

データサイエンス 基礎

Fundamental Data Science

第9回 確率



講義の予定

- 第 1回 「ガイダンスと導入」
- 第 2回 「データの取得とオープンデータ, データサイエンスの倫理」
- 第 3回 「データの種類とデータの要約」
- 第 4回 「データの要約」
- 第 5回 「R によるデータの視覚化」
- 第 6回 「相関と回帰」
- 第 7回 「Excel による単回帰分析」
- 第 8回 「R による主成分分析・クラスター分析」
- 第 9回 「確率」
- 第10回 「確率変数と確率分布」
- 第11回 「主要な確率分布」
- 第12回 「二変量確率分布」
- 第13回 「データ収集法」
- 第14回 「点推定と区間推定」
- 第15回 「区間推定」

記述統計

データ分析手法

推測統計

これからの講義では, まず
区間推定を理解するための
準備をしていきます



推測統計の例

✓ 推測統計

全体の傾向や特徴を収集した**一部のデータ**から**推測**すること

区間推定

一部の受験者の点数から受験者**全員**の平均点は
確率95% (信頼度95%)で**55点以上60点以下**
と推測!!

確率的に!!

推測統計では確率がキーワード!!

まずは
確率について
知っておかなきゃですね



私たちがナビゲートします!

今日の内容

- ▶ **確率**
- ▶ **条件付き確率**
- ▶ **ベイズの定理**



確率とは

✓ 確率

偶然起こる現象の、現象全てに対する割合。
起こりやすさを数値で表したもの。 (参照: Wikipedia)

「～の確率は0.5 (50%)」のように
表現 ※ 確率は0以上1以下の数値

身近な確率

サイコロを
1回投げたとき、
1の目が出る確率



ある野球選手
がヒットを
打つ確率



降水確率

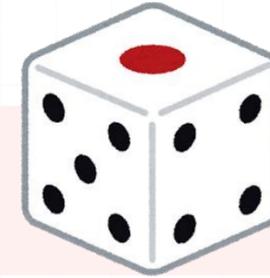


確率は現象の「妥当性」や
「信用度」を数値で与える

「意思決定」を行うための道具

確率の計算

Q サイコロを1回投げたとき, 1の目が出る確率は?



A $\frac{1}{6}$ 1の目が出る場合の数: 1通り
1の目が出る,...,6の目が出る: 6通り

では, 確率の計算方法から話していきますよ

確率の用語で言うと...

