



Title	定数時間アルゴリズム：性質検査と定数時間近似
Author(s)	伊藤, 大雄
Citation	2010年度科学技術振興機構ERATO湊離散構造処理系プロジェクト講究録. p.287-290.
Issue Date	2011-06
Doc URL	<a href="http://hdl.handle.net/2115/48416">http://hdl.handle.net/2115/48416</a>
Type	conference presentation
Note	ERATO 湊離散構造処理系プロジェクト春のワークショップ（キックオフシンポジウム）. 2010年5月28日（金）～29日（土）. ERATO湊プロジェクト研究室.
File Information	02.ito_06.pdf



[Instructions for use](#)

## 定数時間アルゴリズム 一性質検査と定数時間近似一

伊藤大雄  
京都大学 大学院 情報学研究所

2010.5.28  
第1回 湊離散構造処理系シンポジウム

湊離散構造処理系 2010.5.28

1

## 決定問題と最適化問題

- 決定問題の例：連結性判定問題
  - 入力：グラフG
  - 要請：Gが連結であるか判定せよ (YesかNoか)
- 最適化問題の例：最大マッチング問題
  - 入力：グラフG
  - 要請：Gのマッチングの最大サイズを求めよ (数値)
- 一般的要請：入力長 $n$ に対し、計算時間 $T(n)$ がなるべく小さいアルゴリズムを設計せよ。

湊離散構造処理系 2010.5.28

2

## 定数時間アルゴリズムとは

- これまでの常識：入力をすべて見なければ話にならない。つまり  $T(n) = \Omega(n)$ .
- しかし、一部を見るだけで、判断できないか？
  - e.g., モンテカルロ法、サンプリング調査、料理の味見...
- $n$ に無関係の定数個のデータを見るだけで判断！
  - つまり  $T(n) = O(1)$ .
  - 理論的保証。(ヒューリスティクスでは無い。)
  - 確率アルゴリズム。
  - ウェブグラフ、ゲノムなど超巨大情報が簡単に扱える。



湊離散構造処理系 2010.5.28

3

## 性質検査(property testing)

- 判定問題(YesかNoか)の緩和→性質検査(property testing)
- 例えば、 $n$ 個の節点、 $m$ 本の枝からなるグラフが連結であることを、 $n, m$ に無関係な定数個のデータを見るだけで検査する。
- 直感的には「不可能」。(見ていない所に枝が1本あるだけで、結果が変わる。)
- 多少の不正確さを許容することで、可能にする。

湊離散構造処理系 2010.5.28

4

## 性質検査の考え方

- 考え方1：大まかな区別がつけば良い



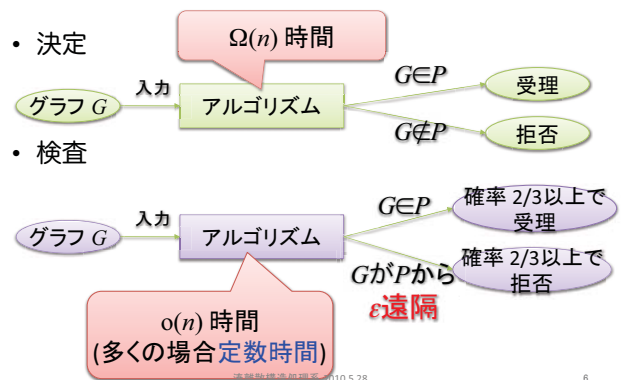
この両者を区別

- 考え方2：確率的に判定
  - (任意の入力に対し)確率 $2/3$ 以上で正解を出す。

湊離散構造処理系 2010.5.28

5

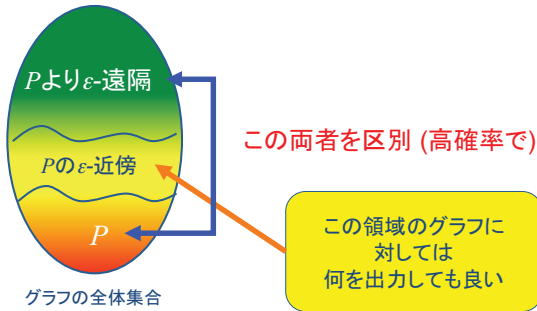
## 決定アルゴリズムと検査アルゴリズム



湊離散構造処理系 2010.5.28

6

## 検査アルゴリズムの目的



淡路散構造処理系 2010.5.28

7

## 検査アルゴリズムの実用上の意味

- 一部を見て全体の性質を推定することは、実用上多い。
  - プログラムのチェック、視聴率調査、料理の味見。
- 大規模な対象物の性質を調べる時、事前に検査アルゴリズムを実行する。その結果、
  - $\epsilon$ -遠隔  $\Rightarrow$  終了。
  - その他  $\Rightarrow$  (通常)の判定アルゴリズムを適用。

