

離散数理工学 第 11 回  
離散確率論：乱択データ構造とアルゴリズム (発展)

岡本 吉央  
okamotoy@uec.ac.jp

電気通信大学

2015 年 1 月 13 日

最終更新：2015 年 1 月 12 日 15:22

## スケジュール 前半 (予定)

- |   |                      |         |
|---|----------------------|---------|
| 1 | 数え上げの基礎：二項係数と二項定理    | (10/7)  |
| ★ | 休講 (体育祭)             | (10/14) |
| 2 | 数え上げの基礎：漸化式の立て方      | (10/21) |
| 3 | 数え上げの基礎：漸化式の解き方 (基礎) | (10/28) |
| 4 | 数え上げの基礎：漸化式の解き方 (発展) | (11/4)  |
| 5 | 離散代数：群と対称性           | (11/11) |
| 6 | 離散代数：部分群と軌道          | (11/18) |
| 7 | 離散代数：対称性を考慮した数え上げ    | (11/25) |

## スケジュール 後半 (予定)

- 8 離散確率論 : 確率の復習と確率不等式 (12/2)
- 9 離散確率論 : 確率的離散システムの解析 (12/9)
- ★ 中間試験 (12/16)
- 10 離散確率論 : 乱択データ構造とアルゴリズム (基礎) (1/6)
- 11 離散確率論 : 乱択データ構造とアルゴリズム (発展) (1/13)
- 12 離散確率論 : マルコフ連鎖 (基礎) (1/20)
- ★ 休講 (海外出張) (1/27)
- 13 離散確率論 : マルコフ連鎖 (発展) (2/3)
- ★ 期末試験 (2/17?)

注意 : 予定の変更もありうる

### 今日の目標

典型的な乱択アルゴリズムの設計と解析ができるようになる

- ▶ 確率の推定 (中央値トリック)

## 目次

- ① 確率の推定：単純なアルゴリズム
- ② 確率の推定：中央値トリック
- ③ 今日のまとめ

## 不公平な硬貨

## 設定

- ▶ 硬貨が1つある
- ▶ 投げたとき、表が出る確率はいつも変わらない
- ▶ その確率が分からない
- ▶ **目標**：表が出る確率を知りたい
- ▶ 可能な操作：硬貨を投げる（こののみ）

## 不公平な硬貨

## 設定

- ▶ 考えている硬貨について

$$\Pr(\text{表}) = p$$

ただし,  $0 \leq p \leq 1$

- ▶ 目標 :  $p$ を知りたい

## 単純なアルゴリズム

## 単純なアルゴリズム

硬貨を何度も投げてみる

- ▶  $n$  回投げるとする (独立な試行)
- ▶ 確率変数  $X_i$  を次で定義 ( $i \in \{1, \dots, n\}$ )

$$X_i = \begin{cases} 0 & (i \text{ 回目に投げたとき裏が出る}) \\ 1 & (i \text{ 回目に投げたとき表が出る}) \end{cases}$$

- ▶ 次の量を出力

$$\frac{X_1 + X_2 + \dots + X_n}{n}$$

## 期待値の解析

- ▶ 出力の期待値は

$$\begin{aligned} E \left[ \frac{X_1 + X_2 + \dots + X_n}{n} \right] &= \frac{1}{n} \sum_{i=1}^n E[X_i] \\ &= \frac{1}{n} \sum_{i=1}^n (0 \cdot (1-p) + 1 \cdot p) \\ &= p \end{aligned}$$

期待値は正しい「推測」になっている

## 問題点

必ず「 $p$ 」を出力するわけではない  $\rightsquigarrow$  誤差が出る

$n$  を大きくすれば、誤差は小さくなりそう

## 誤差の解析 (1)

以後、 $X = X_1 + X_2 + \dots + X_n$  とする

- ▶ 真の値  $p$  から出力  $\frac{X}{n}$  がどれだけずれるか？
- ▶ そのずれが  $\varepsilon$  未満である確率を知りたい
- ▶ その確率は次のように書ける

$$\Pr \left( \left| \frac{X}{n} - p \right| < \varepsilon \right)$$

- ▶ 計算

$$\Pr \left( \left| \frac{X}{n} - p \right| < \varepsilon \right) = 1 - \Pr \left( \left| \frac{X}{n} - p \right| \geq \varepsilon \right),$$

$$\Pr \left( \left| \frac{X}{n} - p \right| \geq \varepsilon \right) \leq \frac{E \left[ \left| \frac{X}{n} - p \right| \right]}{\varepsilon} \quad (\text{マルコフの不等式})$$

