

# 離散数理工学 第7回

離散確率論：確率的離散システムの解析 (基礎)

岡本 吉央

okamotoy@uec.ac.jp

電気通信大学

2024年12月17日

最終更新：2024年12月8日 21:31

### 今日の目標

典型的な確率的離散システムの解析ができるようになる

- ▶ 不公平な硬貨投げ
- ▶ クーポン収集問題
- ▶ 誕生日のパラドックス

## 目次

- ① 不公平な硬貨投げ
- ② クーポン収集問題
- ③ 誕生日のパラドックス
- ④ 今日のまとめ

## 不公平な硬貨投げ：設定

## 不公平な硬貨投げ

次のような硬貨 (コイン) を 1 つ投げる

- ▶ 表の出る確率 =  $p$
- ▶ 裏の出る確率 =  $1 - p$

ただし,  $0 < p \leq 1$

**典型的な問題** : この硬貨を続けて何回か独立に投げる ( $n \geq 1$ )

- 1  $n$  回投げて, 表が  $n$  回出る確率は?
- 2  $n$  回投げて, 表が一度も出ない確率は?
- 3  $n$  回投げて, 表が一度は出る確率は?
- 4  $n$  回投げて, 表が出る回数の期待値は?
- 5 表が出るまで投げ続けるとき, 投げる回数の期待値は?

## 不公平な硬貨投げ：表が出続ける確率は？

## 問題

1  $n$  回投げて、表が  $n$  回出る確率は？

- ▶  $E_i = i$  回目に表が出る (事象)
- ▶ このとき、 $E_1, \dots, E_n$  は互いに独立なので

$$\begin{aligned}\Pr(\text{表が } n \text{ 回出る}) &= \Pr(E_1 \text{ かつ } E_2 \text{ かつ } \dots \text{ かつ } E_n) \\ &= \Pr(E_1) \cdot \Pr(E_2) \cdot \dots \cdot \Pr(E_n) \\ &= p \cdot p \cdot \dots \cdot p \\ &= p^n\end{aligned}$$

## 格言

事象 と 確率変数 を明確に区別する

不公平な硬貨投げ：表が一度も出ない確率は？

## 問題

2  $n$  回投げて、表が一度も出ない確率は？

- ▶  $\overline{E}_i = i$  回目に裏が出る (事象)
- ▶ このとき、 $\overline{E}_1, \dots, \overline{E}_n$  は互いに独立なので

$$\begin{aligned}\Pr(n \text{ 回中, 表が一度も出ない}) &= \Pr(\overline{E}_1 \text{ かつ } \dots \text{ かつ } \overline{E}_n) \\ &= \Pr(\overline{E}_1) \cdots \Pr(\overline{E}_n) \\ &= (1 - p) \cdots (1 - p) \\ &= (1 - p)^n\end{aligned}$$

## 不公平な硬貨投げ：表が一度は出る確率は？

## 問題

3  $n$  回投げて、表が一度は出る確率は？

- ▶ 「表が一度は出る」という事象は  
「表が一度も出ない」という事象の余事象
- ▶ したがって、

$$\begin{aligned}\Pr(n \text{ 回中, 表が一度は出る}) &= 1 - \Pr(n \text{ 回中, 表が一度も出ない}) \\ &= 1 - (1 - p)^n\end{aligned}$$

## 不公平な硬貨投げ：表が出る回数の期待値は？

## 問題

4  $n$  回投げて、表が出る回数の期待値は？

- ▶ 次の確率変数を考える (事象  $E_i$  の **標示確率変数** と呼ばれる)

$$X_i = \begin{cases} 1 & (E_i \text{ が生起する, つまり, } i \text{ 回目に表が出る}) \\ 0 & (E_i \text{ が生起しない, つまり, } i \text{ 回目に裏が出る}) \end{cases}$$

- ▶ このとき、 $E[X_i] = 1 \cdot p + 0 \cdot (1 - p) = p$
- ▶ 確率変数  $X$  で、 $n$  回の中で表が出る回数を表すとすると、

$$X = X_1 + \cdots + X_n$$



## 不公平な硬貨投げ：表が出る回数の期待値は？

## 問題

4  $n$  回投げて、表が出る回数の期待値は？

- ▶ 次の確率変数を考える (事象  $E_i$  の **標示確率変数** と呼ばれる)

$$X_i = \begin{cases} 1 & (E_i \text{ が生起する, つまり, } i \text{ 回目に表が出る}) \\ 0 & (E_i \text{ が生起しない, つまり, } i \text{ 回目に裏が出る}) \end{cases}$$