$$\frac{\text{事象の起こりうる場合の数}}{\text{起こりうるすべての場合の数}}$$



試行, 標本空間

✓ 試行

偶然性を伴う実験や調査

例 「サイコロを1回投げる」

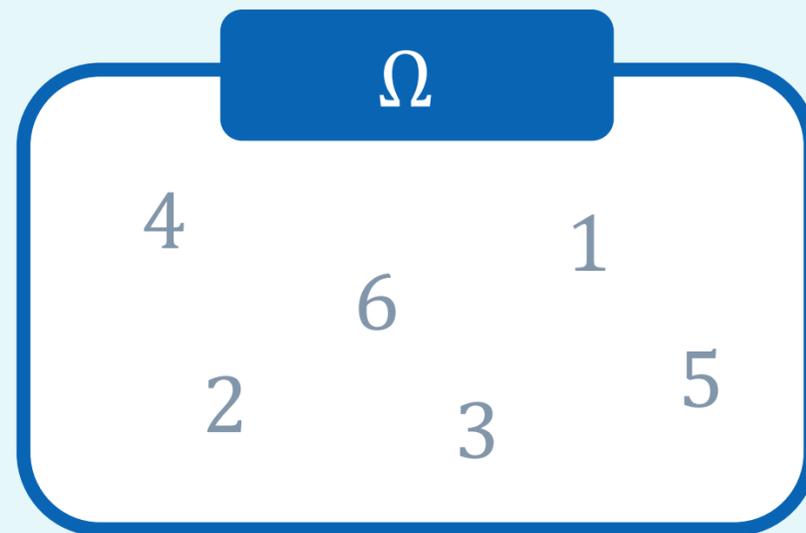


✓ 標本空間 (全事象) Ω

試行の際に起こりうる結果の全体

例 サイコロの出る目全体

イメージ図



数式でかくと

$$\Omega = \{1, 2, 3, 4, 5, 6\}$$

※ **数字**だけでも**言葉**でかいても OK

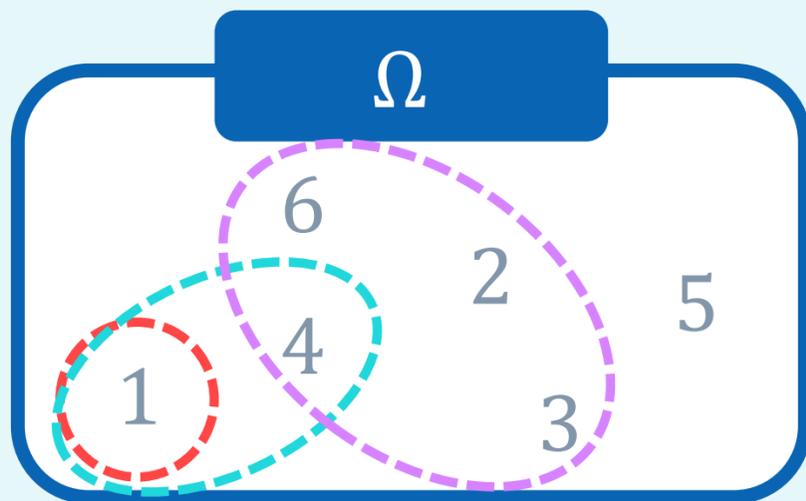
$$\Omega = \{1の目が出る, 2の目が出る, 3の目が出る, 4の目が出る, 5の目が出る, 6の目が出る\}$$

事象, 場合の数

✓ 事象

試行の結果としてありうる事柄で, Ω の一部分

例



1の目が出る事象: $A = \{1\}$

1または4が出る事象: $B = \{1, 4\}$

1と5以外が出る事象: $C = \{2, 3, 4, 6\}$

$\Omega = \{1, 2, 3, 4, 5, 6\}$

※ Ω を言葉でかいたら事象も言葉でかく: $A = \{1\text{の目が出る}\}$

✓ 場合の数

事象が起こりうるすべての場合を重複なく数え上げた数.

事象 A が起こりうる場合の数を $\#(A)$ とかく

例

$$\#(A) = 1$$

$$\#(B) = 2$$

$$\#(C) = 4$$

$$\#(\Omega) = 6$$

(古典的) 確率

- ✓ 事象 A が起こりうる確率 (Probability):

$$P(A) = \frac{\text{事象 } A \text{ の起こりうる場合の数}}{\text{起こりうるすべての場合の数}} = \frac{\#(A)}{\#(\Omega)}$$

古典的**確率**ともいう

- 例 サイコロを1回投げたとき、1の目が出る確率

標本空間: $\Omega = \{1, 2, 3, 4, 5, 6\}$

事象: $A = \{1\}$

➡ $P(A) = 1/6$



- 例 コインを1回投げたとき、表が出る確率

標本空間: $\Omega = \{\text{表}, \text{裏}\}$

事象: $A = \{\text{表}\}$

➡ $P(A) = 1/2$



これは
小・中学校などで学んだ
確率ではないでしょうか?



確率の使用例

あるテレビショッピング



このサプリメントはダイエットに抜群に効きます。
実際に**5人中5人**
全員の体重が減少しています。

本当に効くなら買いたい

Aさん

サプリの効果と関係なく、
たまたま全員の体重が
減っただけかも？



サプリの効果関係なしに偶然
5人全員の体重が減少する確率 < 0.01 (1%) なら買う
 > 0.01 (1%) なら買わない

確率の使用例

5人全員の体重が偶然減少する確率を計算

起こりうるすべての場合の数

1人目 2人目 3人目 4人目 5人目

$$2 \times 2 \times 2 \times 2 \times 2 = 32 \text{通り}$$

減るか減らないの2通りを5人分

5人全員の体重が減る場合の数 = 1通り

$$\text{確率} = 1/32 = 0.03125 = \text{約}3\%$$

買わない!!