大幅な時間削減が可能！

淡路散構造処理系 2010.5.28

8

## グラフGと性質Pの距離

- $\Gamma_n$ : 考慮するグラフの全体集合 (ただし  $n$  節点)
- $G, G' \in \Gamma_n$  の距離:
- $\text{dist}(G, G') := G$  を  $G'$  に変形するために、操作(追加または削除)しなければならない枝の割合 ( $\therefore 0 \leq \text{dist}(G, G') \leq 1$ )。
- グラフ  $G$  と性質  $P$  の距離:
- $\text{dist}(G, P) := \min \{ \text{dist}(G, G') \mid G' \in P \}$
- $G$  が  $P$  より  $\epsilon$ -遠隔  $\Leftrightarrow \text{dist}(G, P) \geq \epsilon$ . (ただし  $0 < \epsilon \leq 1$ )

淡路散構造処理系 2010.5.28

9


## グラフの表現法 1 :

隣接行列モデル (Adjacency Matrix Model)

- 密なグラフに使用
- グラフは隣接行列  $g(i, j)$ ,  $i, j \in \{1, \dots, n\}$  で表現

$$g(i, j) = \begin{cases} 1 & ((i, j) \in E) \\ 0 & ((i, j) \notin E) \end{cases} \quad (i, j \in \{1, \dots, n\})$$

- 例:



	n			
	1	2	3	4
1	0	0	1	1
2	1	0	0	0
3	0	0	0	1
4	0	1	0	0


淡路散構造処理系 2010.5.28

10

## グラフの表現法 2 :

次数制限モデル (Bounded Degree Model)

- 疎なグラフに使用。
- $\Gamma_n$  は次数上限  $d$  の制限を持つ ( $d$  は整数)。
- グラフは節点  $i$  の  $p$  番目の隣接節点を表す行列  $g(i, p)$ ,  $i \in \{1, \dots, n\}$ ,  $p \in \{1, \dots, d\}$  で表現。該当節点が存在しないときは0を返す。
- 例: ( $d=2$ )



淡路散構造処理系 2010.5.28

11

## 次数制限モデルの下での グラフ間の距離

- $\text{dist}(G, G') := G$  を  $G'$  に変形するために、操作(追加または削除)しなければならない枝の割合
- $:= (G$  を  $G'$  に変形するために、操作しなければならない枝の数) /  $(dn/2)$



- $G$  が性質  $P$  から  $\epsilon$ -遠隔  $\Leftrightarrow G$  を (次数上限を満たしつつ)  $P$  を満足するようにするために少なくとも  $\epsilon dn/2$  本の枝の操作が必要。

淡路散構造処理系 2010.5.28

12

## 連結性の検査

定理1: 次数制限モデルの下で、与えられたグラフ $G$ が連結であることを検査する, i.e.,

- $G$ が連結ならば確率 $2/3$ 以上で受理し、
- 連結から $\epsilon$ 遠隔ならば、確率 $2/3$ 以上で拒否する

$O(1/\epsilon^2 d)$ 時間アルゴリズムが存在する。

淡輪散構造処理系 2010.5.28

13

## 連結から $\epsilon$ 遠隔であるグラフの性質

• 補題2: 連結から $\epsilon$ 遠隔なグラフには、少なくとも $\epsilon dn/6$ 個の連結成分が存在する。□




• 補題3: 連結から $\epsilon$ 遠隔なグラフには、**サイズが高々 $12/\epsilon d$ の連結成分が少なくとも $\epsilon dn/12$ 個存在する。**(証明: 補題2+連結成分は互い素であること。) □

淡輪散構造処理系 2010.5.28

14

## 非連結性の証拠

- 補題3より、 $\epsilon$ 遠隔なグラフには、**小さな**( $\leq 12/\epsilon d$ )連結成分が**多数**( $\geq \epsilon dn/12$ )存在する。
- そのうちの一つでも見つけることができれば、 $G$ が非連結であることが判明する。



淡輪散構造処理系 2010.5.28

15

## 連結成分を如何に見つけるか

- 無作為に節点 $v$ を選べば、
- $\Pr(v \in \text{小さな連結成分}) \geq (\epsilon dn/12)/n = \epsilon d/12$
- 無作為に  $24/\epsilon d$  個節点を選べば、少なくとも一つが小さな連結成分に入っている確率が高い。
- 節点の回りを探索することで、その節点が小さな( $\leq 12/\epsilon d$ )連結成分に入っているか否かを、定数時間( $O(1/\epsilon d) \cdot d = O(1/\epsilon)$ )で確認できる。

$$\begin{aligned} & 1 - (1 - \epsilon d/12)^{24/\epsilon d} \\ & > 1 - (e^{-\epsilon d/12})^{24/\epsilon d} \\ & = 1 - e^{-2} > 6/7 \end{aligned}$$

淡輪散構造処理系 2010.5.28

16

## 連結性検査アルゴリズム

- 無作為に  $24/\epsilon d$  個節点を選ぶ。
- 選ばれた各節点 $v$ のまわりを (BFS等で)  $12/\epsilon d + 1$  歩まで探索する。
- どれか一つの $v$ でも、上記の探索を終えることができなければ、「拒否」を出力し、終了。そうでなければ「受理」を出力し終了。
- 計算時間: 一つのBFSは $O(d/\epsilon d) = O(1/\epsilon)$ 時間で行える。従ってアルゴリズム全体で $O(1/\epsilon^2 d)$ 時間。
- 注意: 連結なグラフは常に(=確率1で)受理される。(1-sided error)