- ▶ このとき、 $E[X_i] = 1 \cdot p + 0 \cdot (1 - p) = p$
- ▶ 確率変数  $X$  で、 $n$  回の中で表が出る回数を表すとすると、

$$X = X_1 + \cdots + X_n$$

- ▶ したがって、

$$\begin{aligned} E[n \text{ 回中, 表が出る回数}] &= E[X] \\ &= E[X_1 + \cdots + X_n] \end{aligned}$$

不公平な硬貨投げ：表が出る回数の期待値は？

## 問題

4  $n$  回投げて、表が出る回数の期待値は？

- ▶ 次の確率変数を考える (事象  $E_i$  の **標示確率変数** と呼ばれる)

$$X_i = \begin{cases} 1 & (E_i \text{ が生起する, つまり, } i \text{ 回目に表が出る}) \\ 0 & (E_i \text{ が生起しない, つまり, } i \text{ 回目に裏が出る}) \end{cases}$$

- ▶ このとき、 $E[X_i] = 1 \cdot p + 0 \cdot (1 - p) = p$
- ▶ 確率変数  $X$  で、 $n$  回の中で表が出る回数を表すとすると、

$$X = X_1 + \cdots + X_n$$

- ▶ したがって、

$$\begin{aligned} E[n \text{ 回中, 表が出る回数}] &= E[X] \\ &= E[X_1 + \cdots + X_n] \\ &= E[X_1] + \cdots + E[X_n] \leftarrow \text{期待値の線形性} \end{aligned}$$

不公平な硬貨投げ：表が出る回数の期待値は？

## 問題

4  $n$  回投げて、表が出る回数の期待値は？

- ▶ 次の確率変数を考える (事象  $E_i$  の **標示確率変数** と呼ばれる)

$$X_i = \begin{cases} 1 & (E_i \text{ が生起する, つまり, } i \text{ 回目に表が出る}) \\ 0 & (E_i \text{ が生起しない, つまり, } i \text{ 回目に裏が出る}) \end{cases}$$

- ▶ このとき,  $E[X_i] = 1 \cdot p + 0 \cdot (1 - p) = p$
- ▶ 確率変数  $X$  で,  $n$  回の中で表が出る回数を表すとすると,

$$X = X_1 + \cdots + X_n$$

- ▶ したがって,

$$\begin{aligned} E[n \text{ 回中, 表が出る回数}] &= E[X] \\ &= E[X_1 + \cdots + X_n] \\ &= E[X_1] + \cdots + E[X_n] \leftarrow \text{期待値の線形性} \\ &= pn \end{aligned}$$

## (補足) 不公平な硬貨投げ：表が出る回数の期待値は？

↪ 標示確率変数を使わなかったら…

- ▶  $F_j = n$  回の中で  $j$  回表が出る (事象)
- ▶ このとき,  $\Pr(F_j) = \binom{n}{j} p^j (1-p)^{n-j}$
- ▶ したがって,

$$\begin{aligned} E[n \text{ 回中, 表が出る回数}] &= \sum_{j=0}^n j \cdot \Pr(F_j) = \sum_{j=0}^n j \cdot \binom{n}{j} p^j (1-p)^{n-j} \\ &= np(p + (1-p))^{n-1} = pn \end{aligned}$$

ここで

(演習問題)

$$nx(x+y)^{n-1} = \sum_{j=0}^n j \binom{n}{j} x^j y^{n-j}$$

不公平な硬貨投げ：表が出るまで投げるとき、投げる回数の期待値は？

## 問題

5 表が出るまで投げるとき、投げる回数の期待値は？

- ▶ 「表が出るまで投げるとき、投げる回数」を  $Y$  とする (確率変数)
- ▶ 1 回目に表が出る事象は  $E_1$  と書いたので、

$$E[Y] = E[Y | E_1] \Pr(E_1) + E[Y | \overline{E_1}] \Pr(\overline{E_1})$$

- ▶ ここで、 $\Pr(E_1) = p$ ,  $\Pr(\overline{E_1}) = 1 - \Pr(E_1) = 1 - p$
- ▶ また、 $E[Y | E_1] = 1$  であり、 $E[Y | \overline{E_1}] = E[1 + Y] = 1 + E[Y]$
- ▶ したがって、