1%より大きい ⇒ 偶然の確率が大きい (効果があるとはいえない)

確率の使用例

あるテレビショッピング



このサプリメントはダイエットに抜群に効きます。
実際に**10人中10人全員**の体重が減少しています。

10人中10人の体重が偶然減少する確率

$$= 1/1024 = \text{約}0.00097 = \text{ほぼ}0\%$$



1%を境目で判断すると買う!!

確率を計算する前に情報を正しく把握しよう!!

(古典的) 確率の注意点

例 いびつなサイコロを1回投げたとき, 1の目が出る確率



いびつなサイコロ:
1,6 が出る本当の割合: $1/6$ より**大きい**

標本空間: $\Omega = \{1, 2, 3, 4, 5, 6\}$ 事象: $A = \{1\}$

古典的確率:
いびつなサイコロでも,
 $P(A) = 1/6$ となる

計算結果と現実のギャップ!!

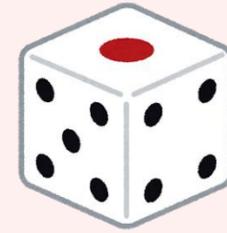
でも実際の割合は
 $1/6$ より**大きい**

(古典的) 確率ではそれぞれの事象が起こる確率が等しいことが前提!!

条件付き確率

条件付き確率

Q サイコロを1回投げた。
どの目が出たかは確認できていないとする。
このとき、3以下の目が出た確率は?



奇数が出ていたなら1,3,5の目だけ考えればいいですね。
3以下は1と3だけです

A $\frac{1}{2}$ (通常確率)

情報の追加

Q 投げるのを見ていた人が「**奇数が出ていた**」と教えてくれた。
このとき、3以下の目が出た確率は?

A $\frac{2}{3}$ (条件付き確率)

情報の追加で確率が変化!!



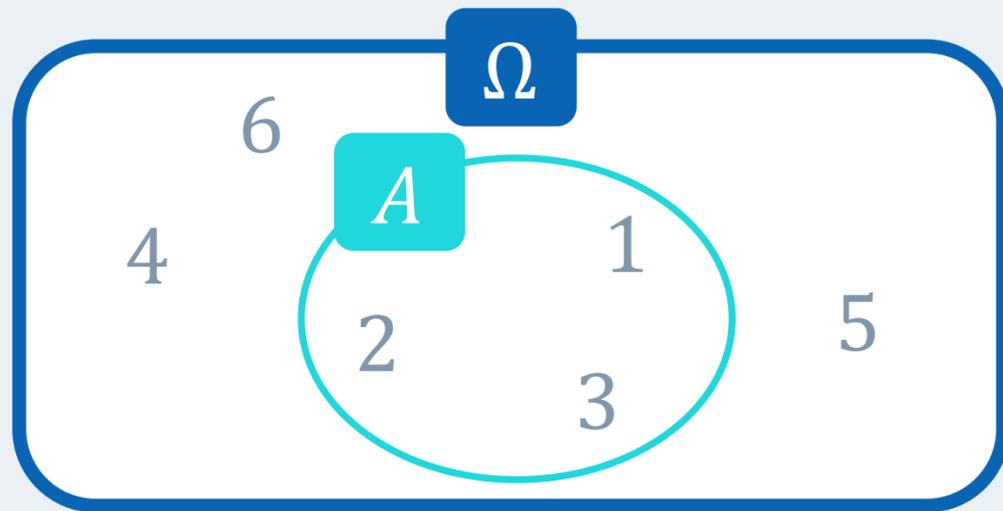
条件付き確率の仕組み

例 サイコロを1回投げる

標本空間: $\Omega = \{1, 2, 3, 4, 5, 6\}$

事象: $A = \{1, 2, 3\}$: 出目が3以下

情報なしの場合



条件付き確率を
図でイメージしてみましょう!