しかし、 $E \left[ \left| \frac{X}{n} - p \right| \right]$  はどう計算したらいいかわからない

## 誤差の解析 (2)

$$\Pr\left(\left|\frac{X}{n} - p\right| \geq \varepsilon\right) = \Pr\left(\left|\frac{X}{n} - p\right|^2 \geq \varepsilon^2\right) \leq \frac{E\left[\left|\frac{X}{n} - p\right|^2\right]}{\varepsilon^2}$$

$E\left[\left|\frac{X}{n} - p\right|^2\right]$  を計算してみる

## 誤差の解析 (3)

$$E \left[ \left| \frac{X}{n} - p \right|^2 \right] = E \left[ \left( \frac{X}{n} \right)^2 - 2p \frac{X}{n} + p^2 \right] = \frac{1}{n^2} E[X^2] - \frac{2p}{n} E[X] + p^2$$

ここで,

$$E[X] = E[X_1 + \cdots + X_n] = \sum_{i=1}^n E[X_i] = pn$$

$$E[X^2] = E[(X_1 + \cdots + X_n)^2] = \sum_{i=1}^n E[X_i^2] + \sum_{i=1}^n \sum_{j=1, (i \neq j)}^n E[X_i X_j]$$

## 誤差の解析 (4)

任意の  $i \in \{1, \dots, n\}$  に対して

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

したがって,

$$\sum_{i=1}^n E[X_i^2] = pn$$

任意の異なる  $i, j \in \{1, \dots, n\}$  に対して,  $X_i$  と  $X_j$  は独立なので,

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

したがって,

$$\sum_{i=1}^n \sum_{j=1, (i \neq j)}^n E[X_i X_j] = p^2 n(n - 1)$$

## 誤差の解析 (5)

ここまで、まとめると

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

## 誤差の解析 (6)

すなわち,

$$\Pr\left(\left|\frac{X}{n} - p\right| \geq \varepsilon\right) \leq \frac{\mathbb{E}\left[\left|\frac{X}{n} - p\right|^2\right]}{\varepsilon^2} = \frac{1}{\varepsilon^2} \frac{p(1-p)}{n}$$

- ▶ この不等式は **チェビシェフの不等式** と呼ばれる (ものの特殊な場合)
- ▶ この右辺を  $\delta$  以下にするには,  $n \geq \frac{1}{\varepsilon^2} \frac{p(1-p)}{\delta}$  とすればよい

## 結論

誤差が  $\varepsilon$  以上になる確率を  $\delta$  以下とするためには,

$$n \geq \frac{1}{\varepsilon^2} \frac{p(1-p)}{\delta}$$

とすればよい

## 疑問

## 単純なアルゴリズム

硬貨を何度も投げてみる

- ▶  $n$  回投げるとする (独立な試行)
- ▶ 確率変数  $X_i$  を次で定義 ( $i \in \{1, \dots, n\}$ ) (標示確率変数)

$$X_i = \begin{cases} 1 & (i \text{ 回目に投げたとき表が出る}) \\ 0 & (i \text{ 回目に投げたとき裏が出る}) \end{cases}$$

- ▶ 次の量を出力

$$\frac{X_1 + X_2 + \dots + X_n}{n}$$

## 疑問

この「単純なアルゴリズム」よりもよいアルゴリズムは無いのか？

## 目次

- ① 確率の推定：単純なアルゴリズム
- ② 確率の推定：中央値トリック
- ③ 今日のまとめ

## 中央値トリック (median trick)

## 中央値トリック

- ▶  $n$  回投げるとする (独立な試行)
- ▶  $n = (2k - 1)t$  とする ( $k, t$  は自然数)
- ▶ 確率変数  $X_i$  を次で定義 ( $i \in \{1, \dots, n\}$ )

$$X_i = \begin{cases} 0 & (i \text{ 回目に投げたとき裏が出る}) \\ 1 & (i \text{ 回目に投げたとき表が出る}) \end{cases}$$