淡輪散構造処理系 2010.5.28

17

## 定数(準線形)時間近似


- 最適化問題の検査版 (近似解を算出)
- 最小化問題の $(\alpha, \epsilon n)$ 近似とは、最適解の値をOPTとすると
- $\text{OPT} \leq \text{ALG} \leq \alpha \text{OPT} + \epsilon n$
- である解ALGを求める。
- 最大化問題なら
- $\text{OPT}/\alpha - \epsilon n \leq \text{ALG} \leq \text{OPT}$

淡輪散構造処理系 2010.5.28

18

### なぜ定数時間で近似できるのか？

- 解の範囲が $\{1, \dots, n\}$ の場合、それらをすべて区別するためには $\Omega(\log n)$ の計算が必要。
- しかし $\epsilon n$ の絶対誤差を許せば、解の範囲を $\epsilon n$ 毎に刻むことになり、 $n/\epsilon n = 1/\epsilon$ 通りの区別ができれば良い。→定数時間でできる可能性。



グラフの全体集合 淡路散構造処理系 2010.5.28

### 定数時間近似の枠組み

- 関数  $f(v)$  に対して  $f(G) = \sum_{v \in V} f(v)$  を計算したい。
- (例: 枝の数  $m = \sum_{v \in V} \frac{d_v}{2}$ )

- 頂点を一様ランダムに  $s$  個サンプリング  $\rightarrow S$
- $\forall v \in S$  に対して  $f(v)$  を計算。
- $\tilde{f}(G) = \frac{n}{s} \sum_{v \in S} f(v)$  を出力。

- $0 \leq f(v) \leq w$  であれば  $s = O(w^2/\epsilon^2)$  とすると、高い確率で  $|f(G) - \tilde{f}(G)| \leq \epsilon n$  となる。
- (Hoeffdingの不等式より)

### Hoeffding's Inequality

- $X_1, \dots, X_N$ :
  - indep. rand. vars.,
  - $\Pr(X_i - E[X_i] \in [a_i, b_i]) = 1$  for  $1 \leq i \leq N$ , i.e., a. s. bound.
  - Let  $S = X_1 + \dots + X_N$ .

- Then for any  $t > 0$  we have

$$\Pr(|S - E[S]| \geq t) \leq 2 \exp\left(-\frac{2t^2}{\sum_{i=1}^N (b_i - a_i)^2}\right).$$

- If  $t = \epsilon N, N = cd^2/2\epsilon^2$ , then

$$\Pr(|S - E[S]| \geq N\epsilon) \leq 2 \exp\left(-\frac{2\epsilon^2 N^2}{Nd^2}\right) = 2 \exp(-c).$$

### 定数時間近似の枠組み

- 頂点を一様ランダムに  $s$  個サンプリング  $\rightarrow S$
- $\forall v \in S$  に対して  $f(v)$  を計算。
- $\tilde{f}(G) = \frac{n}{s} \sum_{v \in S} f(v)$  を出力。

- この枠組み自体は定数時間で作動する。
- よって、もし  $f(v)$  が高い確率で定数時間で十分な精度で計算可能ならば、全体として定数時間で近似できる。
- ローカルサーチ、貪欲算法、枝刈り…解析法

### 我々の主な成果

- 性質検査
  - $k$ -点連結性検査:  $O\left(d \left(\frac{ck}{\epsilon d}\right)^k \log\left(\frac{k}{\epsilon d}\right)\right)$  時間 ICALP 2008
  - グラフの外平面性検査:  $\tilde{O}\left(\frac{1}{\epsilon^{13} d^6} + \frac{d}{\epsilon^2}\right)$  時間 [submitted]
  - 3辺彩色、3次元マッチング、有向・無向ハミルトン(閉)路、Schaeferの3SATが $\Omega(n)$ 時間必要。[EICE2010]
- 定数時間近似
  - 最小頂点被覆、最大マッチングの $(2, \epsilon)$ 近似:  $O(d^4/\epsilon^2)$ 時間 STOC 2009
  - 最大マッチングの $(1, \epsilon)$ 近似:  $d^{O(1/\epsilon^2)} (1/\epsilon)^{O(1/\epsilon)}$  時間

### まとめ

- データの一部(定数個)しか見ずに対象の性質を検査したり、解を近似したりする手法がある。
- 確率的な解答(確率2/3以上で正答する)と「 $\epsilon x$ (解の範囲)」の絶対誤差を許すことで実現している( $\epsilon > 0$ は任意の定数)。
- ウェブグラフやゲノム情報などの大規模なデータを扱う際に有効。
- 近年のホットな研究テーマであり、様々な性質や関数が検査・近似可能であることが分かっている。