

大規模2部グラフに対する 極大クリーク列挙アルゴリズムの改良と実装

宇野 毅明

国立情報学研究所 〒101-8430 東京都千代田区一ツ橋 2-1-2 e-mail: uno@nii.jp

抄録: グラフ $G = (V, E)$ の頂点集合 S に対して, 任意の S の頂点間に枝が張られているとき S をクリークとよぶ. また, 2部グラフ $G = (V_1 \cup V_2, E)$ の頂点集合 S に対して, 任意の S の頂点 $v_1 \in V_1$ と $v_2 \in V_2$ に対して枝が張られているならば S を2部クリークとよぶ. 本稿では, 巨大で疎なグラフの集合の意味で極大なクリークと極大な2部クリークを列挙する, 実用的に高速なアルゴリズムを提案する. グラフの次数を Δ とすると, 本稿の改良により, 極大クリーク1つあたりの計算時間が $O(|V||E|)$ から $O(\Delta^4)$ に, 極大2部クリークは $O(|V||E|)$ から $O(\Delta^3)$ に改善された. さらに, 計算機実験により, ある程度ランダムな入力に対しては, 1つあたり $O(\Delta^2)$ 時間程度しかかからないことを示す.

A Practical Fast Algorithm for Enumerating Cliques in Huge Bipartite Graphs and Its Implementation

Takeaki Uno

National Institute of Informatics

2-1-2 Hitotsubashi, Chiyoda-ku, Tokyo 101-8430, JAPAN, e-mail: uno@nii.jp

Abstract: A vertex subset of a graph $G = (V, E)$ is called a clique if any two vertices of S are connected by an edge. A vertex subset of a bipartite graph $G = (V_1 \cup V_2, E)$ is called a bipartite clique if any two vertices $v_1 \in V_1$ and $v_2 \in V_2$ are connected by an edge. In this paper, we propose a practical fast enumeration algorithm for maximal cliques and bipartite maximal cliques of huge sparse graphs. The time complexity per maximal clique is reduced from $O(|V||E|)$ to $O(\Delta^4)$, and that of maximal bipartite cliques is reduced from $O(|V||E|)$ to $O(\Delta^3)$. By computational experiments, we show that the algorithm takes $O(\Delta^2)$ in random instances.

1 はじめに

グラフ $G = (V, E)$ に対して, V の部分集合 S で, 任意の2つの頂点 $v_1, v_2 \in V$ の間に枝がある, つまり $(v_1, v_2) \in E$ であるようなものを G のクリークとよぶ. G が2つの V_1, V_2 により構成される2部グラフである場合, 任意の2つの頂点 $v_1 \in V_1, v_2 \in V_2$ に対して $(v_1, v_2) \in E$ であるようなものを, G の2部クリーク, あるいは単にクリークとよぶ. 集合の意味で極大なクリークを極大クリーク (極大2部クリーク) とよぶ. クリークは, グラフ論の中でも基礎的なものであり, 最適化問題を含め多くの研究がなされている.

クリークは, 他の分野での応用も多い. データマイニングやネットワーク・計算言語学モデルの分野では, データセットの対応, コンピューターネットワーク, 異種言語の意味的な対応を表すグラフなどから極大クリークを見つけ出し, 対象となるデータを分析しようという試みが多く行われてきている. クリークは, 関連の大きいデータの集合を表すなど, 自然なモデル化に基づいて導き出されるものだからである.

最近のデータマイニングやネットワーク・言語学モデル, グラフマイニングなどの分野では, 列挙を行う必要性が高まっている [4, 1, 2]. 例えばグラフマイニングでの, 入力されたグラフの中で頻出する部分グラフを求める問題などは, 本質的に列挙を行うことにより求解を行うアルゴリズムが多い. しかし, 列挙自体に時間がかかるようでは, 列挙という手法を用いるモチベーションが低くなる. 例えばウェブネットワークの中からコミュニティを見つけ出す [4] の研究では, 非常に大規模なグラフの極大クリークを列挙に挑戦しているが, 列挙に時間がかかりすぎるため, モデルを簡易化することで, 擬似的に問題を解いている. これら大規模なデータは, 疎であることが多い. そこで, 疎であることを上手に高速アルゴリズムを開発すれば, これらの研究を前進させることにつながるであろう.