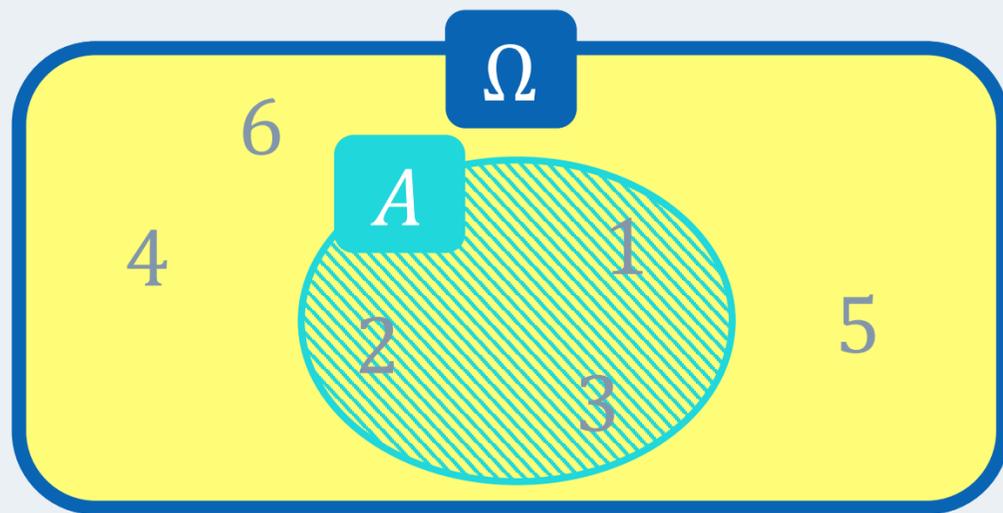
条件付き確率の仕組み

例 サイコロを1回投げる

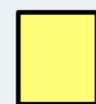
標本空間: $\Omega = \{1, 2, 3, 4, 5, 6\}$

事象: $A = \{1, 2, 3\}$: 出目が3以下

情報なしの場合



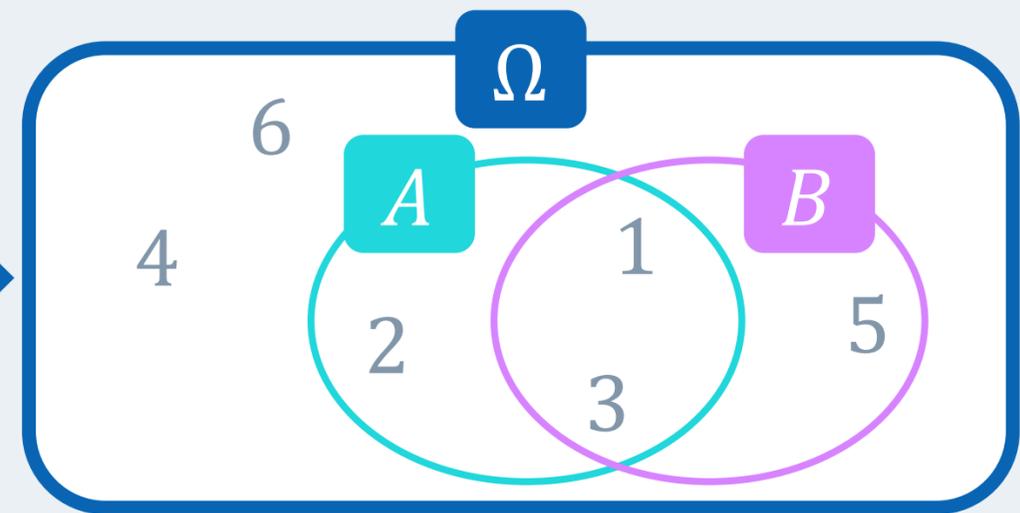
標本空間の中から確率を考える

 のうちの  の割合

情報の追加

情報ありの場合

$B = \{1, 3, 5\}$: 出目が奇数



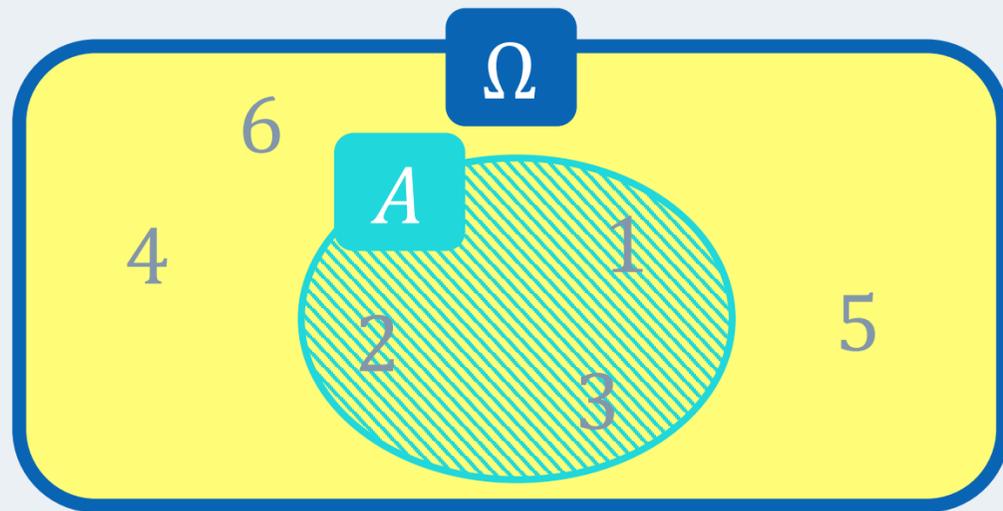
条件付き確率の仕組み

