能な割合 k_{on}

感染者のうち、潜伏期間で健常者と区別できない割合 $1 - k_{on}$

事前診断で判定可能な人を**感染候補者**と判定する確率 α

事前診断で健常者と区別できない人を**感染候補者**と判定する確率 $1 - \beta$

感染者のうち、何らかの発症があつて事前診断で**感染候補者**に抽出される割合 $k_{on}\alpha$

健常者と区別できない人の割合 $(1 - k_{on})k_{inf} + (1 - k_{inf})$

健常者と区別できない人のうち**感染候補者**に抽出される割合 $(1 - \beta)[(1 - k_{on})k_{inf} + (1 - k_{inf})]$

事前診断で抽出される全割合 $\theta = k_{on}\alpha + (1 - \beta)[(1 - k_{on})k_{inf} + (1 - k_{inf})]$

$k_{inf} = 0.002, k_{on} = 0.5, \alpha = 0.9, 1 - \beta = 0.01$

$\theta = 0.0018 + 0.01[0.5 * 0.002 + 0.998] \sim \mathbf{0.012}$ の割合で抽出されることになる

$N = 10000$

抽出される人数 $x = N\theta = 120$ 人

全感染者数 $Nk_{inf} = 20$ 人

感染者で何らかの発症があつて抽出される数 $Nk_{inf}k_{on}\alpha = 9$

感染者で健常者と区別できない数 $Nk_{inf}(1 - k_{on}) = 10$

感染者で健常者と区別できないが抽出される数 $10(1 - \beta) = 0.1$

感染候補者中に捕捉された感染者 9人

=> 11人は野放しにされる: 改善するには α を上げるしかないが、それならPCR検査をする必要がない

その他の条件での結果

COVID-19による罹病判定

(1) 10000人が無差別に検診を受ける場合

- ・感染者で 陽性と判定される $20 * 0.8 = 16$ 人: 正、正常判定で入院させられる人数
- ・非感染者で陰性と判定される $9980 * 0.9 = 8982$ 人: 正、陰性判定
- ・感染者で 陰性と偽判定される $20 - 16 = 4$ 人: 誤、野放しになっている感染者数
- ・非感染者で陽性と判定される $9980 - 8982 = 998$ 人: 誤、無駄に入院している健常者数

結果: 陽性と判定された人のうち、正しく判定された人はたったの1.6%

998床のベッドが無駄遣いされる

感染しているのに野放しにされる人は4人

(2) 他の症状や診断（事前診断）で、感染可能性が高い人を100人選択して検診をする場合

前提: 事前診断で選択した集団のうち、感染者の割合 15%

- ・選択した集団のうち感染者 15人
- ・選択した集団にとらえられなかった感染者 5人 野放しになっている感染者数

選択した集団のうち:

- ・感染者で 陽性と判定される $15 * 0.8 = 12$ 人: 正、正常判定で入院させられる人数
- ・非感染者で陰性と判定される $85 * 0.9 = 77$ 人: 正、陰性判定
- ・感染者で 陰性と偽判定される $15 - 12 = 3$ 人: 誤、野放しになっている感染者数
- ・非感染者で陽性と判定される $85 - 77 = 8$ 人: 誤、無駄に使われている病床