$$E[Y] = 1 \cdot p + (1 + E[Y]) \cdot (1 - p)$$

- ▶  $\therefore E[Y] = \frac{1}{p}$

不公平な硬貨投げ：表が出るまで投げるとき、投げる回数の期待値は？

## 問題

5 表が出るまで投げるとき、投げる回数の期待値は？

- ▶ 「表が出るまで投げるとき、投げる回数」を  $Y$  とする (確率変数)
- ▶ 1 回目に表が出る事象は  $E_1$  と書いたので、

$$E[Y] = E[Y | E_1] \Pr(E_1) + E[Y | \overline{E_1}] \Pr(\overline{E_1})$$

- ▶ ここで、 $\Pr(E_1) = p$ ,  $\Pr(\overline{E_1}) = 1 - \Pr(E_1) = 1 - p$
- ▶ また、 $E[Y | E_1] = 1$  であり、 $E[Y | \overline{E_1}] = E[1 + Y] = 1 + E[Y]$
- ▶ したがって、

$$E[Y] = 1 \cdot p + (1 + E[Y]) \cdot (1 - p)$$

- ▶  $\therefore E[Y] = \frac{1}{p}$

不公平な硬貨投げ：表が出るまで投げるとき、投げる回数の期待値は？

## 問題

5 表が出るまで投げるとき、投げる回数の期待値は？

- ▶ 「表が出るまで投げるとき、投げる回数」を  $Y$  とする (確率変数)
- ▶ 1 回目に表が出る事象は  $E_1$  と書いたので、

$$E[Y] = E[Y | E_1] \Pr(E_1) + E[Y | \overline{E_1}] \Pr(\overline{E_1})$$

- ▶ ここで、 $\Pr(E_1) = p$ ,  $\Pr(\overline{E_1}) = 1 - \Pr(E_1) = 1 - p$
- ▶ また、 $E[Y | E_1] = 1$  であり、 $E[Y | \overline{E_1}] = E[1 + Y] = 1 + E[Y]$
- ▶ したがって、

$$E[Y] = 1 \cdot p + (1 + E[Y]) \cdot (1 - p)$$

- ▶  $\therefore E[Y] = \frac{1}{p}$

不公平な硬貨投げ：表が出るまで投げるとき、投げる回数の期待値は？

## 問題

5 表が出るまで投げるとき、投げる回数の期待値は？

- ▶ 「表が出るまで投げるとき、投げる回数」を  $Y$  とする (確率変数)
- ▶ 1 回目に表が出る事象は  $E_1$  と書いたので、

$$E[Y] = E[Y | E_1] \Pr(E_1) + E[Y | \overline{E_1}] \Pr(\overline{E_1})$$

- ▶ ここで、 $\Pr(E_1) = p$ ,  $\Pr(\overline{E_1}) = 1 - \Pr(E_1) = 1 - p$
- ▶ また、 $E[Y | E_1] = 1$  であり、 $E[Y | \overline{E_1}] = E[1 + Y] = 1 + E[Y]$
- ▶ したがって、

$$E[Y] = 1 \cdot p + (1 + E[Y]) \cdot (1 - p)$$

- ▶  $\therefore E[Y] = \frac{1}{p}$

不公平な硬貨投げ：表が出るまで投げるとき、投げる回数の期待値は？

## 問題

5 表が出るまで投げるとき、投げる回数の期待値は？

- ▶ 「表が出るまで投げるとき、投げる回数」を  $Y$  とする (確率変数)
- ▶ 1 回目に表が出る事象は  $E_1$  と書いたので、

$$E[Y] = E[Y | E_1] \Pr(E_1) + E[Y | \overline{E_1}] \Pr(\overline{E_1})$$

- ▶ ここで、 $\Pr(E_1) = p$ ,  $\Pr(\overline{E_1}) = 1 - \Pr(E_1) = 1 - p$
- ▶ また、 $E[Y | E_1] = 1$  であり、 $E[Y | \overline{E_1}] = E[1 + Y] = 1 + E[Y]$
- ▶ したがって、