例 サイコロを1回投げる

標本空間: $\Omega = \{1, 2, 3, 4, 5, 6\}$

事象: $A = \{1, 2, 3\}$: 出目が3以下

情報なしの場合



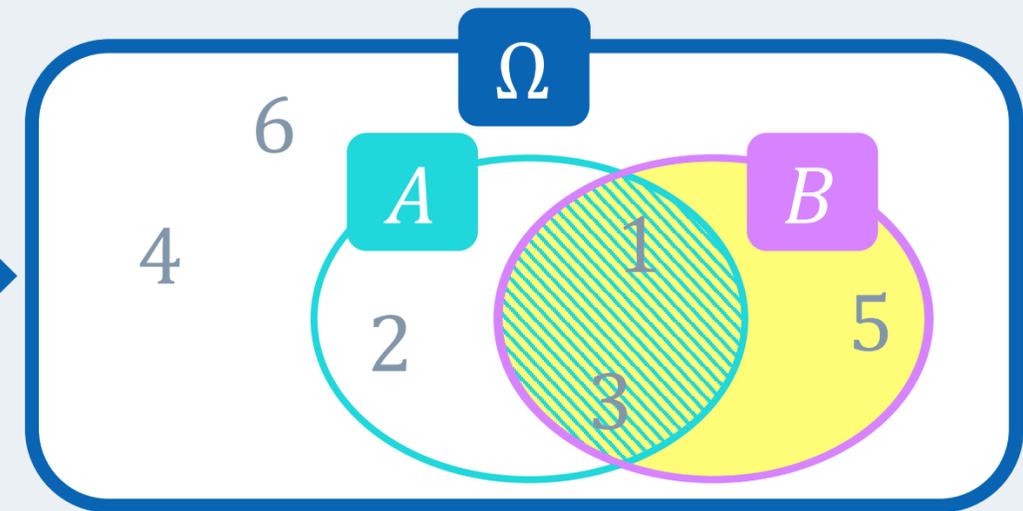
標本空間の中から確率を考える

 のうちの  の割合

情報の追加

情報ありの場合

$B = \{1, 3, 5\}$: 出目が奇数



追加情報の中から確率を考える

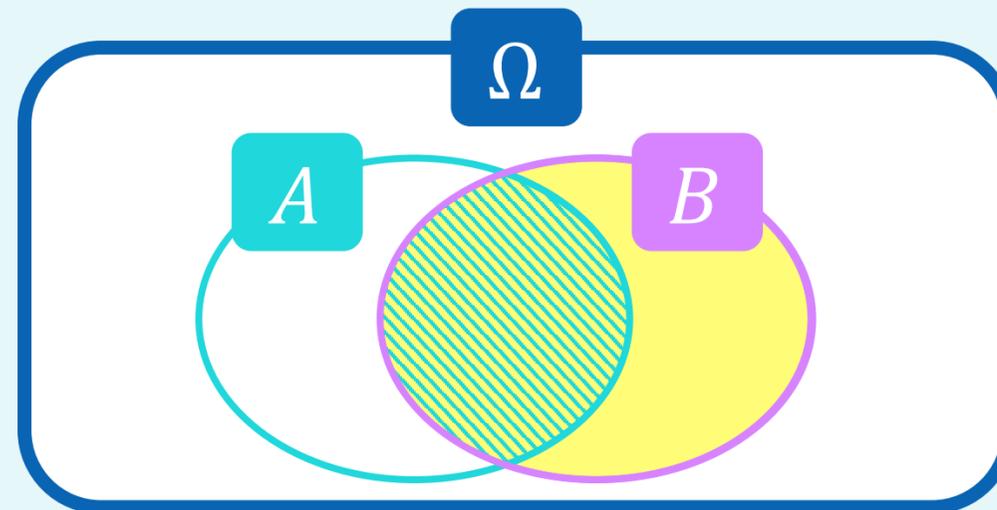
 のうちの  の割合

条件付き確率

- ✓ 2つの事象 A, B (ただし, $P(B) > 0$) に対して, 事象 B が起こったときに事象 A が起こる**条件付き確率**:

