

# 統計（医療統計）

## 前期・第3回 確率変数と確率分布（1）

授業担当: 徳永伸一


東京医科歯科大学教養部 数学講座

### 前回（第2回）の授業の概要：

- 第1回（教科書第9章「順列・組合せと確率」ほぼ全部）の復習.
- ベイズの定理に関する補足.
- 教科書第10章「記述統計」最後まで.

## Overview

- 確率(9章) ……第1回授業
- 記述統計(10章) ……第2回授業
  - 表やグラフで表す
  - 代表値(平均など)や散布度(分散など)を求める



確率モデル(11章 確率変数と確率分布)

- 推測統計(13章～)
  - 推定(点推定、区間推定)
  - 仮説検定

[復習] ベイズの定理 Bayes' Theorem

事象  $A_1, A_2, \dots, A_r, B \in \Omega$  について

[仮定]①  $\bigcup_{1 \leq k \leq r} A_k = \Omega$  かつ

② 各  $A_k$  は互いに排反

であるとき,

[結論] 条件付確率  $P(A_1/B)$  に関して, 以下の公式が成立つ.

$$P(A_1 | B) = \frac{P(A_1)P(B | A_1)}{\sum_{k=1}^r P(A_k)P(B | A_k)}$$

## [復習] $r = 2$ の場合に関する補足

$r = 2$  のとき, 仮定の条件は  
「 $A_2$ は $A_1$ の余事象」  
と言っているのと同じ。よって

$A_1 = A, A_2 = \bar{A}$  として

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

と書ける(仮定は自動的に満たされるので一般に成り立つ式となる)


## [復習] 例題 (p.75) の解答と考察

$$\begin{aligned} P(A | B) &= (P(A)P(B | A)) / (P(A)P(B | A) + P(A^c)P(B | A^c)) \\ &= (0.01 \times 0.99) / (0.01 \times 0.99 + 0.99 \times 0.07) \\ &= 0.125 \dots (\text{答}) \end{aligned}$$

→意外と小さい?

### 考察のポイント

- 検診結果が陽性でも, 実際には病気Xでない確率の方がずっと高い.
- しかし1%→12.5%だから確率は10倍以上.
- 使い方, 結果の理解の仕方(患者への伝え方)が重要.



例題 (p.75) の結果についての考察

考察のポイント

- 検診結果が陽性でも, 実際には病気Xでない確率の方がずっと高い.
- しかし1%→12.5%だから確率は10倍以上.
- 使い方、結果の理解の仕方(患者への伝え方)が重要。

## 第9章の概要REPRISE

- I. 順列と組合せ
- II. 確率の基礎概念
  - 標本空間、事象
- III. 確率の定義と性質
  - 確率の公理
- IV. 条件付き確率と事象の独立性
  - 「事象の独立性」の定義
- V. ベイズの定理
  - 仮定と結論

では10章へ.

## 第10章 記述統計

- I. 統計データの種類
  
- II. 度数分布
  - 1. 階級と度数, 度数分布表
  - 2. 度数分布表の視覚化 (ヒストグラム)
  
- III. データの特性値
  - 1. 代表値 (平均・メディアン・モード)
  - 2. 散布度 (分散と標準偏差、**不偏分散**)

## [復習] I. 統計データの種類 & II. 度数分布

### I. 統計データの種類

- 定性的データ (分類尺度)
  - 定量的データ (順序尺度・間隔尺度)
    - 離散的discreteデータ
    - 連続的continuousデータ
- ★「離散的」か「連続的」かで数学的な扱い方が異なる

### II. 度数分布

#### KEYWORDS

- 度数frequency, 度数分布表, 階級class、階級値
- スタージェスの公式
- 相対度数、累積度数、累積相対度数
- ヒストグラム

S. TOKUNAGA

11

## [復習] III. データの特性値 (2-3)

1-代表値 …分布の中心的な位置を示す.

[1] 平均mean

データ  $x_1, x_2, \dots, x_n$  に対し,

平均  $\bar{x} := (x_1 + x_2 + \dots + x_n) / n = (1/n) \sum x_k$   
と定義される。

度数分布表(階級数:m)が与えられているときは  
階級値  $x'_1, x'_2, \dots, x'_m$  と度数  $f_1, f_2, \dots, f_m$  を用いて

$\bar{x} := (1/n) \sum x'_k f_k$   
と計算(一種の近似計算)。

[2] メディアンmedian = 中央値(順位的に真ん中の値)

\* データが偶数個の場合は「真ん中の2つ」の平均.

[3] モードmode = 最頻値(度数が最大となる値or階級値)

12

### [復習] III. データの特性値 (4-5)

2-散布度…分布の広がり・ばらつきの度合いを示す.