$$E[Y] = 1 \cdot p + (1 + E[Y]) \cdot (1 - p)$$

- ▶  $\therefore E[Y] = \frac{1}{p}$

不公平な硬貨投げ：表が出るまで投げるとき、投げる回数の期待値は？

## 問題

5 表が出るまで投げるとき、投げる回数の期待値は？

- ▶ 「表が出るまで投げるとき、投げる回数」を  $Y$  とする (確率変数)
- ▶ 1 回目に表が出る事象は  $E_1$  と書いたので、

$$E[Y] = E[Y | E_1] \Pr(E_1) + E[Y | \overline{E_1}] \Pr(\overline{E_1})$$

- ▶ ここで、 $\Pr(E_1) = p$ ,  $\Pr(\overline{E_1}) = 1 - \Pr(E_1) = 1 - p$
- ▶ また、 $E[Y | E_1] = 1$  であり、 $E[Y | \overline{E_1}] = E[1 + Y] = 1 + E[Y]$
- ▶ したがって、

$$E[Y] = 1 \cdot p + (1 + E[Y]) \cdot (1 - p)$$

- ▶  $\therefore E[Y] = \frac{1}{p}$

不公平な硬貨投げ：表が出るまで投げるとき、投げる回数の期待値は？

## 問題

5 表が出るまで投げるとき、投げる回数の期待値は？

- ▶ 「表が出るまで投げるとき、投げる回数」を  $Y$  とする (確率変数)
- ▶ 1 回目に表が出る事象は  $E_1$  と書いたので、

$$E[Y] = E[Y | E_1] \Pr(E_1) + E[Y | \overline{E_1}] \Pr(\overline{E_1})$$

- ▶ ここで、 $\Pr(E_1) = p$ ,  $\Pr(\overline{E_1}) = 1 - \Pr(E_1) = 1 - p$
- ▶ また、 $E[Y | E_1] = 1$  であり、 $E[Y | \overline{E_1}] = E[1 + Y] = 1 + E[Y]$
- ▶ したがって、

$$E[Y] = 1 \cdot p + (1 + E[Y]) \cdot (1 - p) = (1 - p)E[Y] + 1$$

- ▶  $\therefore E[Y] = \frac{1}{p}$

(補足) 不公平な硬貨投げ：表が出るまで投げるとき、投げる回数の期待値は？

↪ 条件つき期待値を使わなかったら…

- ▶  $A_i = 1$  回目から  $i-1$  回目まですべて裏で、 $i$  回目で表が出る (事象)
- ▶ このとき、

$$\begin{aligned} \Pr(A_i) &= \Pr(\overline{E_1} \text{ かつ } \dots \text{ かつ } \overline{E_{i-1}} \text{ かつ } E_i) \\ &= \Pr(\overline{E_1}) \cdots \Pr(\overline{E_{i-1}}) \cdot \Pr(E_i) \quad (\text{独立性}) \\ &= (1-p)^{i-1} p \end{aligned}$$

- ▶ したがって、

$$\begin{aligned} \text{求める期待値} &= \sum_{i=1}^{\infty} i \cdot \Pr(A_i) \\ &= \sum_{i=1}^{\infty} i \cdot (1-p)^{i-1} p \\ &= \frac{1}{p} \quad (\text{詳細は演習問題}) \end{aligned}$$

不公平な硬貨投げ：表が出る回数が期待値から離れる確率は？

- ▶ 次の確率変数を考える (事象  $E_i$  の **標示確率変数** と呼ばれる)

$$X_i = \begin{cases} 1 & (E_i \text{ が生起する, つまり, } i \text{ 回目に表が出る}) \\ 0 & (E_i \text{ が生起しない, つまり, } i \text{ 回目に裏が出る}) \end{cases}$$

- ▶ 確率変数  $X$  で,  $n$  回の中で表が出る回数を表すとすると,

$$X = X_1 + \cdots + X_n$$

- ▶ したがって,


$$\begin{aligned} \mathbb{E}[X] &= \mathbb{E}[X_1 + \cdots + X_n] \\ &= \mathbb{E}[X_1] + \cdots + \mathbb{E}[X_n] = pn \end{aligned}$$

次の確率はどれくらい小さいか？ (または大きいか？)

$$\Pr(X \geq 2\mathbb{E}[X])$$

不公平な硬貨投げ：表が出る回数が期待値から離れる確率は？

シミュレーションを試してみた



$n = 100$ ,  $p = 0.1$ , 10000 回の試行を行ったところ

$$\blacktriangleright \Pr(X \geq 2E[X]) = \frac{30}{10000} = 0.003 \quad (\text{とても小さい})$$