$A \cap B$: A と B が重なる部分

$$P(A|B) = \frac{\#(A \cap B)}{\#(B)}$$
$$= \frac{P(A \cap B)}{P(B)}$$



場合の数で表しても
確率で表しても, 全く同じ
計算結果になります



条件付き確率の例1

知り合い夫婦に子供が2人いるらしい。
このとき、2人とも男の子である確率は？

情報1 「少なくとも1人は男の子」

情報2 「年上は男の子」

Q 情報なし, 情報1あり, 情報2ありのときの
それぞれの確率は？

「双子である」という
可能性は考えなくて
いいですよ



条件付き確率の例1

情報なしの場合

事象 A : {2人とも男の子}

$$\#(A) = 1 \quad \longrightarrow \quad P(A) = \frac{1}{4}$$

情報1
「少なくとも1人
は男の子」の場合

事象 B : {少なくとも1人は男の子}

$$\#(B) = 3 \quad \#(A \cap B) = 1$$

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

情報2
「年上は男の子」
の場合

事象 C : {年上は男の子}

$$\#(C) = 2 \quad \#(A \cap C) = 1$$

$$\longrightarrow P(A|C) = \frac{1}{2}$$

全部で4通り

年上	年下
子1	子2
男	男
男	女
女	男
女	女

どんな情報かによって
確率が変化

条件付き確率の例2

Q Aさんはある病気にかかっているかどうかの検査を受け、陽性と言われた。

このとき、本当に病気にかかっている確率は？



病気に関する
直接的な情報

Aさんの地域では、**0.01%**の人がその病気にかかっている

受けた検査の精度は**99%**

病気の人を病気であると正しく判定する確率 (感度) : 99%

病気でない人を病気でないと正しく判定する確率 (特異度) : 99%

検査の精度も
