

ローテーションに基づく2分木間の距離

5B-4

清水 道夫
(長野県短期大学)

1.はじめに

木の近さや類似性に関する問題は、パターン認識や誤り訂正構文解析などに関連して検討されてきた。この近さや類似性を表す尺度が距離であり、一般には重み付きレーベンシュタイン距離で定義されている(文献1)。本報告では、木のトポロジ(位相)を意識した距離として、ローテーション(回転)に基づく2分木の距離を考える。ローテーションは、木をデータ構造としてとらえたとき、見出し(キー)の挿入や削除にともなう更新のための基本的技法である。同じ大きさの2分木AとBがあるとき、AからBへ変換するローテーションの最小数を距離とする。とくに、木Aと木Bの距離が1のとき、この2つの木は結合しているという。まず、2分木をコードワードとよばれる整数列で表現し、その辞書式順序に基づいて2分木のランク(番号)付けを行う。つぎに、大きさnの2分木にたいして、ランクを要素とする結合表を作成する。2分木間の距離はこの結合表をもとにしたグラフから、単純な最短経路問題として求めることができる。

2.2分木の符号化

2分木をコンピュータ上で扱うために、それを整数列として符号化する。ここでは、D. Zerling(文献2)によって提案されたコードワード(CW)を生成し、それを2分木に対応づける。まず、2分木のローテーションを図1に示しておく。ここに、部分木 α , β , γ は空の場合もある。(a)から(b)への変換を右ローテーション、(b)から(a)への変換を左ローテーションとよぶ。右ローテーションでは、節Aの右部分木 β が節Bの左部分木になる。

CWの生成はつぎのように行う。長さLのCWを X_1, X_2, \dots, X_L とおく。 X_1 から X_b ($b = 1, 2, \dots, L$)までの総和がb以下であるような整数列をす

べて生成する。L=1から3のとき

$$L=1: 0, 1$$

$$L=2: 00, 01, 02, 10, 11$$

$$L=3: 000, 001, 002, 003, 010, 011, 012, 020, 021, 100, 101, 102, 110, 111$$

となる。ただし、要素間のカンマは省略している。なお、これは辞書式順序(lexicographic order)に並んでおり、この順番をCWの長さLにたいするランクとよぶ。たとえば、010はランク5である。

ところで、2分木がCWにどのように対応しているかを示す。2分木の大きさは内部節の数nで表す。大きさnの2分木の総数はカタラン数(Catalan number) ${}_n C_n / (n+1)$ で表されるが、これは長さL=n-1のCWの総数に一致する。CWの各要素は2分木の左端路上の節からみた右部分木に対応している。 X_L は根からみた右部分木の大きさで、左ローテーションによって右部分木がなくなるまでの回数を表している。つぎに、 X_{L-1} は根における左ローテーションが終了した時点での、根の左子からみた右部分木の大きさである。以下同様であるが、CWは左端路だけからなる線形の2分木(0…0)に変換されるまでの各レベルにおける左ローテーションの回数を表している。n=3の2分木とそのCWを図2に示す。




図1 ローテーション




図2 n=3の2分木とCW

3. 結合表の作成

ここでは、表1のような結合表の作り方を説明する。ここに、CWおよびそのランクRは前節で生成したものである。つぎの欄のBはブロック番号で、CWの末尾のケタ以外が同じものの集合をブロックと呼ぶ。ブロック番号もCWの辞書式順序にしたがってつけられる。そのつぎのuvは、CW(2分木)を左、右部分木の大きさに従って分類したもので、左、右部分木の節の数をそれぞれu、vとすると、n=4のとき(u, v)=(3, 0), (2, 1), (1, 2), (0, 3)の4通りに分けられる。ただし、表1のuvはカッコとカンマを省略している。ところで、CWから左、右部分木の大きさを決めるにはつぎのようにする。CWを右から走査して、J+1ケタ目が0、かつ、1からJ+1ケタまでの数の総和がJのとき、(u, v)=(n-1-J, J)とする。

表1のRANKは結合する2分木のランクを示したもので、この求めかたを説明する。結合はブロック内同士とブロック外同士に分けられるが、双方の和はつねにn-1になる。ブロック内のCWの違いは末尾のケタだけで、これは根についてのローテーションによる変化を示しているから、隣合うもの同士が結合する(ただし、ブロックの両端では片側のみ)。たとえば、R=2のブロック内結合はR=1とR=3である。一方、ブロック外結合は、表1のBとuvさらにn=3の結合表から決定する。n=3の結合表は省略するが、結合するランクだけを示すと(1:2, 4), (2:1, 3), (3:2, 5), (4:1, 5), (5:3, 4)である。ここに、(1:2, 4)はランク1がランク2とランク4に結合していることを示す。このn=3の結合ランクに相当する表1のブロック番号のうち、uvの等しいもの同士が結合する。たとえば、ランクR=2はB=1だからB=2かB=4を調べればよいが、B=2のなかに相当するものではなく、B=4のR=11が結合する。ところで、n=3の結合表は図2からも作れるが、n=2の結合表より再帰的に作成する。

4. 最短経路問題

表1からn=4の結合グラフをかくと図3のようになる。節内の数はランクで、節から節に至る枝の数は2分木間の距離を表している。これは、単純な最短経

表1 n=4の結合表

R	CW	B	UV	RANK
1	000	1	30	2, 5, 10
2	001	1	21	1, 3, 11
3	002	1	12	2, 4, 6
4	003	1	03	3, 7, 12
5	010	2	30	1, 6, 8
6	011	2	12	3, 5, 7
7	012	2	03	4, 6, 9
8	020	3	30	5, 9, 13
9	021	3	03	7, 8, 14
10	100	4	30	1, 11, 13
11	101	4	21	2, 10, 12
12	102	4	12	4, 11, 14
13	110	5	30	8, 10, 14
14	111	5	03	9, 12, 13




図3 n=4の結合グラフ

路問題として求められる。たとえば、ランクR=7とランクR=10の2分木間の距離は4である。まず、節7を0とし、それに結合する節4, 6, 9を1とする。以下、結合する節のラベル付けされたものなかで、最小値+1をその節のラベルとする。

文 獻

- (1) 田中栄一：構造をもつものの距離と類似度、情報処理、Vol.31, No.9, PP.1270-1279(1990).
- (2) D.Zerling : Generating Binary Trees Using Rotations, J.ACM, Vol.32, No.3, pp.694-701 (July 1985).