これを数学的に解析したい

## マルコフの不等式

## 性質：マルコフの不等式

非負整数値確率変数  $Z \geq 0$  と正実数  $t > 0$  に対して、 $E[Z]$  が存在するとき

$$\Pr(Z \geq t) \leq \frac{E[Z]}{t}$$

## 格言

マルコフの不等式で、起こりにくい事象の確率を評価

## マルコフの不等式

## 性質：マルコフの不等式

非負整数値確率変数  $Z \geq 0$  と正実数  $t > 0$  に対して、 $E[Z]$  が存在するとき

$$\Pr(Z \geq t) \leq \frac{E[Z]}{t}$$

## 格言

マルコフの不等式で、起こりにくい事象の確率を評価

証明：

$$\begin{aligned} E[Z] &= \sum_{i=0}^{\infty} i \cdot \Pr(Z = i) = \sum_{i=0}^{t-1} i \cdot \underbrace{\Pr(Z = i)}_{\geq 0} + \sum_{i=t}^{\infty} \underbrace{i}_{\geq t} \cdot \Pr(Z = i) \\ &\geq t \sum_{i=t}^{\infty} \Pr(Z = i) = t \Pr(Z \geq t) \quad \square \end{aligned}$$

## 不公平な硬貨投げ：マルコフの不等式

マルコフの不等式より

$$\Pr(X \geq 2E[X]) \leq \frac{E[X]}{2E[X]} = \frac{1}{2}$$

「とても小さい」ということが証明できない

性質：マルコフの不等式

(復習)

非負整数値確率変数  $Z \geq 0$  と正実数  $t > 0$  に対して、 $E[Z]$  が存在するとき

$$\Pr(Z \geq t) \leq \frac{E[Z]}{t}$$

## 不公平な硬貨投げ：チェルノフ上界の技法

$$\Pr(X \geq 2E[X]) = \Pr(2^X \geq 2^{2E[X]})$$

## 不公平な硬貨投げ：チェルノフ上界の技法

マルコフの不等式より

$$\begin{aligned}\Pr(X \geq 2E[X]) &= \Pr(2^X \geq 2^{2E[X]}) \\ &\leq \frac{E[2^X]}{2^{2E[X]}}\end{aligned}$$

## 不公平な硬貨投げ：チェルノフ上界の技法

マルコフの不等式より

$$\begin{aligned}\Pr(X \geq 2E[X]) &= \Pr(2^X \geq 2^{2E[X]}) \\ &\leq \frac{E[2^X]}{2^{2E[X]}}\end{aligned}$$

よって、 $E[2^X]$ を知りたい

## 不公平な硬貨投げ：チェルノフ上界の技法 (2)

$X_1, \dots, X_n$  は互いに独立なので,  $2^{X_1}, \dots, 2^{X_n}$  も互いに独立であり,

$$\begin{aligned} \mathbb{E}[2^X] &= \mathbb{E}[2^{X_1 + \dots + X_n}] = \mathbb{E}\left[\prod_{i=1}^n 2^{X_i}\right] \\ &= \prod_{i=1}^n \mathbb{E}[2^{X_i}] \quad \leftarrow \text{独立性を利用} \end{aligned}$$

ここで, 任意の  $i$  に対して

$$\mathbb{E}[2^{X_i}] = 2^1 \cdot p + 2^0 \cdot (1 - p) = 2p + (1 - p) = 1 + p$$

ゆえに,

$$\mathbb{E}[2^X] = \prod_{i=1}^n \mathbb{E}[2^{X_i}] = (1 + p)^n$$

## 不公平な硬貨投げ：チェルノフ上界の技法 (3)

まとめると,

$$\begin{aligned}\Pr(X \geq 2E[X]) &\leq \frac{E[2^X]}{2^{2E[X]}} \\ &= \frac{(1+p)^n}{2^{2pn}} = \left(\frac{1+p}{4^p}\right)^n\end{aligned}$$

- ▶ 右辺は  $n$  が大きくなるにつれて小さくなる
- ▶  $p = 1/10$ ,  $n = 100$  のとき, 右辺  $\approx 0.0132$

## 不公平な硬貨投げ：チェルノフ上界の技法 (4)

## 疑問

- ▶ 疑問： $X_i$  から  $2^{X_i}$  を作ったが、「2」でないといけないのか？
- ▶ 回答：「2」でなくてもよい。1 より大きければよい

例えば、2 ではなく、3 にすると、

$$\begin{aligned} \Pr(X \geq 2E[X]) &\leq \frac{E[3^X]}{3^{2E[X]}} \\ &= \frac{(1+2p)^n}{3^{2pn}} = \left(\frac{1+2p}{9p}\right)^n \end{aligned}$$