確率の計算に取り入れましょう



条件付き確率の例2

陽性と判定されたとき病気にかかっている確率 $P(A|B)$

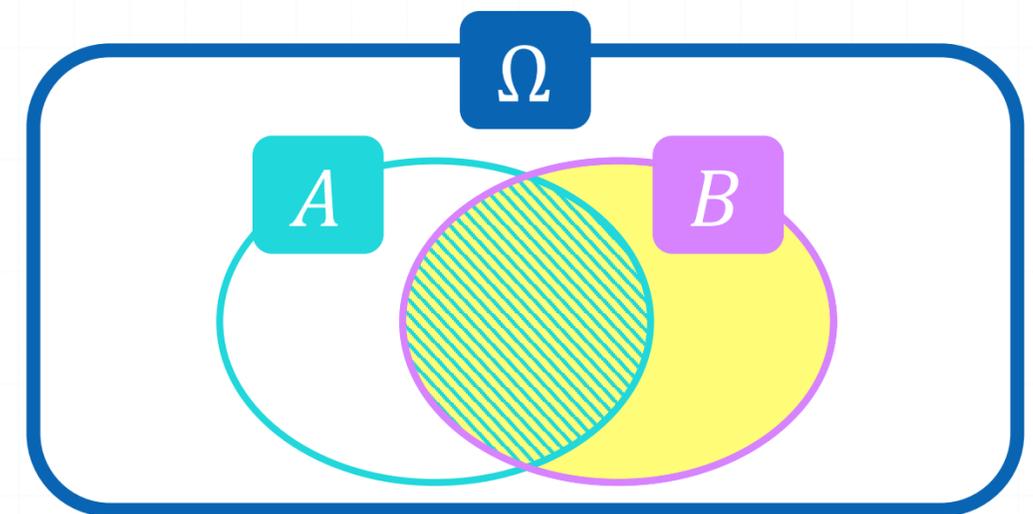
事象 A : {病気にかかっている}

事象 B : {陽性と判定される}

に対応

100万人のうちの割合

	陽性 B	陰性	合計
病気 A	99 (99%)	1 (1%)	100
病気でない	9,999 (1%)	989,901 (99%)	999,900
合計	10,098	989,902	1,000,000



$$P(A|B) = \frac{P(A \cap B)}{P(B)} = \frac{\#(A \cap B)}{\#(B)} = \frac{99}{10098} = 0.009804 = \text{約1\%}$$

ベイズの定理 (条件付き確率の応用)

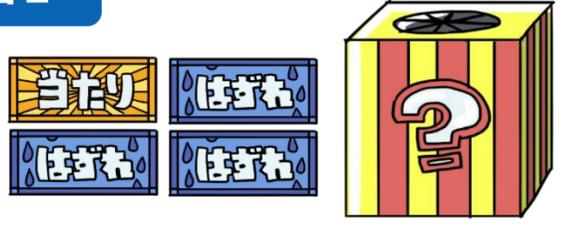
どっちの箱?

Q 外見は同じだけど、当たりの枚数が異なる
2つのくじ引きの箱がある。

お店の人にどちらか1つの箱を目の前に出され、
そこからくじを引くと当たりだった。

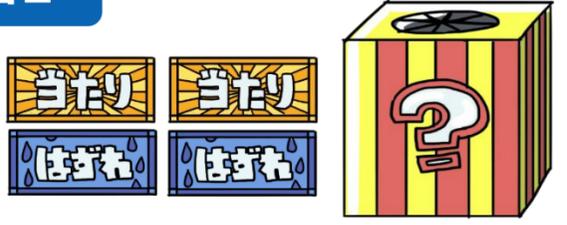
このとき、どっちの箱からくじを引いた確率が高いか?

箱1



4枚中1枚当たり

箱2



4枚中2枚当たり

結果

原因

でも当たりを
引いたんだから
当たりが多い
箱2の気がする…

箱1か箱2かの2択だから
確率は $1/2$??
(通常確率)



結果の情報を利用したい!!

ベイズの定理

✓ ベイズの定理

$$P(B|A) = P(B) \times \frac{P(A|B)}{P(A)}$$

原因 B が起きたもとので 結果 A が起きた確率

結果 A が起きたもとので 原因 B が起きた確率

結果 をもとに **その原因** の確率 (逆の確率) を計算できる!!

事象 A : **結果**, 事象 B : **その原因** としてみる!!