[1]分散variance と 標準偏差standard deviation

データ  $x_1, x_2, \dots, x_n$  の平均  $\bar{x}$  に対し,

分散  $\sigma^2 := \{ \sum (x_k - \bar{x})^2 \} / n$   
階級値  $x'_1, x'_2, \dots, x'_m$  と度数  $f_1, f_2, \dots, f_m$  を用いると

$$\sigma^2 := (1/n) \sum (x'_k - \bar{x})^2 f_k$$

標準偏差 = 「 $\sigma^2$ の正の平方根」、すなわち

$$\sigma := \sqrt{(\sigma^2)}$$

S. TOKUNAGA

13

### [復習] III. データの特性値 (6)

[2]不偏分散unbiased variance

データ  $x_1, x_2, \dots, x_n$  の平均  $\bar{x}$  に対し,

$$\text{不偏分散 } U^2 := \{ \sum (x_k - \bar{x})^2 \} / (n-1)$$

★ $n$ ではなく $(n-1)$ で割る理由: 不偏性(→第13章II)

★バラツキの度合いを表す指標としては同等.

★ $n$ が十分大きいときには $n$ で割っても $(n-1)$ で割っても大差ない.

(たとえば $n=10000$ で有効数字3桁なら無視できる)

S. TOKUNAGA

14

## [復習] III. データの特性値 (7)

### **【重要】不偏分散についての補足(定義の不統一)**

★文献によっては

- ①「分散」を不偏分散の形で定義
- ②「分散」は同じだが「**標本分散**」を不偏分散の形で定義しているケースもあり、用語の使い方が統一されていない(以前使用していた教科書も②だった).

★上記①②のケースでは、標準偏差ないし「**標本標準偏差**」を不偏分散の正の平方根 $U = \sqrt{U^2}$ で定義.

## 第10章 記述統計の概要

### I. 統計データの種類

### II. 度数分布

1. 階級と度数, 度数分布表
2. 度数分布表の視覚化(ヒストグラム)

### III. データの特性値

1. 代表値(平均・メディアン・モード)
2. 散布度(分散と標準偏差, **不偏分散**)

次はいよいよ「11章 確率変数と確率分布」

## 第11章 確率変数と確率分布

### はじめに

確率変数は、確率・統計の学習において  
もっとも基本的かつ重要な概念  
であるが、きちんと理解するのは意外と難しい。  
(一度わかってしまえば簡単だが)

ということを頭に留めておきましょう。

## 第11章 確率変数と確率分布

- I. 確率変数と確率分布の定義
- II. 確率変数の特性値
  - 期待値（平均），分散など
- III. 確率変数の独立性
- IV. 代表的な確率分布
  - 2項分布，正規分布など
- V. 中心極限定理と正規近似
- VI. 標本分布

## I. 確率変数と確率分布の定義 (1)

### 1-確率変数の定義

[定義] 標本空間  $\Omega$  上の実数値関数  
(各根元事象に実数を対応させたもの)を  
確率変数 random variable という.

- とり得る値が離散的→離散型確率変数
- とり得る値が連続的→連続型確率変数

## I. 確率変数と確率分布の定義 (2)

### 教科書p.83例1

$\Omega$ : サイコロを振ったときの, 目の出方で定まる 事象  
全体の集合.

- 「サイコロを振って1の目が出る」は 事象.
- 「サイコロを振って  $i$  の目が出る」という 事象  $\omega_i$   
に整数  $i$  を対応させる 関数 を  $X(=X(\omega_i))$  とおくと,  
 $X$ は(離散型)確率変数 となる.
- 確率変数  $X$  に対し,
  - 「 $X=1$ 」「 $X \leq 4$ 」
  - 「 $X$ は偶数」などは事象.

# I. 確率変数と確率分布の定義 (3)

## 2-離散型確率変数の確率分布

[定義] 離散型確率変数  $X$  のとる値  $x$  と,  $X$  がその値をとる確率  $P(X=x)$  との対応関係を ( $X$  の) 確率分布という.


教科書 p.84 例3


$X$ : サイコロを1回振ったときの目の値.

$X$  の確率分布 (離散型):

|          |     |     |     |     |     |     |
|----------|-----|-----|-----|-----|-----|-----|
| k        | 1   | 2   | 3   | 4   | 5   | 6   |
| $P(X=k)$ | 1/6 | 1/6 | 1/6 | 1/6 | 1/6 | 1/6 |

★関数  $f(x)=P(X=x)$  を「 $X$  の確率分布」とよんで差し支えない。





## I. 確率変数と確率分布の定義 (4)

### 離散型確率変数の性質:

離散型確率変数  $X$  の取り得る値を  $x_1, x_2, \dots$  とする.

$f(x) = P(X=x)$  とおくと,  $f$  は確率の性質(公理)より

$$f(x_k) \geq 0 \quad (k=1,2,\dots) \quad \text{かつ} \quad \sum f(x_k) = 1$$

を満たすことがただちに導ける.

