

離散数理工学 第 10 回
離散確率論：乱択データ構造とアルゴリズム (基礎)

岡本 吉央
okamotoy@uec.ac.jp

電気通信大学

2015 年 1 月 6 日

最終更新：2015 年 1 月 6 日 17:10

岡本 吉央 (電通大)

離散数理工学 (10)

2015 年 1 月 6 日

1 / 26

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) |

岡本 吉央 (電通大)

離散数理工学 (10)

2015 年 1 月 6 日

2 / 26

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 (10)

2015 年 1 月 6 日

3 / 26

今日の目標

今日の目標

典型的な乱択アルゴリズムの解析ができるようになる

- ▶ 乱択クイックソート

岡本 吉央 (電通大)

離散数理工学 (10)

2015 年 1 月 6 日

4 / 26

目次

- 1 乱択アルゴリズム
- 2 乱択クイックソート
- 3 今日のまとめ

岡本 吉央 (電通大)

離散数理工学 (10)

2015 年 1 月 6 日

5 / 26

乱択アルゴリズム

乱択アルゴリズムの 2 つの側面

乱択アルゴリズムは乱数を使ってもよいので、振る舞いが確率的になる

類型その 1：モンテカルロ・アルゴリズム

- ▶ 実行時間は乱数によって変化しない
- ▶ 出力の正しさが乱数によって変化する (「正しさ」が確率変数)

注：「モンテカルロ法」は違う概念を指す名称なので注意

類型その 2：ラスベガス・アルゴリズム

- ▶ 実行時間が乱数によって変化する (「実行時間」が確率変数)
- ▶ 出力の正しさは乱数によって変化しない (つまり、常に正しい)

岡本 吉央 (電通大)

離散数理工学 (10)

2015 年 1 月 6 日

7 / 26

乱択アルゴリズム

乱択アルゴリズムとは？

乱数を用いる (あるいは、用いてもよい) アルゴリズムのこと

確率的アルゴリズム, 乱数使用アルゴリズムとも呼ばれる

なぜ乱数を用いるのか？

- ▶ アルゴリズムを設計しやすくなる
- ▶ アルゴリズムを解析しやすくなる
- ▶ 乱数を使わないとできないことが、乱数を使うとできる

岡本 吉央 (電通大)

離散数理工学 (10)

2015 年 1 月 6 日

6 / 26

乱択クイックソート

目次

- 1 乱択アルゴリズム
- 2 乱択クイックソート
- 3 今日のまとめ

岡本 吉央 (電通大)

離散数理工学 (10)

2015 年 1 月 6 日

8 / 26

ソーティング (整列問題) とは？

- ▶ 入力：異なる n 個の数から成る配列 $A = (a_1, a_2, \dots, a_n)$ (配列)
- ▶ 出力： A の並べ替え $A' = (a'_1, a'_2, \dots, a'_n)$ で、
 $a'_1 < a'_2 < \dots < a'_n$ を満たすもの

例： $A = (8, 3, 5, 1, 7, 9, 2, 4) \rightsquigarrow A' = (1, 2, 3, 4, 5, 7, 8, 9)$

アルゴリズムにおける基本的な問題

クイックソート

再帰によってソーティングを行うアルゴリズム (の1つ)

- 1 A から要素を1つ選択 (その要素を **ピボット** と呼ぶ)
- 2 A を3つの部分に分割
 - ▶ A_1 : ピボットよりも小さい要素から成る配列
 - ▶ p : ピボット
 - ▶ A_2 : ピボットよりも大きい要素から成る配列
- 3 A_1 と A_2 を再帰的に整列 (結果をそれぞれ A'_1, A'_2 とする)
- 4 A'_1 と p と A'_2 をこの順に連結して出力

- ▶ アルゴリズムの正当性は直ちに分かる
- ▶ ピボットの選択法, A_1, A_2 の作成法によって, 細かな実装が変わる

ピボットの選択法, A_1, A_2 の作成法によって, 細かな実装が変わる

よく使われるピボット選択法

- ▶ 配列の先頭の要素をピボットとする
- ▶ 配列の先頭の3要素の中央値をピボットとする
- ▶ 配列の中のランダムな要素をピボットとする (乱択アルゴリズム)
(各要素が選択される確率は同一 (一様分布に従う標本抽出))