結果: 陽性と判定された人のうち、正しく判定された人は60%に増加

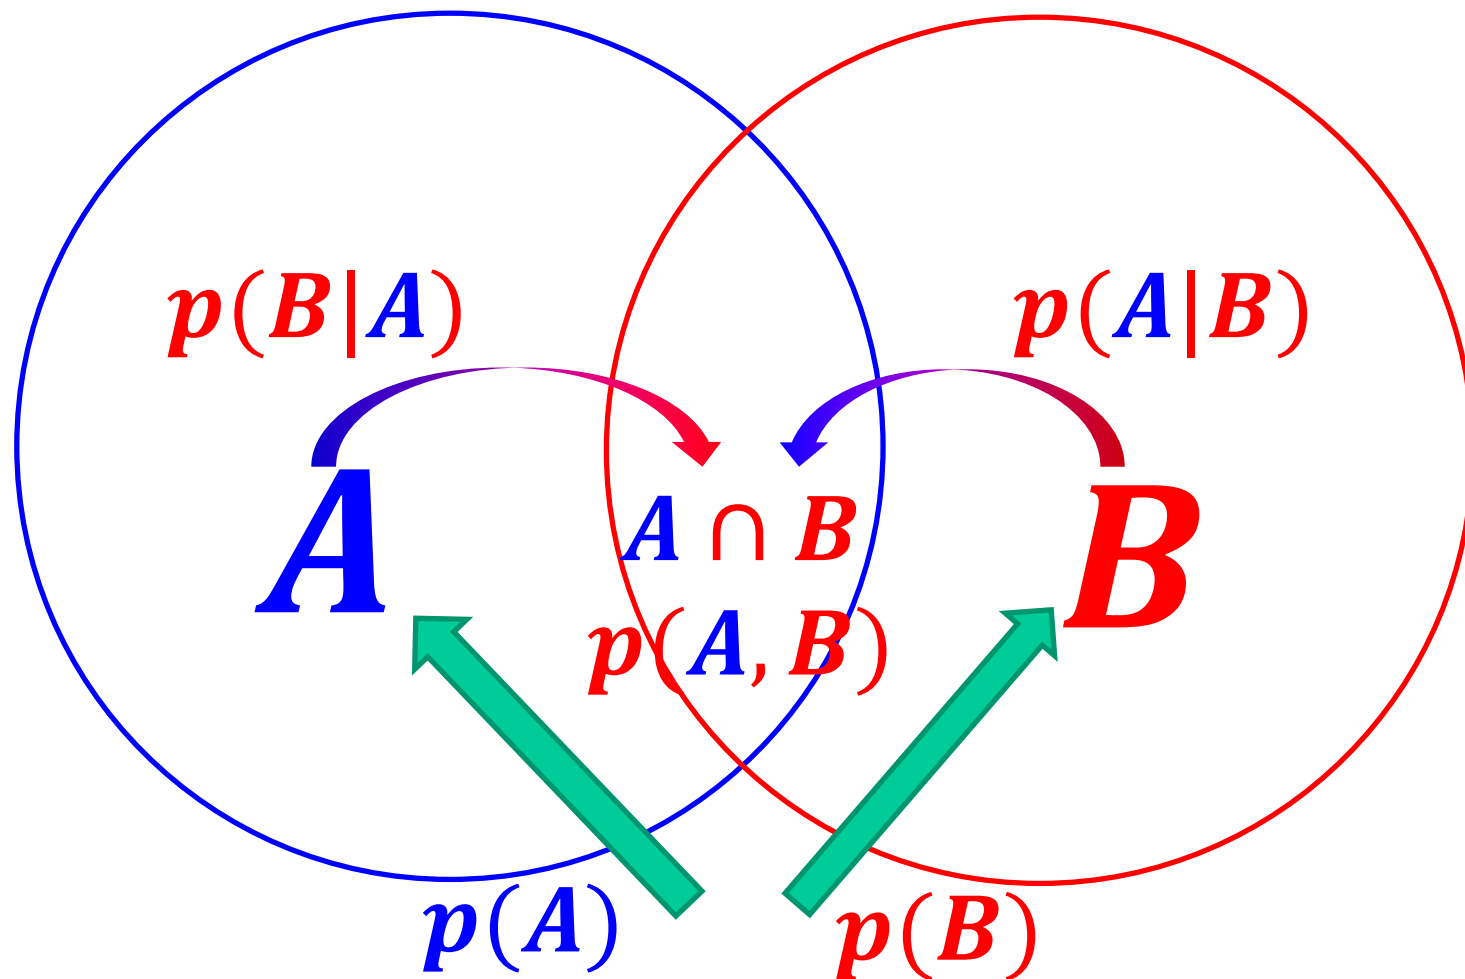
無駄遣いされるベッドは8床に減る

感染しているのに野放しにされる人は5人

ベイズの定理からの計算

確率に関するベイズの定理

$$p(A, B) = p(B|A)p(A) = p(A|B)p(B)$$



ベイズの定理: $p(A|B) = p(B|A)p(A)/p(B)$

事後確率

事前確率

確率に関するベイズの定理

豊田秀樹著、基礎からのベイズ統計学、朝倉書店(2015)

$$p(A|B) = \frac{p(B|A)p(A)}{p(B)}$$

A, B : 事象 (event)

$p(A)$: 事象Aが観察される確率

$p(A, B)$: 同時確率 (joint probability)。事象AとBが同時に観察される確率

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

$\sum_i p(A_i, B_j) = p(B_j)$: 周辺確率 (marginal probability)

$p(B|A)$: 条件付き確率 (conditional probability)。

事象Aが観察されたという条件の下で、Bが観察される確率

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

$$\sum_j p(B_j|A_i) = 1$$

乗法の定理 (multiplication theorem of probability): $p(A_i, B_j) = p(B_j|A_i) p(A_i) = p(A_i|A_j) p(B_j)$

全確率の公式 (law of total probability): $p(B_j) = \sum_i p(A_i, B_j)p(A_i)$

ベイズの定理 (Bayes' theorem): $p(A_i|B_j) = \frac{p(B_j|A_i)p(A_i)}{p(B_j)} = \frac{p(B_j|A_i)p(A_i)}{\sum_i p(B_j|A_i)p(A_i)}$

$p(A_i)$: 事前確率 (prior probability)

$p(A_i|B_j)$: 事後確率 (posterior probability)

$p(A_i|B_j) = p(B_j|A_i)$: AとBは互いに独立である (independent)

$$\Rightarrow p(A_i, B_j) = p(A_i)p(B_j)$$

ベイズの定理の応用: COVID-19による罹病判定

豊田秀樹著、基礎からのベイズ統計学、朝倉書店(2015)

https://qiita.com/oki_mebarun/items/ee345ba45c7d3752b54c

2020/3/14 イタリア 感染者数 145,637人、死者 5,436人、人口 6000万人

COVID-19 (A) に感染する割合: 0.0024 (事前確率 $p(A)$)

