

# データサイエンス 基礎

*Fundamental Data Science*

## 第10回 確率変数と確率分布



# どのくじを引く?

くじ引き1

	A賞	B賞	C賞
賞金 (円)	1000	500	100
本数 (本)	1	3	6

くじ引き2

	A賞	B賞	C賞
賞金 (円)	1000	500	0
本数 (本)	2	2	6

くじ引き3

	A賞	B賞	C賞
賞金 (円)	1000	400	100
本数 (本)	2	1	7



どのくじを引こう??



今日の内容


- ▶ **確率変数**
- ▶ **確率分布**
- ▶ **確率変数の期待値, 分散**



# 確率変数と確率分布

# 用語の復習

サイコロを1回投げたとき, 1の目が出た



## ✓ 試行

偶然性を伴う実験や調査

## ✓ 事象

試行の結果としてありうる事柄で, 標本空間の一部分 {1の目が出る} とか {1}

## ✓ 標本空間 (全事象) $\Omega$

試行の際に起こりうる結果の全体

{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}  
とか {1,2,3,4,5,6}

事象や標本空間は  
言葉でも数字で  
かいても OK

# 確率変数

でも言葉より数字のほうが数学的に扱いやすい



もし言葉でかいたなら... 言葉でかいた事象を**数字表記に置き換える!!**

## ✓ 確率変数

事象を数字に置き換える変換器のこと

例

サイコロ

1の目が出る ⇒ **1** と変換  
2の目が出る ⇒ **2**

**数字をそのまま使用**

例

試合の勝敗

勝ち ⇒ **1** と変換  
負け ⇒ **-1**


**数字は区別のためだけに使用**

# 問い

2枚のコインを同時に投げる試行を考える.

このとき, 標本空間を  $\Omega = \{(\text{表}, \text{表}), (\text{表}, \text{裏}), (\text{裏}, \text{表}), (\text{裏}, \text{裏})\}$  とかく.

このとき, 3つの確率変数  $X, Y, Z$  を考えた



確率変数  $X$

	(表, 表)	(表, 裏)	(裏, 表)	(裏, 裏)
$X$	4	3	2	1

確率変数  $Y$

	(表, 表)	(表, 裏)	(裏, 表)	(裏, 裏)
$Y$	1	0	0	-1

確率変数  $Z$

	(表, 表)	(表, 裏)	(裏, 表)	(裏, 裏)
$Z$	2	1	1	0

**Q** いま, 試行の結果として **表が出る枚数**に興味の対象があるとき, どの確率変数が最も適切と考えられるか?

興味の対象をそのまま確率変数に反映させるとよい!!

# 確率変数に対する確率

例 2枚のコインを同時に投げる

確率変数  $X$  : 表がでる枚数

## 確率変数に対する確率

$$X = 0 \text{ である確率: } P(X = 0) = \frac{1}{4}$$

表が0枚の確率

$$X = 1 \text{ である確率: } P(X = 1) = \frac{2}{4}$$

表が1枚の確率

$$X = 2 \text{ である確率: } P(X = 2) = \frac{1}{4}$$

表が2枚の確率

確率変数 $X$	0	1	2	計
確率	1/4	2/4	1/4	1

この表のことを  
確率分布と呼びます



# 確率分布

一般的にかくと…

確率変数 $X$	$x_1$	$x_2$	...	$x_n$	計
$P(X = x_k)$	$p_1$	$p_2$	...	$p_n$	1

$$P(X = x_k) = p_k \quad (k = 1, \dots, n)$$

- ✓ 確率変数のとる値とその確率の対応関係を**確率分布**（または単に**分布**）といい、確率変数はその確率分布に従うという

※ 確率変数に対する全ての確率 = 確率分布 と思えば OK

**確率分布は現象を理解するための道具**

確率分布がわかれば、  
その現象が起こる  
確率的な仕組みがわかる!!

# 練習問題 (1)

Q A賞, B賞, C賞のどれかが当たる10本のくじがある.  
10本からくじを1本引くときの賞金額を  $X$  円とする.