乱択クイックソート (Ruby)

```

1: def quicksort(a)
2:   return nil.to_a if a.length == 0
3:   p = a.sample()
4:   a.delete(p)
4': a1 = Array.new(); a2 = Array.new()
5:   a.each { |e|
6:     print "G"
7:     e < p ? a1 << e : a2 << e
8:   }
9:   return quicksort(a1) + [p] + quicksort(a2)
10: end

```

X_A = 入力 A に対する乱択クイックソートの比較回数 (確率変数)

X_n = $\max\{X_A \mid |A| = n\}$ (確率変数)

- ▶ X_n が表すのは最悪時の比較回数を表す確率変数

目標

X_n が小さいこと (具体的には高確率で $O(n \log n)$ になること)

まず, $E[X_n]$ を考えてみる

- ▶ $E[X_0] = 0$

乱択クイックソート (適当な疑似コード)

```

1: def quicksort(A) # A: array of distinct numbers
2:   return nil if length(A) == 0
3:   p = a number in A chosen uniformly at random
4:   delete p from A
5:   foreach e in A {
6:     print "G"
7:     if e < p then add e to A1 else add e to A2
8:   }
9:   return quicksort(A1) + p + quicksort(A2)
10: end

```

評価尺度として, 以下のものがよく用いられる

- ▶ 比較回数：2要素の比較を行った回数
- ▶ 移動回数：要素を移動した回数
- ▶ 領域量：入力配列以外に用いた変数の数

ここでは, **比較回数**に注目 (比較回数 = 出力された G の個数)

- ▶ 乱択クイックソートにおいて,
比較回数は使用される乱数によって変わる (つまり, 確率変数)
 X_A = 入力 A に対する乱択クイックソートの比較回数 (確率変数)

$n \geq 1$ のとき, $X_n = X_A$ となるような入力 A を考えてみると

$$\begin{aligned}
 E[X_n] &= E[X_A] \\
 &= \sum_{i=1}^n E[X_A \mid a'_i \text{ がピボット}] \Pr[a'_i \text{ がピボット}] \\
 &\quad (\text{ただし, } a'_i \text{ は } A \text{ の中で } i \text{ 番目に小さい要素}) \\
 &= \sum_{i=1}^n E[X_A \mid a'_i \text{ がピボット}] \frac{1}{n}
 \end{aligned}$$

ここで, a'_i がピボットであるとき

- ▶ $|A_1| = i - 1, |A_2| = n - i$
- ▶ $\therefore X_{A_1} \leq X_{i-1}$ かつ $X_{A_2} \leq X_{n-i}$

したがって,

$$E[X_n] \leq \sum_{i=1}^n (n - 1 + E[X_{i-1}] + E[X_{n-i}]) \frac{1}{n} = n - 1 + \sum_{i=0}^{n-1} \frac{2}{n} E[X_i]$$

$E[X_n]$ に関して得られた漸化式

$$E[X_0] = 0$$

$$E[X_n] \leq n-1 + \sum_{i=0}^{n-1} \frac{2}{n} E[X_i] \quad (n \geq 1)$$

ここで、次の漸化式を満たす数列 $\{t_n\}_{n \geq 0}$ を考える

$$t_0 = 0$$

$$t_n = n-1 + \sum_{i=0}^{n-1} \frac{2}{n} t_i \quad (n \geq 1)$$

▶ このとき、任意の $n \geq 0$ に対して

$$E[X_n] \leq t_n$$

となる (演習問題)