$p = 1/10$ ,  $n = 100$  のとき、この右辺は  $\approx 0.0238$

チェルノフ上界の技法： $X$  が独立確率変数の和であるとき

- ▶  $E[X]$  の代わりに  $E[c^X]$  を考えて、マルコフの不等式 (など) を適用
- ▶ 上界ができる限り小さくなるように、定数  $c$  を定める

# 目次

- ① 不公平な硬貨投げ
- ② **クーポン収集問題**
- ③ 誕生日のパラドックス
- ④ 今日のまとめ

## クーポン収集問題

## クーポン収集問題

## 設定

- ▶ 商品を買うと  $n$  種類の景品 (クーポン) の中の 1 つが当たる
- ▶ 景品の集合  $N = \{1, \dots, n\}$
- ▶ どの景品  $i$  に対しても,  $\Pr(\text{景品 } i \text{ が当たる}) = \frac{1}{n}$  で,  
これらは商品の間で同一であり, 互いに独立

## 問題


- ▶ 全種類の景品を集め切るまで, 何個商品を購入すればよいか?

注意: 購入商品数は確率変数なので, 答えたいものは

- ▶ 購入商品数の期待値
- ▶ 高確率で購入する商品数 (の上界)

## クーポン収集問題：シミュレーション

## 景品数 100 の場合



1,000,000 回の試行：購入商品数平均 = 518.62

## クーポン収集問題：期待値

考え方：商品を次々と買うとき，既にいくつ景品を持っているか考慮する

$$\text{▶ Pr(新しい景品が当たる | 既に景品を } j \text{ 個所持)} = \frac{n-j}{n}$$

ここで，次の確率変数を考える

$X_j =$  景品を  $j$  種類所持した瞬間から，  
新しい景品が当たるまでに購入した商品の数

- ▶ 景品を  $j$  種類所持しているとき，新しい景品が当たることは表が出る確率が  $\frac{n-j}{n}$  である硬貨を投げて表が出ること とみなせる
- ▶ したがって， $E[X_j] = \frac{n}{n-j}$

## クーポン収集問題：期待値 (続き)

▶ 購入商品数 =  $X_0 + X_1 + \cdots + X_{n-1}$  なので,

$$\begin{aligned} \mathbf{E}[\text{購入商品数}] &= \mathbf{E}[X_0 + X_1 + \cdots + X_{n-1}] \\ &= \mathbf{E}[X_0] + \mathbf{E}[X_1] + \cdots + \mathbf{E}[X_{n-1}] \\ &= \frac{n}{n} + \frac{n}{n-1} + \cdots + \frac{n}{1} \\ &= n \sum_{k=1}^n \frac{1}{k} = nH_n \end{aligned}$$


定義：調和数とは？

**第  $n$  調和数** とは、次で定義される数  $H_n$  のこと

$$H_n = \sum_{k=1}^n \frac{1}{k}$$

## クーポン収集問題：シミュレーション (再掲)

## 景品数 100 の場合



1,000,000 回の試行：購入商品数平均 = 518.62

( $100H_{100} \approx 518.74$ )


## 調和数の性質

性質：調和数の上界と下界

任意の整数  $n \geq 1$  に対して

$$\ln(n+1) \leq H_n \leq 1 + \ln n$$

証明：演習問題 (ヒントは次の図)



帰結

$$H_n = \ln n + O(1)$$

## クーポン収集問題：期待値から確率へ

- ▶ すなわち,

$$E[\text{購入商品数}] = nH_n = n \ln n + O(n)$$

- ▶ マルコフの不等式より

$$\Pr(\text{購入商品数} \geq 2nH_n) \leq \frac{E[\text{購入商品数}]}{2nH_n} = \frac{1}{2}$$

購入商品数が大きくなる確率に対して、もっと「きつい」上界が欲しい

## クーポン収集問題：期待値から確率へ — 合併上界の利用 (1)

- ▶  $E_i = 2nH_n$  回の商品購入で景品  $i$  が得られない (事象)
- ▶ このとき、任意の  $i \in \{1, \dots, n\}$  に対して、

$$\begin{aligned}\Pr(E_i) &= \left(\frac{n-1}{n}\right)^{2nH_n} = \left(1 - \frac{1}{n}\right)^{2nH_n} \\ &\leq \left(e^{-\frac{1}{n}}\right)^{2nH_n} = e^{-2H_n} \\ &\leq e^{-2\ln(n+1)} = \frac{1}{(n+1)^2}\end{aligned}$$