グラフ G の極大クリークは, G の補グラフでは極大安定集合になる. 安定集合とは, 任意の 2 つの頂点間に枝がないような頂点集合のことである. 極大安定集合の列挙問題に対しては, 1977 年に Tsukiyama, Ide, Ariyoshi, Shirakawa [5] によって出力多項式時間アルゴリズムが提案されている. 出力多項式時間であるとは, 入力と出力の大きさに対する多項式時間であるということである. 時間計算量は出力される極大安定集合 1 つあたり $O(|V||E|)$ である. このアルゴリズムを用いれば, 極大クリークも 1 つあたり $O(|V||E|)$ 時間で列挙できる. しかしグラフが巨大になると, 計算時間は極端に大きくなる. 本研究では, このアルゴリズムに, グラフが疎であることに基づいた改良を加えることにより, 時間計算量を解 1 つあたり, 極大クリークは $O(\Delta^4)$, 極大 2 部クリークは $O(\Delta^3)$ に下げた. これにより, 解 1 つあたりの計算時間は頂点数・枝数に依存しなくなり, 大規模ネットワークでの大幅な高速化が期待される. さらに, 計算実験により, 平均的な計算時間は $O(\Delta^2)$ 程度であることを実証した.

2 基本アルゴリズム

この節では, [5] のアルゴリズムを簡単に説明する. まず入力グラフであるが, グラフが疎である場合を主に考えるので, グラフは頂点の隣接リストで表現されるとする. つまり各頂点について, その頂点に隣接する頂点のリストがあるとする. $V = \{v_1, \dots, v_n\}$ とし, G に対して G_i を頂点集合 $\{v_1, \dots, v_i\}$ によって誘導される部分グラフとする. 頂点集合 S がグラフ G_i の極大クリークであるとき, S を i 極大クリークとよぶ. [5] のアルゴリズムは, 1 極大クリークから $|V|$ 極大クリークまでのすべての i 極大クリークを列挙するものである. 頂点集合 S に対し, S の全ての頂点と隣接する頂点の集合を $N(S)$ とする. また, クリーク S に対して,

・ S に加えても S がクリークであるような頂点の中で, 最小添え字な頂点を, 添え字が i 以下であれば, S に加える

という作業を S が極大になるまで繰り返して得られる頂点集合を $X^*(i, S)$ と表記する. これは, $N(S)$ の最小添え字頂点を追加していることになる.

i 極大クリーク S に対して, S の親 $p(S, i)$ を以下の $i-1$ 極大クリークで定義する.

$$p(S, i) = \begin{cases} S & \text{if } v_i \notin S \\ X^*(i-1, S \setminus \{v_i\}) & \text{if } v_i \in S \end{cases}$$

1 極大クリーク $\{v_1\}$ 以外の全ての i 極大クリークに唯 1 つ親が定義され, かつ, i 極大安定集合の親は $i-1$ 極大安定集合であることから, この親子関係をグラフで表現すると, $\{v_1\}$ を根とする根付き木になる. この木を深さ優先探索し, すべての i 極大クリークを列挙する. 深さ優先探索を行うのに, この木全体をメモリに蓄える必要はない. ある i 極大クリークの子供を見つけるアルゴリズムを用いて, 現在訪れている頂点の子供に対して, 再帰呼び出しをする, という方法を用いればよい.