▶ つまり、 t_n の上界が分かれば、 $E[X_n]$ の上界となる

整理すると、 $n \geq 1$ のとき、

$$(n+1)t_{n+1} = 2n + (n+2)t_n$$

両辺を $2(n+1)(n+2)$ で割ると、 $n \geq 1$ のとき、

$$\frac{t_{n+1}}{2(n+2)} = \frac{n}{(n+1)(n+2)} + \frac{t_n}{2(n+1)}$$

ここで、 $s_n = \frac{t_n}{2(n+1)}$ と置くと、得られる漸化式は

$$s_0 = \frac{t_0}{2(0+1)} = 0$$

$$s_1 = \frac{t_1}{2(1+1)} = 0$$

$$s_{n+1} = \frac{2}{n+2} - \frac{1}{n+1} + s_n \quad (n \geq 1)$$

解けそうな形に近づいてきた

したがって、 $n \geq 0$ に対して、

$$s_n = H_{n+1} + \frac{1}{n+1} - 2$$

したがって、 $n \geq 0$ に対して、

$$t_n = 2(n+1)s_n = 2(n+1)H_{n+1} + 2 - 4(n+1)$$

したがって、

$$E[X_n] \leq t_n = 2(n+1)H_{n+1} + 2 - 4(n+1)$$

$H_{n+1} \leq 1 + \ln(n+1)$ なので (前回の演習問題)

$$\begin{aligned} E[X_n] &\leq 2(n+1)(1 + \ln(n+1)) + 2 - 4(n+1) \\ &= 2(n+1)\ln(n+1) - 2n = O(n \log n) \end{aligned}$$

① 乱択アルゴリズム

② 乱択クイックソート

③ 今日のまとめ

$$t_n = n-1 + \sum_{i=0}^{n-1} \frac{2}{n} t_i \quad (n \geq 1)$$

第2式において、添え字をずらしたものを考えると

$$t_{n+1} = n + \sum_{i=0}^n \frac{2}{n+1} t_i \quad (n \geq 0)$$

第2式と第3式を変形すると

$$nt_n = (n-1)n + \sum_{i=0}^{n-1} 2t_i \quad (n \geq 1)$$

$$(n+1)t_{n+1} = n(n+1) + \sum_{i=0}^n 2t_i \quad (n \geq 0)$$

下から上を引くと、 $n \geq 1$ のとき、

$$(n+1)t_{n+1} - nt_n = 2n + 2t_n$$

$n \geq 2$ のとき、

$$\begin{aligned} s_n &= \frac{2}{n+1} - \frac{1}{n} + s_{n-1} \\ &= \left(\frac{2}{n+1} - \frac{1}{n} \right) + \left(\frac{2}{n} - \frac{1}{n-1} \right) + s_{n-2} \\ &= \left(\frac{2}{n+1} - \frac{1}{n} \right) + \left(\frac{2}{n} - \frac{1}{n-1} \right) + \cdots + \left(\frac{2}{3} - \frac{1}{2} \right) + s_1 \\ &= \frac{2}{n+1} + \frac{1}{n} + \frac{1}{n-1} + \cdots + \frac{1}{3} - \frac{1}{2} \\ &= \frac{1}{n+1} + H_{n+1} - \frac{1}{2} - 1 - \frac{1}{2} \\ &= H_{n+1} + \frac{1}{n+1} - 2 \end{aligned}$$

復習: $H_{n+1} = 1 + \frac{1}{2} + \cdots + \frac{1}{n+1}$ (調和数)

ここまでで分かったこと

任意の $n \geq 0$ に対して、 $E[X_n] \leq 2(n+1)\ln(n+1)$

したがって、マルコフの不等式を適用してみると

$$\begin{aligned} \Pr[X_n \geq 24(n+1)\ln(n+1)] &\leq \frac{E[X_n]}{24(n+1)\ln(n+1)} \\ &\leq \frac{2(n+1)\ln(n+1)}{24(n+1)\ln(n+1)} \\ &= \frac{1}{12} \end{aligned}$$

- ▶ つまり、比較回数が $24(n+1)\ln(n+1)$ を超える確率は高くない
- ▶ 「チェルノフ上界の技法」を用いると、 $n \rightarrow \infty$ のとき、この確率が 0 に収束することを証明できる (ちょっと面倒で、他のアイデアも必要なので、省略)

今日の目標

典型的な乱択アルゴリズムの解析ができるようになる

▶ 乱択クイックソート