事実：有用な不等式

(第1回講義より)

任意の実数  $x$  に対して

$$1 + x \leq e^x$$

## クーポン収集問題：期待値から確率へ — 合併上界の利用 (2)

▶ したがって、

$$\begin{aligned} \Pr(\text{購入商品数} > 2nH_n) &= \Pr(E_1 \text{ または } E_2 \text{ または } \dots \text{ または } E_n) \\ &\leq \sum_{i=1}^n \Pr(E_i) \\ &\leq n \cdot \frac{1}{(n+1)^2} \leq \frac{n+1}{(n+1)^2} = \frac{1}{n+1} \end{aligned}$$

つまり、 $\lim_{n \rightarrow \infty} \Pr(\text{購入商品数} > 2nH_n) = 0$

性質：合併上界

(『確率論』の復習)

事象  $A, B$  に対して

$$\Pr(A \cup B) \leq \Pr(A) + \Pr(B)$$

## クーポン収集問題：期待値から確率へ (続)

次が知られている (証明は省略：ポアソン近似とチェルノフ技法を使う)

事実：エルデシュとレニィによる 1961 年の結果

任意の正実数  $c > 0$  に対して,

$$\lim_{n \rightarrow \infty} \Pr(\text{購入商品数} > n \ln n + cn) = 1 - e^{-e^{-c}},$$

$$\lim_{n \rightarrow \infty} \Pr(\text{購入商品数} < n \ln n + cn) = 1 - e^{-e^{-c}}$$

つまり購入商品数 (確率変数) は, その期待値の周りに集中している

## クーポン収集問題：まとめ

## クーポン収集問題

## 設定

- ▶ 商品を買うと  $n$  種類の景品 (クーポン) の中の 1 つが当たる
- ▶ 景品の集合  $N = \{1, \dots, n\}$
- ▶ どの景品  $i$  に対しても,  $\Pr(\text{景品 } i \text{ が当たる}) = \frac{1}{n}$  で,  
これらは商品の間で同一であり, 互いに独立

## 問題

- ▶ すべての景品を集め切るまで, 何個商品を購入すればよいか?

## 回答

- ▶ 購入商品数の期待値は  $nH_n$  であり,
- ▶  $n \rightarrow \infty$  のとき, 購入商品数は高い確率で  $nH_n$  になる

# 目次

- ① 不公平な硬貨投げ
- ② クーポン収集問題
- ③ 誕生日のパラドックス
- ④ 今日のまとめ

## 誕生日のパラドックス：例

## 誕生日問題

10 人いる部屋の中に、誕生日が同じ 2 人はいるか？  
そのような 2 人がいる確率は？

仮定

- ▶ 1 年は 366 日
- ▶ 人の誕生日がそれら 366 日の間に等確率で分布する

$$\Pr(i \text{ さんの誕生日が } j) = \frac{1}{366}$$

## 誕生日のパラドックス：計算

まず、10人の誕生日がすべて異なる確率を計算する


$$\blacktriangleright 10 \text{ 人の誕生日がすべて異なる確率} = \frac{366 \cdot 365 \cdot \dots \cdot 357}{366^{10}} \approx 0.883$$

したがって

$$\blacktriangleright 10 \text{ 人の中に誕生日の同じ人がいる確率} \approx 1 - 0.883 = 0.117$$

つまり、

$$\blacktriangleright 11\% \text{ ぐらいの確率で同じ誕生日の 2 人がいる}$$



## 誕生日のパラドックス：計算 — 30 人の場合

まず、30 人の誕生日がすべて異なる確率を計算する


$$\blacktriangleright 30 \text{ 人の誕生日がすべて異なる確率} = \frac{366 \cdot 365 \cdot \dots \cdot 337}{366^{30}} \approx 0.295$$

したがって


$$\blacktriangleright 30 \text{ 人の中に誕生日の同じ人がいる確率} \approx 1 - 0.295 = 0.705$$

つまり、

$$\blacktriangleright 70 \% \text{ ぐらいの確率で同じ誕生日の 2 人がいる}$$



## 誕生日のパラドックス：計算してみた



## 誕生日のパラドックス：一般化

## 設定

- ▶  $k = 1$  年の日数
- ▶  $m =$  部屋の人数
- ▶  $\Pr(i \text{ さんの誕生日が } j) = \frac{1}{k}$