次に, i 極大クリーク S の子供を求める方法を説明する. S' を, $S = p(S', i+1)$ が成り立つような $i+1$ 極大クリークとする. $\bar{X}(S, v)$ を S に v を加え, v に隣接する頂点をすべて取り除いて得られる頂点集合とすると, $p(i, S)$ の定義より,

$$S' = \begin{cases} S & \text{if } v_i \notin S' \\ \bar{X}(S, v_{i+1}) & \text{if } v_i \in S' \end{cases}$$

が成り立つ. よって, S の子供は S 自身が $\bar{X}(S', v_{i+1})$ の高々2つである.

もし $S \cup \{v_{i+1}\}$ がクリークであれば, $S \cup \{v_{i+1}\} = \bar{X}(S, v_{i+1})$ であり, $p(S, i+1) = S$ である. よって, $S \cup \{v_{i+1}\}$ は S の子供である. もし $S \cup \{v_{i+1}\}$ がクリークでなければ, S は $i+1$ 極大クリークである. $p(S, i+1) = S$ となるので, これは S の子供になる. これらの子供を S の type 1 の子供とよぶ. 任意の i 極大クリークは, $i < |V|$ であれば, 必ず type 1 の子供を持つ. もし $S \cup \{v_{i+1}\}$ がクリークでない場合は, $\bar{X}(S, v_{i+1})$ が type 1 でない子供になりうる. これを type 2 の子供とよぶ. $\bar{X}(S, v_{i+1})$ が $i+1$ 極大クリークであり, かつ $p(\bar{X}(S, v_{i+1}), i+1) = S$ であれば, $\bar{X}(S, v_{i+1})$ は S の子供になる. type 2 の子供は必ず存在するとは限らない. $\bar{X}(S, v_{i+1}), X^*(i-1, S \setminus \{v_i\})$ とともに $O(|S|\Delta)$ 時間で求められるで, $|S| \leq \Delta$ より, S の子供は $O(\Delta^2)$ 時間で求められる.

任意の i 極大クリークから type 1 の子供を最低 $|V|$ 回たどると G の極大クリークに到達する. よって, 極大クリーク 1 つあたりの計算時間は $|V|$ 回の反復の計算時間となり, $O(|V|\Delta^2)$ となる. もう少し詳しく解析すると, 極大クリーク 1 つあたりの計算時間は $O(|V||E|)$ となる.

3 改良アルゴリズム

Tsukiyama らのアルゴリズムの計算時間は, 巨大なグラフでは大きくなる. このアルゴリズムの計算時間を, 初期化の計算時間を除き, 度数のみに依存する形にしたのが本研究の結果である. 以下で, その改良を説明する.

改良の基本的な方針は, 反復と type 2 子供の存在の確認を省略することである. v_{i+1} が S のどの頂点にも隣接していないとする. この場合, $\bar{X}(S, v_{i+1}) = \{v_{i+1}\}$ となる. そこで, これら 1 頂点のみからなる i 極大クリークのみを別口で発生させ, その子孫を深さ優先探索することにすれば, これら 1 頂点のみからなる i 極大クリークが子供となる場合は, 探索の必要がなくなる. すると, 頂点 v_{i+1} が S に隣接する場合のみ type 2 子供の生成を行えばよい.

また, ある i 極大クリーク S に対して, type 1 の子供を再帰的に生成して得られる極大クリークは $X^*(|V|, S)$ である. よって, $X^*(|V|, S)$ を生成することにより, type 1 の子供を作成する再帰を省略し, 一気に最下層の反復まで到達できる. これは $O(\Delta^2)$ 時間でできる.

上記の議論から, これら省略された反復の中で, $\bar{X}(S, v_j)$ が生成する必要のある type 2 の子供であるならば, v_j は S の添え字が j 以下の頂点と隣接する. ゆえに, 以下で定める $J(S, i)$ の頂点についてのみ, type 2 の子供の処理を行えばよい. i 極大クリーク S に対して, $X^*(|V|, S)$ の頂点 v_j に隣接する添え字が j 以上かつ i 以上である $X^*(|V|, S)$ の頂点の頂点を集めたりすと $J(S, i)$ とする.

