

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

岡本 吉央 (電通大)

離散数理工学 (11)

2015 年 1 月 13 日

1 / 28

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

岡本 吉央 (電通大)

離散数理工学 (11)

2015 年 1 月 13 日

3 / 28

確率の推定：単純なアルゴリズム

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

岡本 吉央 (電通大)

離散数理工学 (11)

2015 年 1 月 13 日

5 / 28

確率の推定：単純なアルゴリズム

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

岡本 吉央 (電通大)

離散数理工学 (11)

2015 年 1 月 13 日

7 / 28

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)

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)

岡本 吉央 (電通大)

離散数理工学 (11)

2015 年 1 月 13 日

4 / 28

確率の推定：単純なアルゴリズム

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 (このみ)

岡本 吉央 (電通大)

離散数理工学 (11)

2015 年 1 月 13 日

6 / 28

確率の推定：単純なアルゴリズム

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

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

岡本 吉央 (電通大)

離散数理工学 (11)

2015 年 1 月 13 日

8 / 28

岡本 吉央 (電通大)

離散数理工学 (11)

2015 年 1 月 13 日

8 / 28

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 \rightarrow 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 (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 (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 (6)

すなわち、

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

▶ 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 δ 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 ε 以上になる確率を δ 以下にするためには、

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

とすればよい

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 ε 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 (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、

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

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

誤差の解析 (5)

ここまで、まとめると

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

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 ($i \in \{1, \dots, n\}$)

(標本確率変数)

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

▶ 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？

- 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：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きたい

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

- ▶ 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 (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 ε 以上になる確率を δ 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：単純なアルゴリズム



平均 0.1111089, 標準偏差 0.0011736

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 (2)

- ▶ このとき、
 $\Pr(k \text{ 個の } j \text{ に対して, } |Y_j - p| \geq \varepsilon)$
 $< \binom{2k-1}{k} \left(\frac{1}{8}\right)^k \leq \left(\frac{e(2k-1)}{k}\right)^k \left(\frac{1}{8}\right)^k < \left(\frac{2e}{8}\right)^k < \left(\frac{3}{4}\right)^k$
- ▶ したがって、


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

- ▶ $k \geq \log_{3/4} \delta$ とすると

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

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)



平均 0.1111111, 標準偏差 1.22541×10^{-14} (つまり, 0.0000000)

- 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

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)