	A賞	B賞	C賞
くじ引き 1			
賞金 (円)	1000	500	100
本数 (本)	1	3	6

このとき, 確率変数  $X$  が従う確率分布を求めよ.  
(つまり, 下の表を埋めよ)

確率変数 $X$	1000	500	100	計
確率				1



# 離散型と連続型 (もっと詳しく!!)

# 確率変数の分類

## ✓ 離散型確率変数

確率変数の値が**とびとびの値 (離散値)**をとるとき、  
離散型確率変数という

## ✓ 連続型確率変数

確率変数の値が**連続的な値**をとるとき、  
連続型確率変数という

確率変数は  
離散型と連続型に  
分類されるんですね




確率の扱い方が離散型, 連続型でかわる!!

# 離散型確率変数の例

ここまでで扱った確率変数はすべて離散型!!

サイコロを投げて出る目の数

確率変数  $W$ : 1,2,3,4,5,6



とびとびの値

試合の勝ち, 負け

確率変数  $X$ : 1, -1



くじを引いたときの賞金

確率変数  $Y$ : 1000, 500, 100



1年間で起こる交通事故の件数

確率変数  $Z$ : 0, 1, 2, 3, ...



# 離散型分布

## ✓ 離散型分布

離散型確率変数  $X$  が従う分布を離散型分布という。

$X$	$x_1$	$x_2$	...	計
$P(X = x_k)$	$p_1$	$p_2$	...	1

$$P(X = x_k) = p_k \quad (k = 1, 2, \dots)$$


このとき,  $P(X = x_k)$  を  $X$  の**確率関数**といい,  $f_X(x_k)$  または  $f_X$  と表す。

! 確率関数  $f_X$  は**確率変数1つ1つの値の確率**そのもの

!  $f_X$  をすべて足すと 1:  $f_X(x_1) + f_X(x_2) + \dots = 1$

# 確率関数

例 確率関数  $f_X(x_k) = P(X = x_k)$  のグラフ



確率変数が離散型なので  
横軸の値がとびとびに  
なっているのがわかりますね




縦軸の値が確率  $P(X = x_k)$  を表す

# 確率関数の例


## サイコロを投げて出る目の数

確率変数  $W$ : 1, 2, 3, 4, 5, 6




## 試合の勝ち, 負け

確率変数  $X$ : 1, -1



## 1年間で起こる交通事故の件数

確率変数  $Z$ : 0, 1, 2, 3, ...



# 連続型確率変数の例

自販機で買ったコーラに含まれる砂糖の量

確率変数  $Z: 0 \leq Z$



身長


確率変数  $Y: 0 \leq Y$



では  
連続型確率変数は  
どんなものでしょう

0から1の数直線上にランダムに針を落としたときの値

確率変数  $X: 0 \leq X \leq 1$




連続的な値



# 連続型確率変数の確率

0から1の数直線上に  
ランダムに針を落としたときの値

確率変数  $X: 0 \leq X \leq 1$



無限に多くの数から  
0.5という数だけを当てるのは  
無理だから確率が0なんです

Q  $X$  が0.5となる確率  $P(X = 0.5)$  は??

A  $P(X = 0.5) = 0$

0と1の間には無限に多くの数がある  
0.1, 0.01, 0.001, ...


連続型確率変数は  
1つの値をとる確率を計算しても0



# 連続型確率変数の確率

1つの値でなく、**幅をもたせた (範囲の) 確率**で考える

- ✓  $X$  が  $a$  以上  $b$  以下である確率  $P(a \leq X \leq b)$





$$P(a \leq X \leq b) = \frac{\text{区間の幅}}{\text{全体の区間の幅}} = \frac{b - a}{1 - 0} = b - a$$

例  $P(0 \leq X \leq 0.5) = 1/2$

連続型確率変数は幅をもたせた確率を扱う

# 連続型確率変数の確率

確率を視覚的に表す  
幅をもつ確率を**グラフの面積**で表す!!