以上より, Tsukiyama らのアルゴリズムと同等なものが

- (1) $X^*(|V|, S)$ を求め, 出力する
- (2) $J(S, i)$ を求める
- (3) 添え字の大きい順に $J(S, i)$ の頂点を取出し, その頂点が type 2 子供を生成すれば再帰呼出しという手続きにより実現できる.

(1), (2) にかかる時間, および (3) での繰り返し数は $O(\Delta^2)$, (3) での type 2 子供の生成は $O(\Delta^2)$ 時間であるので, 計算時間の合計は $O(\Delta^4)$ となる. よって, この改良の結果, 極大クリークひとつあたりの計算時間は $O(\Delta^4)$ に短縮された.

以下に, この改良アルゴリズムを示す. 以下では, 頂点集合は添え字順にソートされたリストで保持するものとし, リスト L の末尾の頂点を $l(L)$ と表記する. L が空の場合 $l(L)$ には v_{-1} という架空の頂点が入るものとする.

Procedure ENUM_MAXIMAL_CLIQUe_ITER(i 反復の深さ, S : i 極大クリーク)

(EMC1) $J := J(S, i)$, $S := X^*(|V|, S)$ とし, $N(S)$ を更新し, S を出力する

(EMC2) $v_j := l(J)$, $v_h := l(S)$ とする

(EMC3) **If** $j, h \leq i$ **then return**

(EMC4) **If** $h > j$ **then** $S := S \setminus \{v_h\}$

(EMC5) **Else**

(EMC6) $J := J \setminus \{v_j\}$, $S' := \bar{X}(S, v_{i+1})$

(EMC7) **If** $N(S') = \emptyset$ **then**

(EMC8) $S' := X^*(i, S' \setminus \{v_j\})$

(EMC9) **If** $S' = S$ **then** ENUM_MAXIMAL_CLIQUe_ITER(S', j); **End if**

(EMC10) **End if**

(EMC11) **End if**

(EMC12) **Go to** (EMC2)

Procedure ENUM_MAXIMAL_CLIQUe_MAIN($G = (V, E)$)

(EMCM1) **For** $i := 1$ **to** $|V|$

(EMCM2) **If** v_i に隣接する任意の頂点の添え字が i 以上 **then**

(EMCM3) ENUM_MAXIMAL_CLIQUe_ITER($\{v_i\}, i$)

(EMCM4) **End for**

4 2部極大クリーク列挙の高速化

この節では, グラフ $G = (V = V_1 \cup V_2, E)$ の極大2部クリークを列挙するアルゴリズムの改良を説明する. 簡単のため, V_1 のすべての頂点に隣接する V_2 の頂点, および V_2 のすべての頂点に隣接する V_1 の頂点は存在しないとする. 以下では, 頂点の添え字は V_1 の頂点が $1, \dots, |V_1|$ であり, V_2 の頂点が $|V_1| + 1, \dots, |V_1| + |V_2|$ という条件を満たすとする. この条件は本質的であり, この条件が満たされていないと成り立たない議論が存在することを注意しておく. また, 以下では特に断らない限り $i > |V_1|$ であるとする.

グラフ G の2部クリークは, V_1 と V_2 がクリークになるように枝を追加したグラフ, つまり $(V_1 \cup V_2, E \cup V_1 \times V_1 \cup V_2 \times V_2)$ のクリークと対応する. よって, G の極大2部クリークの列挙はこのグラフの極大クリークの列挙により行える. しかし, この方法は今回の研究対象のような疎なグラフに対しては歓迎されない. 枝の追加によりグラフが極めて密になるからである.

このような枝の追加を, 実際に実際に行わず, 仮想的に行ったとしても計算時間は短縮されない. なぜならば, 上記アルゴリズムの計算時間は最大次数に依存し, このグラフの最大次数は $|V_1|, |V_2|$ より大きくなるからである. これでは速度の向上は見込めない.