## 問題

- 1 部屋の中に同じ誕生日の 2 人がいる確率は？
- 2 同じ誕生日の 2 人がいる確率が  $\frac{1}{2}$  を超えるのはいつ？

## 誕生日のパラドックス：一般化

まず、 $m$  人の誕生日がすべて異なる確率を計算する

- ▶  $m$  人の誕生日がすべて異なる確率  $= \frac{k \cdot (k-1) \cdots (k-m+1)}{k^m}$
- ▶ ここで、

$$\begin{aligned} \frac{k \cdot (k-1) \cdots (k-m+1)}{k^m} &= \prod_{i=0}^{m-1} \frac{k-i}{k} = \prod_{i=0}^{m-1} \left(1 - \frac{i}{k}\right) \\ &\leq \prod_{i=0}^{m-1} e^{-\frac{i}{k}} = e^{\sum_{i=0}^{m-1} -\frac{i}{k}} = e^{-\frac{m(m-1)}{2k}} \end{aligned}$$

事実：有用な不等式

(第 1 回講義の復習)

任意の実数  $x$  に対して

$$1 + x \leq e^x$$

## 誕生日のパラドックス：一般化 (2)

したがって、

- ▶  $m$  人の中に誕生日が同じ 2 人がいる確率  $\geq 1 - e^{-\frac{m(m-1)}{2k}}$
- ▶  $m \geq \sqrt{(2 \ln 2)k} + 1$  のとき、この右辺が  $\frac{1}{2}$  以上になる

なぜならば、 $m \geq \sqrt{(2 \ln 2)k} + 1$  であるとき、

$$(m-1)^2 \geq (2 \ln 2)k$$

$$\therefore m(m-1) \geq (2 \ln 2)k$$

$$\therefore -\ln 2 \geq -\frac{m(m-1)}{2k}$$

$$\therefore \frac{1}{2} \geq e^{-\frac{m(m-1)}{2k}}$$

$$\therefore 1 - e^{-\frac{m(m-1)}{2k}} \geq \frac{1}{2} \quad \text{となるから}$$


## 誕生日のパラドックス：ハッシュ値の衝突との関係

## ハッシュ

（『アルゴリズム論第一』の復習）

ハッシュ関数は  $N = \{1, \dots, n\}$  から  $K = \{1, \dots, k\}$  への関数  $h$   
(典型的には  $k < n$ )

- ▶ 性質： $h$ が「よくかき混ぜる」関数であるとき  
 $h(x) = h(y)$  であるならば、 $x = y$  である可能性が高い
- ▶  $x \neq y$  であるのに  $h(x) = h(y)$  であるとき、  
 $x$  と  $y$  のハッシュ値が衝突 (好ましくない)



## 誕生日のパラドックス：ハッシュ値の衝突との関係 (続)

## ハッシュ

(『アルゴリズム論第一』の復習)

ハッシュ関数は  $N = \{1, \dots, n\}$  から  $K = \{1, \dots, k\}$  への関数  $h$   
(典型的には  $k < n$ )

- ▶ 性質： $h$ が「よくかき混ぜる」関数であるとき  
 $h(x) = h(y)$ であるならば、 $x = y$ である可能性が高い
- ▶  $x \neq y$ であるのに  $h(x) = h(y)$ であるとき、  
 $x$ と  $y$ のハッシュ値が衝突 (好ましくない)

次の2つは同じであると見なせる

- ▶ 要素数  $m$  の部分集合  $S \subseteq N$  にハッシュ値の衝突する2要素があるか？
- ▶ 1年が  $k$  日の場合、 $m$  人の部屋の中に誕生日の同じ2人がいるか？

$\therefore m \geq \sqrt{(2 \ln 2)k} + 1$  のとき、そのような2要素の存在確率は  $\frac{1}{2}$  以上

## 目次

- ① 不公平な硬貨投げ
- ② クーポン収集問題
- ③ 誕生日のパラドックス
- ④ 今日のまとめ

## 今日の目標

## 今日の目標

典型的な確率的離散システムの解析ができるようになる

- ▶ 不公平な硬貨投げ
- ▶ クーポン収集問題
- ▶ 誕生日のパラドックス

## 目次

- ① 不公平な硬貨投げ
- ② クーポン収集問題
- ③ 誕生日のパラドックス
- ④ 今日のまとめ