$f_X$  は面積に合う  
ある曲線

**「 $f_X$  と  $X=a, b$  で囲まれた面積」 = 「幅の確率」**

# 連続型分布

## ✓ 連続型分布

連続型確率変数  $X$  のとる幅の確率が,  $P(a \leq X \leq b) = \int_a^b f_X(x) dx$

と表されるとき,  $f_X$  を  $X$  の**確率密度関数**といい,  
この  $X$  の分布を連続型分布という

$\int$  は積分記号  
積分 = 面積 と思えば OK

!  $P(a \leq X \leq b)$  は  $f_X$  と  $X = a, b$  で囲まれた**面積**で表す  
※ グラフの縦軸の値 ( $f_X$ の値) は確率ではないことに注意!!

! 1つの値をとる確率:  $P(X = a) = P(a \leq X \leq a) = \int_a^a f_X(x) dx = 0$

!  $f_X$  を与えれば  $P(a \leq X \leq b)$  が定まる. その逆も言える.


# 確率密度関数の例

0から0.5の数直線上にランダムに針を落としたときの位置

確率変数  $X: 0 \leq X \leq 0.5$

確率密度関数  $f_X(x) = 2$  ( $0 \leq x \leq 0.5$ ) とすると,

$$P(a \leq X \leq b) = \frac{b-a}{0.5} = \frac{\text{区間の幅}}{\text{全体の区間の幅}}$$



$$P(a \leq X \leq b) = \int_a^b f_X(x) dx$$


縦軸の値 ( $f_X$ の値)  
は確率ではない!!

離散型と連続型で  
グラフの見方が違うことに  
注意しましょう



# 離散型, 連続型のまとめ

## 離散型分布




確率関数:  $f_X(x_k)$

$f_X$  が**1つの値**の確率

$$f_X(x_k) = P(X = x_k)$$

## 連続型分布



確率密度関数:  $f_X(x)$

$f_X$  の**面積**が**幅**の確率

$$P(a \leq X \leq b) = \int_a^b f_X(x) dx$$

# 離散型確率変数の期待値 (平均), 分散


# データの平均値, 分散 (復習)

表. 5人の体重データ

人	1	2	3	4	5
体重 (kg)	60	52	44	74	60

✓ **平均値** データの重心を表す

$$\frac{60+52+44+74+60}{5} = 58$$



✓ **分散** 平均値周りのバラつき具合を表す

$$\frac{(60-58)^2 + (52-58)^2 + (44-58)^2 + (74-58)^2 + (60-58)^2}{5} = 99.2$$

似たようなものが確率変数でもある!!

# 離散型確率変数の期待値 (平均)

## くじ引き1

	A賞	B賞	C賞
賞金 (円)	1000	500	100
本数 (本)	1	3	6

確率変数  $X$ : 1回くじを引いたときの賞金額  $X$  円

確率変数 $X$	1000	500	100	計
確率	1/10	3/10	6/10	1

### ✓ 離散型確率変数 $X$ の期待値 (平均) (Expected value)

$$E[X] = (\text{確率変数 } X \text{ の値}) \times (\text{その確率}) + \dots$$

どれくらいの値を中心にして  $X$  の値が起こりやすいかを表す


くじ引き1

$$E[X] = 1000 \times \frac{1}{10} + 500 \times \frac{3}{10} + 100 \times \frac{6}{10} = 310$$

何度もくじを引くと  
310円周りに賞金が集まる

# 期待値の視覚的イメージ

確率変数 $X$	1000	500	100	計
確率	1/10	3/10	6/10	1



期待値について  
視覚的にグラフで  
イメージしておきましょう



!  $E[X]$  は確率分布の重心を表す

# 確率変数の期待値

## 練習問題 (1) のくじ

	A賞	B賞	C賞
賞金 (円)	1000	500	100
本数 (本)	1	3	6



期待値の計算には、  
例えばこんな利用方法が  
考えられます

400円で1回だけくじを引けます



お得なら引きたい

期待値 310 < 支払額 400  
だから損しそう ⇒ 引かないでおこう



# 離散型確率変数の分散

## ✓ 離散型確率変数 $X$ の分散

$$\begin{aligned} V[X] &= \{(\text{確率変数 } X \text{ の値}) - E[X]\}^2 \times (\text{その確率}) + \dots \\ &= E[(X - E[X])^2] \end{aligned}$$