さらにもう1つ問題がある. それは, 任意の部分グラフ G_i に対して, $i \leq |V_1|$ であれば $\{1, \dots, i\}$, $i > |V_1|$ であれば $\{1, \dots, |V_1|\}$ と $\{|V_1| + 1, \dots, i\}$ は, それぞれ i 極大2部クリークになるということである. これらを自明なクリークとよぶ. 自明なクリークは頂点数が大きく, 計算に多大な時間を要する. 自明なクリークが子供の候補として現れることにより, 多くの計算時間を必要としてしまう.

本研究での改良は、上記一般のクリーク用の改良を2部クリーク用に焼きなおしたこと、自明なクリークを列挙せず、それらに関わる計算を省略したことにある。

頂点集合 S に対して、 $S_1 = S \cap V_1, S_2 = S \cap V_2$ とする。 i 極大2部クリーク S に対して、

$$N(S_1) = S_2, N(S_2) = S_1$$

が成り立つことを注意しておく。特に断らない限り、 i 極大2部クリークは自明でないクリークを指すとする。

i 極大2部クリークを G_i の極大2部クリークで定義する。任意の i 極大2部クリーク S に対して、 $X^*(i, S)$ と $p(S, i)$ を i 極大クリークに対する定義と同じ定義で定める。

$$X^*(i, S) = S \cup N(S_2) \cup N(S_1 \cup N(S_2)) \cap \{1, \dots, i\}$$

であることを注意しておく。 i 極大クリークと同様、 i 極大2部クリーク S は type 1 の子供を1人必ず持ち、そのほかに高々1人の type 2 子供を持つ。この親子関係は $|V_1|$ 極大2部クリーク V_1 を根とする木を構成する。

i 極大2部クリーク S に対して、 $\bar{X}(S, v_{i+1})$ を S から v に隣接しない S_1 の頂点を取り除き、 v を加えて得られる2部クリークとする。 S' が S の type 2 の子供であれば、 $S' = \bar{X}(S, v_{i+1})$ が成り立つ。 $N(\bar{X}(S, v_{i+1}) \setminus \{v_{i+1}\}) = S_1$ であることから、

$$X^*(i, \bar{X}(S, v_{i+1}) \setminus \{v_{i+1}\}) = S$$

が必ず成り立つ。よって、 $\bar{X}(S, v_{i+1})$ が $i+1$ 極大クリークであれば、またそのときに限り、 $\bar{X}(S, v_{i+1})$ は S の type 2 子供となる。

自明な i 極大クリークの計算を省略するため、その親子がどのようになるか考察する。 i 極大クリーク S に対して、 S の子供 S' は $S'_2 \subseteq S \cup \{v_{i+1}\}$ を満たす。よって、 $S \subseteq V_2$ であれば、 $N(S_2) = \emptyset$ であることより、 S' は必ず自明な $i+1$ 極大クリークとなる。逆に、 $S' \subseteq V_2$ である場合、 S' の親 S が自明なクリークでなければ、 S_1 の頂点と v_{i+1} は隣接しない。

$S = V_1$ であるときは、 $S' = S$ であり、自明なクリークであるか、 S'_2 がある1頂点のみで構成されている。逆に $S' = V_1$ であれば、 S' の親は必ず V_1 である。

一般グラフの改良と同じように、自明なクリークが子供である場合は生成を行わず、自明なクリークの子供については別口で発生させるとすると、自明なクリークに関する計算が必要なくなる。自明でない i 極大2部クリーク S の子供が自明である場合は、 v_{i+1} が S_1 の頂点と隣接しない。よって、極大クリーク列挙の改良と同じく、 S_1 の頂点に隣接する頂点についてのみ、子供の生成を行えばよい。

以上のアイデアを用いると、極大クリーク列挙のアルゴリズムとほぼ同じく、 $X^*(|V|, S)$ と $J(S, i)$ を用いて反復を省略する、極大2部クリーク列挙アルゴリズムが構築できる。ページ数の都合で、詳細な記述は省略する。