次に連続型確率変数へ

## I. 確率変数と確率分布の定義 (5)

### 3-連続型確率変数の確率分布

教科書p.83例2:

「ある短大の1年生から無作為に選んだ1名の身長」を $X$ cmとすると、 $X$ は連続型確率変数.

(とり得る値が連続的になっただけ)

では、

$X$ が連続型確率変数のとき、離散型の場合と同様に

「確率変数 $X$ のとり値 $x$ と、確率 $P(X=x)$ との対応関係」  
(もしくは関数  $f(x)=P(X=x)$  そのもの)

を(連続型)確率分布と呼んで良いだろうか？

S. TOKUNAGA

25

## I. 確率変数と確率分布の定義 (6)

そもそも

「連続型確率変数 $X$ と確率との対応関係」  
とは？

[注意]  $X$ が連続型確率変数のとき、  
(特殊な例を除き)ほとんどすべての値 $x$ に対して

$$P(X=x)=0である！$$

つまり

S. TOKUNAGA

26

## I. 確率変数と確率分布の定義 (7)

連続型確率分布は  
 $f(x)=P(X=x)$ のような関数で表すことはできない。

そこでこれに代わるものとして確率密度関数を導入。  
[定義]

$$f(x) \geq 0, \quad \int_{-\infty \leq x \leq \infty} f(x) dx = 1 \text{ であり,}$$

$$P(a \leq X \leq b) = \int_{a \leq x \leq b} f(x) dx$$

であるような関数  $f$  を、連続型確率変数  $X$  の  
確率密度関数という。

★すなわち連続型確率分布は、確率密度関数により表される。

S. TOKUNAGA

27

## 連続型確率分布の例

教科書p.85例4〈一様分布〉

$a, b$  を定数とすると、密度関数

$$\begin{aligned} f(x) &= P(X=x) = 1/(b-a) & (a \leq x \leq b) \\ f(x) &= P(X=x) = 0 & (x < a \text{ または } x > b) \end{aligned}$$

であらわされる確率分布を一様分布という。

- このとき  $X$  は一様確率変数または一様乱数
- EXCEL課題で用いるRAND関数は  $a=0, b=1$  とした一様乱数。

S. TOKUNAGA

28

## I. 確率変数と確率分布の定義 (8)

### [注意]

$$F(x) = P(X \leq x)$$

をXの累積分布関数という.

- 図11-1(b), 11-2(b)でイメージをつかんでください.
- 「累積」を省略して分布関数と呼ばれることも多く, 紛らわしいので気をつけましょう.
- Excelの関数「BINOMDIST」で4つ目の引数を「TRUE」にした場合がこれに相当  
(→Excel実習の際に確認を)

## II. 確率変数の特性値 (1)

### 1-期待値と分散・標準偏差の定義

確率変数Xの平均 (=期待値 expectation)  $E(X)$

を次式で定義:

$$E(X) := \sum x_k P(X=x_k) \quad (Xが離散型)$$

$$E(X) := \int x f(x) dx \quad (Xが連続型)$$

(ただし  $f(x)$  はXの確率密度関数)

Xの値を繰り返し取り出したとき, それらの平均値は回数を増やすほど  $E(X)$  に近づくと考えられる

## II. 確率変数の特性値 (2)

$\mu = E(X)$  とするとき,  
確率変数の分散 variance  $V(X)$  を

$$V(X) := E((X - \mu)^2)$$

で定義. すなわち,

▫  $V(X) = \sum (x_i - \mu)^2 P(X = x_i)$  ( $X$  が離散型)

▫  $V(X) = \int (x - \mu)^2 f(x) dx$  ( $X$  が連続型)

分散  $V(X)$  は,  $X$  のばらつき, 変動の指標となる.  
 $V(X) = \sigma^2$  と表すことも多い.

▪  $X$  の標準偏差 standard deviation:

$$\sigma = \sigma(X) := \sqrt{V(X)}$$

S. TOKUNAGA

31

## II. 確率変数の特性値 (3)

### 期待値 (平均) $E$ の性質:

$X$  を確率変数,

$a, b$  を定数 とするとき,

$$E(X + b) = E(X) + b$$

$$E(aX) = aE(X)$$

が成り立つ.

以上合わせて

$$E(aX + b) = aE(X) + b$$

より一般には, 定数  $a, b$  と関数  $f, g$  に対して

$$E(af(X) + bg(X)) = aE(f(X)) + bE(g(X))$$

(教科書には載っていません)

S. TOKUNAGA

32

## II. 確率変数の特性値 (4)

分散の性質: ( $X$ は確率変数,  $a, b$  は定数)

$$\begin{aligned}V(X+b) &= E((X+b-E(X+b))^2) \\ &= E((X+b-E(X)-b)^2) \\ &= E((X-E(X))^2) = V(X)\end{aligned}$$

$$\begin{aligned}V(aX) &= E((aX-E(aX))^2) \\ &= E((aX-aE(X))^2) \\ &= E(a^2(X-E(X))^2) = a^2V(X)\end{aligned}$$

以上合わせて  $V(aX+b) = a^2V(X)$

S. TOKUNAGA

33

## II. 確率変数の特性値 (5)

★以下は有名な公式ですが, 教科書には載っていません.