病気Aにかかっている人が 検診Bを受けると、8割の確率で陽性になる。

病気Aにかかっていない人が検診Bを受けると、9割の確率で陰性になる。

検診Bによって陽性と判定された場合、その受信者が病気Aにかかっている確率 (事後確率) を求めよ。

条件付確率: 病気にかかっている人の判定確率

正常診断: $p(\text{陽性}|\text{病気}) = 0.8$, $p(\text{陰性}|\text{病気でない}) = 0.9$ **正常に判定する確率は8割以上だが...**

誤診 : $p(\text{陰性}|\text{病気}) = 0.2$, $p(\text{陽性}|\text{病気でない}) = 0.1$

$$\begin{aligned} \text{事後確率 } p(\text{病気}|\text{陽性}) &= p(A|B) = \frac{p(B|A)p(A)}{p(B)} = \frac{p(B|A)p(A)}{\sum_A p(B|A)p(A)} \\ &= \frac{p(\text{陽性}|\text{病気})p(\text{病気})}{p(\text{陽性}|\text{病気})p(\text{病気}) + p(\text{陽性}|\text{病気でない})p(\text{病気でない})} \end{aligned}$$

事前確率:

$$(1) p(\text{病気}) = 0.0024$$

$$\begin{aligned} p(\text{陽性}) &= p(\text{陽性}|\text{病気})p(\text{病気}) + p(\text{陽性}|\text{病気でない})p(\text{病気でない}) \\ &= 0.8 * 0.0024 + 0.1 * (1 - 0.0024) = 0.1017 \end{aligned}$$

$$\Rightarrow p(\text{病気}|\text{陽性}) = 0.018 \quad \text{陽性と判断されても、98\%は病気ではない}$$

ベイズの定理の応用: COVID-19による罹病判定

Qiitaベイズの定理で理解する新型コロナウイルスへのPCR検査の検査対象を絞る意義

https://qiita.com/oki_mebarun/items/ee345ba45c7d3752b54c

感度: $RC = p(\text{陽性}|\text{病気})$

特異度: $SP = p(\text{陰性}|\text{病気でない})$

適合率: $PC = p(\text{陽性}|\text{病気})$

正解率: $AC = p(\text{陽性}|\text{病気}) + p(\text{陰性}|\text{病気でない})$

偽陽性率: $FP = p(\text{陽性}|\text{病気でない}) = 1 - p(\text{陰性}|\text{病気でない})$

偽陰性率: $FN = p(\text{陰性}|\text{病気}) = 1 - p(\text{陽性}|\text{病気})$

前提条件

再現率 (= 感度) RC は 0.7

特異度 SP は 0.95

事前確率 $p(\text{病気})$ および $p(\text{病気でない})$ をパラメータとする。

covid19.py


検査陽性の適合率 $PC(T)$: 事前確率 $P(\text{罹患}=T)$ が低いとかなり悪化し、

$P(\text{罹患}=T)=0.1$ のとき、検査陽性でも罹患している確率は60%程度。

検査陽性の適合率 $PC(F)$: 事前確率 $P(\text{罹患}=T)$ が高いとかなり悪化し、

$P(\text{罹患}=T)=0.9$ のとき、検査陰性でも罹患していない確率は25%程度。

正解率 (AC) は、特異度と感度を線形補間する形状であり、両方とも値が高いに越したことはない。



ベイズの定理の応用: COVID-19による罹病判定

Qiitaベイズの定理で理解する新型コロナウイルスへのPCR検査の検査対象を絞る意義

https://qiita.com/oki_mebarun/items/ee345ba45c7d3752b54c

※以下は造語

嘘陽性率: 検査陽性でも罹患していない確率。 $p(\text{病気でない}|\text{陽性})$

嘘陰性率: 検査陰性でも罹患している確率。 $p(\text{病気}|\text{陰性})$

⇔偽陽性率: $FP = p(\text{陽性}|\text{病気でない})$ 、偽陰性率: $FN = p(\text{陰性}|\text{病気})$

前提条件

再現率(=感度)RCは0.7

特異度SPは0.95

covid19.py

嘘陽性率は検査陽性の適合率 $PC(T)$ と、嘘陰性率は検査陰性の適合率 $PC(F)$ と逆の関係。

嘘陽性率: 事前確率 $P(\text{罹患}=T)$ が低いとかなり悪化し、

$P(\text{罹患}=T)=0.1$ のとき、検査陽性でも罹患していない確率は40%程度である。

嘘陰性率: 事前確率 $P(\text{罹患}=T)$ が高いとかなり悪化し、

$P(\text{罹患}=T)=0.9$ のとき、検査陰性でも罹患している確率は75%程度である。