期待値周りの ( $X$  の起こりやすさの) バラつき具合を表す

!  $V[X]$  が小さいほど期待値に近い  $X$  の値が起こりやすい

練習問題 (1) のくじ

$$\begin{aligned} V[X] &= (1000 - 310)^2 \times \frac{1}{10} + (500 - 310)^2 \times \frac{3}{10} + (100 - 310)^2 \times \frac{6}{10} \\ &= 84900 \end{aligned}$$

# 違いに注意

## ❗ データの平均値, 分散

今持っている**データそのもの**の特徴を表す  
**データ**がないと計算できない

## ❗ 確率変数の期待値 (平均), 分散

**確率分布**の特徴を表す (確率的な現象・仕組みの特徴)  
データは必要ないが, **確率分布**がわからないと計算できない

考え方が似てるから名前も似ているだけ  
注目しているものは全く異なる!!

データの平均値, 分散とは  
考え方自体は似ていても  
異なるものなので注意です!



# どのくじを引く?

くじ引き1

	A賞	B賞	C賞
賞金 (円)	1000	500	100
本数 (本)	1	3	6

くじ引き2

	A賞	B賞	C賞
賞金 (円)	1000	500	0
本数 (本)	2	2	6

くじ引き3

	A賞	B賞	C賞
賞金 (円)	1000	400	100
本数 (本)	2	1	7

どのくじを引こう??



Q 確率変数の**期待値**と**分散**を計算して判断してみよう!!

# どのくじを引く?

くじ引き1

	A賞	B賞	C賞
賞金 (円)	1000	500	100
本数 (本)	1	3	6

確率変数  $X$ : くじ引き1の賞金額  $X$  円

$X$	1000	500	100	計
確率	1/10	3/10	6/10	1

A

$$E[X] = 310$$

$$V[X] = 84900$$

くじ引き2

	A賞	B賞	C賞
賞金 (円)	1000	500	0
本数 (本)	2	2	6

確率変数  $Y$ : くじ引き2の賞金額  $Y$  円

$Y$	1000	500	0	計
確率	2/10	2/10	6/10	1

A

$$E[Y] = ??$$

$$V[Y] = 106000$$

くじ引き3

	A賞	B賞	C賞
賞金 (円)	1000	400	100
本数 (本)	2	1	7

確率変数  $Z$ : くじ引き3の賞金額  $Z$  円

$Z$	1000	400	100	計
確率	2/10	1/10	7/10	1

A

$$E[Z] = ??$$

$$V[Z] = 126900$$

## 練習問題 (2)

**Q** 期待値の ?? 部分を求めて、どのくじを引くのがいいか考えよ。

確率変数  $X$ : くじ引き1の賞金額  $X$  円

$X$	1000	500	100	計
確率	1/10	3/10	6/10	1

$$E[X] = 310$$

$$V[X] = 84900$$

確率変数  $Y$ : くじ引き2の賞金額  $Y$  円

$Y$	1000	500	0	計
確率	2/10	2/10	6/10	1

$$E[Y] = ??$$

$$V[Y] = 106000$$

確率変数  $Z$ : くじ引き3の賞金額  $Z$  円

$Z$	1000	400	100	計
確率	2/10	1/10	7/10	1

$$E[Z] = ??$$

$$V[Z] = 126900$$

**A**

# 連続型確率変数の期待値, 分散 (参考)

## ✓ 連続型確率変数の期待値, 分散

連続型確率変数  $X$  の確率密度関数を  $f_X(x)$  とする.


$X$  の期待値 (平均):

$$E[X] = \int x f_X(x) dx$$

$X$  の分散:

$$V[X] = E[(X - E[X])^2] = \int (x - E[X])^2 f_X(x) dx$$

離散型と連続型で  
計算方法が違うことだけ  
覚えておきましょう



## 今日のまとめ

- ▶ **確率変数:**  
**事象を数字に置き換える変換器**  
離散型確率変数 or 連続型確率変数
- ▶ **確率分布:**  
**確率変数のとる値とその確率の対応関係**  
離散型分布, 連続型分布  
**確率分布は現象を理解するための道具**
- ▶ **期待値, 分散:**  
**確率分布の特徴を表す指標**  
離散型 or 連続型で異なる  
**データの平均, 分散とは異なる!!**

今回の内容は推測統計を行うときに必要なので理解しておくといいですよ