このアルゴリズムの1反復のボトルネックは、各 $J(S, i)$ の頂点について type 2 子供の存在性を調べる部分であり、その計算時間は、 $v \in J(S, i)$ に対して、

$$O((v \text{ に隣接する } S \text{ の頂点数}) \times \Delta)$$

である。 $v \in J(S, i)$ の全ての頂点についてこの合計をとると、 $O(S \text{ の頂点に接続する枝数})$ になる。よって、1反復での type 2 の子供に関する計算時間の合計は $O(|S|\Delta^2)$ となり、このアルゴリズムの計算時間は、極大2部クリーク1つあたり $O(\Delta^3)$ となる。

5 次数の大きい頂点が存在する場合

ウェブネットワークなどでは、ほとんどの頂点の次数は定数とみなすことができるが、一部の、検索やリンクに関わるページに対する頂点のみ、次数が極端に大きい。このようなグラフが入力として与えられると、上記のアルゴリズムは次数の大きな頂点に対する計算時間が増大する。しかしこれは、いくつかの改良を施すことにより、回避することができる。その改良を以下に示す。

まず、次数の大きな頂点の添え字を、最大添え字から順番につけることにする。つまり、ある閾値 z が存在して、 $i < z$ ならば v_i の次数が定数であり、 $i \geq z$ であれば v_i の次数は大きくなるとする。仮定として、 $|V| - z$ はそれほど大きくないとする。また、 Δ' を添え字が z 未満の頂点の中の最大次数とする。この仮定より、任意の i 極大クリーク S に対して、

$$|J(S, i)| \leq (\Delta' + (|V| - z))^2$$

が成り立つことを注意しておく。

まず、極大クリークを 2 グループに分ける。1 つは添え字が $|V| - z$ 以下の頂点を含まない極大クリーク、もう 1 つは、添え字が $|V| - z$ 以下の頂点を含む極大クリークである。前者は頂点 $v_{|V|-z}, \dots, v_{|V|}$ によって誘導されるグラフを用いて列挙できる。 $|V| - z$ があまり大きくないという仮定から、このグラフの頂点数は小さく、短時間で列挙できる。後者は、もとのアルゴリズムに以下の改良を加えて列挙する。

アルゴリズムの実行中、添え字が z 以上の頂点のみからなる i 極大クリークができた場合、その子供は探索しないようにする。これは、以後の操作により見つかる極大クリークは前者の問題により列挙されているからである。また、頂点 $v_{|V|-z}, \dots, v_{|V|}$ に接する枝に関してのみ、隣接行列を作る。つまり、各頂点 v に対して配列 a を用意し、 $(u, v) \in E$ であれば $a(u, v) = 1$ とする。これにより、 S に次数が大きい頂点を追加するときの手間が $O(|N(S)|)$ になる。よって、 $X^*(i, S), \bar{X}(S, v_i)$ の計算は、 S が添え字 z 未満の頂点を必ず含むことから、 $O((\Delta' + (|V| - z))^2)$ 時間に短縮される。以上により、1 反復の計算時間は $O(\Delta'^4)$ に短縮され、巨大な次数を持つ頂点による計算時間の増大を回避することができる。

6 計算実験と考察

本節では、上記の 2 つのアルゴリズムを実際に計算機上に実装し、計算実験を行った結果を報告する。両者ともに C を用いて実装し、Pentium III 500MHz の PC で実験した。OS は Linux、コンパイラは gcc である。今回の実験では、実験に用いたグラフはランダムグラフである。ただし、通常のランダムグラフを用いると、大規模かつ疎なグラフでは極大クリークの大きさが極端に小さくなり、ほとんどの極大クリークが枝になってしまう。これでは実験の意味がないので、一部が密で大部分が疎であるようなグラフを作成するべく、以下の方法を用いた。頂点の添え字は 0 から $|V| - 1$ であるとする。 r はパラメータである。