例 A : {当たりを引く}, B : {箱1からくじを引く}

どっちの箱？

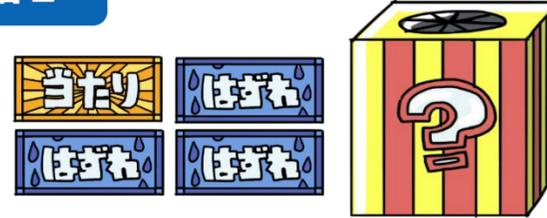
結果

引いたら
当たりだった

原因

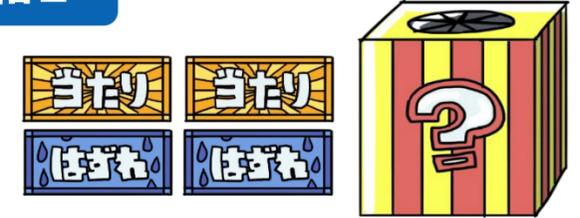
箱1から
くじを引いた

箱1



4枚中1枚当たり

箱2



4枚中2枚当たり

当たりだったときに箱1からくじを引いた確率

事象 (結果) A : {当たりを引く}

事象 (原因) B : {箱1からくじを引く}

箱1からくじを引く確率: $P(B) = \frac{1}{2}$

情報がないから等確率としておく

箱1から当たりを引く確率: $P(A|B) = \frac{1}{4}$

2つの箱から当たりを引く確率: $P(A) = \frac{3}{8}$

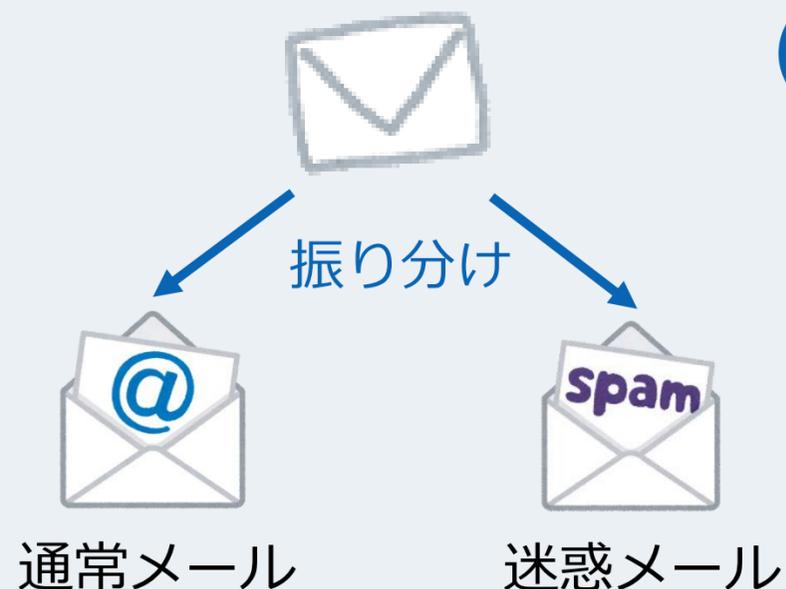
$$P(B|A) = P(B) \times \frac{P(A|B)}{P(A)}$$

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

箱2からくじを引いた確率のほうが大きい

ベイズの定理の実用例

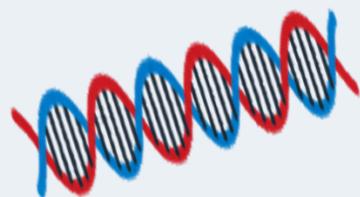
迷惑メールの自動振り分け機能



例

「完全無料」を含む メールが
迷惑メールである 確率

DNA 親子鑑定



例

子の遺伝子が〇〇 のとき、
自分が父親である 確率

ベイズの定理は
実際に身近なところに
使われているんです



今日のまとめ

▶ 確率

統計学では**確率**がキーワード!!
確率を求めることで**意思決定**につながる

▶ 条件付き確率

情報の追加で確率が変わる!!

▶ ベイズの定理

結果からその**原因**の確率がわかる!!

確率は統計学の中でも
大事なものでしたね