- ▶ 確率変数  $Y_j$  を次で定義 ( $j \in \{1, \dots, 2k - 1\}$ )

$$Y_j = \frac{X_{(j-1)t+1} + \dots + X_{(j-1)t+t}}{t}$$

- ▶ 次の量を出力

$$Y = \text{med}\{Y_1, \dots, Y_{2k-1}\}$$

med は中央値 :  $\text{med}\{5, 1, 6, 2, 4\} = 4$

## 中央値トリック：誤差の解析 (1)

- ▶ 次が成り立つために  $n$  が満たす条件を見つけない

$$\Pr(|Y - p| \geq \varepsilon) \leq \delta$$

- ▶ 今までの議論から、任意の  $j \in \{1, \dots, 2k - 1\}$  に対して

$$\Pr(|Y_j - p| \geq \varepsilon) \leq \frac{1}{\varepsilon^2} \frac{p(1-p)}{t}$$

- ▶  $t \geq \frac{8p(1-p)}{\varepsilon^2}$  とすると、

$$\Pr(|Y_j - p| \geq \varepsilon) \leq \frac{1}{8}$$

## 中央値トリック：誤差の解析 (2)

- ▶ このとき,

$$\begin{aligned} & \Pr(k \text{ 個の } j \text{ に対して, } |Y_j - p| \geq \varepsilon) \\ & < \binom{2k-1}{k} \left(\frac{1}{8}\right)^k \leq \left(\frac{e(2k-1)}{k}\right)^k \left(\frac{1}{8}\right)^k < \left(\frac{2e}{8}\right)^k < \left(\frac{3}{4}\right)^k \end{aligned}$$

- ▶ したがって,

$$\begin{aligned} \Pr(|Y - p| \geq \varepsilon) & \leq \Pr(k \text{ 個の } j \text{ に対して, } |Y_j - p| \geq \varepsilon) \\ & < \left(\frac{3}{4}\right)^k \end{aligned}$$

- ▶  $k \geq \log_{3/4} \delta$  とすると

$$\Pr(|Y - p| \geq \varepsilon) < \left(\frac{3}{4}\right)^k \leq \delta$$

## 中央値トリック：誤差の解析 (まとめ)

## 中央値トリック：誤差の解析 (まとめ)

- ▶  $t \geq \frac{8p(1-p)}{\varepsilon^2}$ ,  $k \geq \log_{3/4} \delta$  とすると  
誤差が  $\varepsilon$  以上になる確率を  $\delta$  以下にできる
- ▶ このとき、硬貨を投げる回数  $n$  は

$$n = (2k - 1)t \geq \Omega \left( \frac{p(1-p)}{\varepsilon^2} \log \frac{1}{\delta} \right)$$

補足：単純なアルゴリズムにて、硬貨を投げる回数  $n$  は


$$n \geq \frac{p(1-p)}{\varepsilon^2} \frac{1}{\delta}$$

つまり、中央値トリックにより、硬貨を投げる回数が減った

## 実験してみた


- ▶ パラメータ
  - ▶  $p = 0.111111$
  - ▶  $2k - 1 = 9$
  - ▶  $t = 7901$
  - ▶  $n = (2k - 1)t = 71109$
- ▶ Ruby 2.1.4 で実装
- ▶ 5000 回動かして、推定した  $p$  の度数分布 (ヒストグラム) を見てみた
- ▶ 横軸が推定した  $p$  の値, 縦軸が度数 (頻度)

## 実験してみた：単純なアルゴリズム



平均 0.1111089, 標準偏差 0.0011736

## 実験してみた：中央値トリック



平均  $0.11111111$ , 標準偏差  $1.22541 \times 10^{-14}$  (つまり,  $0.0000000$ )

## 目次

- ① 確率の推定：単純なアルゴリズム
- ② 確率の推定：中央値トリック
- ③ 今日のまとめ

## 今日の目標

## 今日の目標

典型的な乱択アルゴリズムの設計と解析ができるようになる

- ▶ 確率の推定 (中央値トリック)

## 残った時間の使い方

- ▶ 演習問題をやる
  - ▶ 相談推奨 (ひとりでやらない)
- ▶ 質問をする
  - ▶ 教員と TA は巡回
- ▶ 退室時, 小さな紙に感想など書いて提出する ← 重要
  - ▶ 内容は何でも OK
  - ▶ 匿名で OK

## 目次

- ① 確率の推定：単純なアルゴリズム
- ② 確率の推定：中央値トリック
- ③ 今日のまとめ