- ・各頂点 i に対し、頂点 $(i - r) + |V| \bmod |V|$ から $i + r \bmod |V|$ との間に $1/2$ の確率で枝を張る

頂点を円周上に添え字順に並べ、左右 r 個以内の近傍のみに $1/2$ の確率で枝を作る、としたものと同じである。このグラフは局所的に密となるため、極大クリークのサイズはそれなりに大きくなり、また、頂点数が増加しても局所的な状況は変化しないため、頂点数の増加に対してほぼ線形に極大クリーク数が増加する。2 部グラフも同様にして発生させた。

- ・各頂点 $i \in V_1$ に対し、 V_2 の頂点 $i - r$ から $i + r$ との間に $1/2$ の確率で枝を張る

一般グラフと同様に, $i+r \geq |V|$ か $i-r < |V_1|$ となる場合の処理を行う.

実験では, $r = 10, r = 30$ の場合について, 頂点集合の大きさを変化させてグラフを生成し, 既存のアルゴリズムと提案したアルゴリズムを比較した (実験 1). また, 頂点数を 10000 に固定し, r を 10 から 300 まで変化させて生成したグラフに対して, 本稿のアルゴリズムを実行した (実験 2).

また, 一部だけ次数の大きいグラフに対する挙動を見るため, このグラフの一部の次数を大きくしたグラフについても実験を行った. $r = 10$ で生成した一般グラフに対し, 頂点 $v_{|V|-40}, \dots, v_{|V|}$ に対し, 頂点の次数を $|V|/2$ 程度になるよう, 枝をランダムに加えた. この結果, 頂点 $v_1, \dots, v_{|V|-41}$ の次数は平均的に 30 程度になる. 頂点数を 1000 から 256000 まで変化させて生成したグラフに対して計算実験を行った (実験 3).

実験 1, 2, 3 の結果は以下の通りである. 計算時間は, 出力した極大クリーク 1 万個あたりの秒数である. なお, 既存のアルゴリズムについては, 計算時間が莫大になるものについては, 省略, あるいは極大クリークを 10000 個, あるいは 2000 個出力した時点で終了する, という処理を行っていることを注意しておく.

実験 1 : 一般グラフ, $r = 10$

頂点数	1000	2000	4000	8000	10000	16000	32000	64000	128000	256000
旧	378	761	1410	3564	5123					
新	0.64	0.65	0.72	0.73	0.72	0.74	0.75	0.81	0.82	0.82
解数	2774	5553	11058	22133	27624	44398	89120	179012	357657	716978

実験 1 : 一般グラフ, $r = 30$

頂点数	1000	2000	4000	8000	10000	16000	32000	64000	128000	256000
旧	1755	4478	9912	21085	25345					
新	4.41	4.44	4.47	4.56	4.51	4.54	4.55	4.91	4.88	4.88
解数	20571	41394	83146	168049	209594	336870	675229	1352210	2711564	5411519

実験 1 : 2部グラフ, $r = 10$

頂点数	1000	2000	4000	8000	10000	16000	32000	64000	128000	256000
旧	104	214	446	966	1260					
新	0.33	0.32	0.3	0.3	0.27	0.3	0.3	0.34	0.34	0.35
解数	2085	4126	8316	16609	20862	33586	67143	134911	270770	541035

実験 1 : 2部グラフ, $r = 30$

頂点数	1000	2000	4000	8000	10000	16000	32000	64000	128000	256000
旧	282	582.2	890	1190	1481					
新	1.08	1.08	1.09	1.1	1.09	1.11	1.12	1.22	1.22	1.26
解数	9136	18488	40427	68597	101697	165561	322149	625385	1233989	2307135

実験 2 : 一般グラフ, 頂点数 10000

r	10	30	50	70	100	150	200	250	300
新	0.72	2.11	7.93	25.6	56.2	126.3	162.3	135.2	171.8