分散の公式: ( $\mu = E(X)$ とする)

$$V(X) = E(X^2) - E(X)^2$$

[証明]

$$\begin{aligned}V(X) &= E((X-\mu)^2) \\ &= E((X^2-2X\mu + \mu^2)) \\ &= E(X^2) - 2\mu E(X) + \mu^2 \quad \dots(*) \\ &= E(X^2) - E(X)^2\end{aligned}$$

注意: (\*)で公式

$$E(af(X)+bg(X)) = aE(f(X)) + bE(g(X))$$

を使っています.

S. TOKUNAGA

34

## II. 確率変数の特性値 (6)

### 教科書p.87例5

X:サイコロを1回振ったときの目の値 とする.

Xの確率分布(離散型):

|        |     |     |     |     |     |     |
|--------|-----|-----|-----|-----|-----|-----|
| k      | 1   | 2   | 3   | 4   | 5   | 6   |
| P(X=k) | 1/6 | 1/6 | 1/6 | 1/6 | 1/6 | 1/6 |

$$E(X) = \sum kP(X=k) = (1+2+\dots+6)/6 = 7/2 = 3.5$$

$$\begin{aligned} V(X) &= \sum (k-3.5)^2 P(X=k) \\ &= ((1-3.5)^2 + (2-3.5)^2 + \dots + (6-3.5)^2) / 6 \\ &= 35/12 = 2.916666\dots \end{aligned}$$

S. TOKUNAGA

35

### 教科書p.87問題4

Z:サイコロを2回振ったときの目の和の値 とする.  
このときZの確率分布(離散型)は:

|        |      |      |      |     |      |      |     |      |
|--------|------|------|------|-----|------|------|-----|------|
| k      | 2    | 3    | 4    | ... | 7    | 8    | ... | 12   |
| P(X=k) | 1/36 | 2/36 | 3/36 | ... | 6/36 | 5/36 | ... | 1/36 |

$$\begin{aligned} E(Z) &= \sum kP(Z=k) \\ &= 2 \cdot 1/36 + 3 \cdot 2/36 + \dots + 12/36 \\ &= 7 = 2 \times 3.5 \end{aligned}$$

$$\begin{aligned} V(Z) &= \sum (k-7)^2 P(Z=k) \\ &= \dots = 35/6 = 2 \times 35/12 \end{aligned}$$

S. TOKUNAGA

36

## 期待値の加法性（その1）

実は・・・

任意の確率変数 $X, Y$ に対し

$$E(X+Y) = E(X) + E(Y)$$

が成り立っている！（期待値の加法性）

先の例2だと、サイコロを2回振ったとき

$X$ : 1回目に出る目の値,  $Y$ : 2回目に出る目の値  
とすれば,

$$E(X) = E(Y) = 3.5$$

となり,  $Z = X + Y$ なので

$$E(Z) = 3.5 + 3.5 = 7$$

S. TOKUNAGA

37

## 期待値の加法性（その2）

$Z_n$ : サイコロを $n$ 回振ったときの目の和  
とすれば,

$$E(Z_n) = 3.5n$$

も成り立つ.

さらに一般に,

任意の定数 $a_1, a_2, \dots, a_n$ と

任意の確率変数 $X_1, X_2, \dots, X_n$ に対し

$$E(\sum a_k X_k) = \sum a_k E(X_k)$$

が成り立つ(期待値の線形性).

ところで、分散については？

S. TOKUNAGA

38

## 分散の加法性と確率変数の独立性

先のサイコロを2回振る例では、分散についても

$$V(Z) = 2 \times 35/12$$

が成り立っていた。

実は

$Z_n$ : サイコロを $n$ 回振ったときの目の和

とすれば、

$$V(Z_n) = n \times (35/12)$$

も成り立っている。

しかし、「分散の加法性」

$$V(X+Y) = V(X) + V(Y)$$

は（「期待値の加法性」と違って）いつでも成り立つわけではない！

成り立つための（十分）条件：

→ **確率変数の独立性**

（詳しい説明は次回）

## 第11章 確率変数と確率分布

I. 確率変数と確率分布の定義

II. 確率変数の特性値

□ 期待値（平均）、分散など

\*\*\* 今日はこの辺まで \*\*\*

III. 確率変数の独立性

IV. 代表的な確率分布

□ 2項分布、正規分布など

V. 中心極限定理と正規近似

VI. 標本分布