実験 3：一部の頂点の次数を大きくしたグラフ, $r = 10$

頂点数	1000	2000	4000	8000	10000	16000	32000	64000	128000	256000
新	1.07	1.14	1.12	1.31	1.21	1.36	1.74	2.62	4.02	7.8
解数	9136	18488	40427	68597	101697	165561	322149	625385	1233989	2307135

実験 1 の結果より、一般のグラフ、2 部グラフどちらの場合も、既存のアルゴリズム（旧と書かれたもの）の解 1 つあたりの計算時間は入力グラフの頂点数にほぼ比例するのに対して、提案したアルゴリズム（新と書かれたもの）の解 1 つあたりの計算時間は、最大次数さえ等しければ頂点数には依存しないことがわかる。また、最大次数が 60 程度であれば、提案したアルゴリズムの計算時間は、解 1 つあたり 1/1000 秒以下であり、実用的にも高速であることがわかる。これは、頂点数が 10000 以上あるような大規模ネットワークでは、既存のアルゴリズムよりも 1000 倍以上高速化されている。

また、実験 2 より、提案したアルゴリズムの解 1 つあたりの計算時間は、ほぼ $O(\Delta^2)$ であることが確認される。極大クリーク、あるいは極大 2 部クリークを 1 つ求めるには、貪欲法が高速であり、その計算時間は、前処理の時間を除くと $O(\Delta^2)$ である。興味深いことに、これらの時間計算量は等しく、列挙が、貪欲法で多量のクリークをヒューリスティックに求めるアルゴリズムと比べても、計算時間のオーダー的には遜色がないことが分かる。

実験 3 より、定数個の頂点の次数が大きくても、計算時間はそれ以外の頂点の最大次数にしか依存しないことも分かる。なお、実験 3 の結果で、頂点数が 32000 以上のものについて計算時間が増えているのは、使用するメモリが PC のメモリより大きくなり、スワップが発生しているため、CPU の 1 次・2 次キャッシュのヒット率が極端に低下したことに起因すると推測される。

7 まとめ

本研究では、巨大で疎なグラフの極大なクリークと極大な 2 部クリークを列挙するアルゴリズムを提案した。グラフの最大次数を Δ とすると、本稿の改良により、極大クリーク 1 つあたりの計算時間が $O(|V||E|)$ から $O(\Delta^4)$ に、極大 2 部クリークは $O(|V||E|)$ から $O(\Delta^3)$ に改善された。また、計算機実験により、このアルゴリズムのランダムな入力に対する計算時間は $O(\Delta^2)$ 程度であることが確認された。また、一部の頂点のみ次数が大きいようなグラフに対しても、同様な時間計算量が得られ、実際の計算も高速であることが確認された。

参考文献

- [1] R. Agrawal and R. Srikant, “Fast Algorithms for Mining Association Rules in Large Databases,” *In Proceedings of VLDB '94*, pp. 487–499, 1994.
- [2] R. Agrawal, H. Mannila, R. Srikant, H. Toivonen and A. I. Verkamo, “Fast Discovery of Association Rules,” *In Advances in Knowledge Discovery and Data Mining*, MIT Press, pp. 307–328, 1996.
- [3] D. Avis and K. Fukuda, “Reverse Search for Enumeration,” *Discrete Applied Mathematics*, Vol. 65, pp. 21–46, 1996.
- [4] S. R. Kumar, P. Raghavan, S. Rajagopalan, and A. Tomkins, “Trawling the Web for Emerging Cyber-Communities,” *Proceedings of the Eighth International World Wide Web Conference*, Toronto, Canada, 1999.
- [5] S. Tsukiyama, M. Ide, H. Ariyoshi and I. Shirakawa, “A New Algorithm for Generating All the Maximum Independent Sets,” *SIAM Journal on Computing*, Vol. 6, pp. 505–517, 1977.