

6C-5

# ビットストリングによる2分木の表現

清水 道夫  
長野県短期大学

## 1はじめに

近年、組合せ論的な木の符号化問題、とくに2分木の符号化問題がいくつか研究されている。2分木の符号化問題は数学的に興味深いものであるが、応用面としては、木に関するアルゴリズムのふるまいを考えるときのランダムデータとしての使用を志向している。Zak <sup>(1)</sup>sは、2分木の2進数列への符号化を考察した。この2進数列は、2分木の内部節に1、葉に0とラベリングして、木を先行順(root-left-right)にたどったときのラベルをならべたものに対応している。このような数列をX-seqとよび、辞書式順序のもとでのジェネレーティング、ランキング、アソランギングを考えている。しかし、X-seqをランダムデータとして使おうとするとこのままでは非常に使いにくい。これは、木の構造についての情報が不足しているためと考えられる。そこで、2分木を虫が這うようにたどったときの2進数列を考える。虫は根から出発して左回りで根に戻って来るが、根から葉に向かう枝(up)を1、その逆(down)を0とする。これに対応する2進数列をY-seqとよぶ。Y-seqは符号という意味では多少冗長であるが、木の構造を反映しており、いろいろな応用に適している。

## 2定義

2つの2分木間の辞書式順序(lexicographic order)をつぎのように再帰的に定義する。 $T_l, T_r$ はそれぞれ左部分木、右部分木を表す。

[定義1]<sup>(1)</sup> 2分木 $T$ と $T'$ にたいして、次の条件を満たすとき、 $T < T'$ であるという。

(1)  $T$ が空(empty)で $T'$ が空でない。または

(2)  $T$ が空でないとき

- (a)  $T_l < T'_l$ 、または
- (b)  $T_l = T'_l$ かつ  $T_r < T'_r$

ところで、n個の内部節を持つ2分木はカタラン数で表されるが、その集合内での上記辞書式順序をランクという。つぎに、2分木を表現する2種類の2進数列(bit string)を定義する。

[定義2]<sup>(1)</sup> X-seq  $x$  は次の条件を満足する。

- (1)  $x$ にはn個の1とn+1個の0を含む。
- (2)  $x$ を左から走査して、任意のケタまでの0の個数は1の個数よりも多くない。

[定義3] Y-seq  $y$  を次のように構成する。

$n=0 : y = \phi$  (空を表す)

$n=1 : y = "1010"$

$n>1 : y = "1" + \alpha + "01" + \beta + "0"$

ここに、 $\alpha$ と $\beta$ は $|\alpha + \beta| = 4(n-1)$ をみたすY-seqで、+は文字列のつながりを示す。

(例)  $n=4$ にたいするランクR、X-seq、Y-seq.

R	X-seq	Y-seq
1	101010100	1011011011010000
2	101011000	1011011101001000
3	101100100	1011101001101000
4	101101000	1011101101000100
5	101110000	1011110100100100
6	110010100	1101001101101000
7	110011000	1101001110100100
8	110100100	1101101000110100
9	110101000	1101101101000010
10	110110000	1101110100100010
11	111000100	1110100100110100
12	111001000	1110100110100010
13	111010000	1110110100010010
14	111010000	111010010010010

## 3系列の性質

X-seqが2分木に1対1に対応していることは、文献(1)で証明されている。また、Y-seqが2分木に1対1に対応していることは、その構成法からも明かであるが、これを組合せ論における「括弧の問題」に置き換えるとより分かりやすい。X-seqとY-seqの長さは、

それぞれ  $2n+1$ ,  $4n$  である。

2分木の左枝にたいする Y-seq の 1 が, X-seq の 1 に相当することに注意すると, X-seq と Y-seq が辞書式順序の意味で一致していることがわかる。とくに, 2分木 T の X-seq を x, Y-seq を y とすると, x と y の左端から連続する 1 の個数は等しい。

ところで, 2分木のランクを考えるとき, 同じ特徴を持つ木ごとに分類して, その個数をあらかじめ調べておく必要がある。その特徴とは, X-seq では左端路上の内部節の数であり, Y-seq では左端路上の枝の数である。この内部節の数と枝の数が等しいから, Zaks の結果がそのままあてはまる。それによると, 内部節の数が  $n$  で, 連続する 1 の個数(左端路上の内部節の数)が  $j+1$  以上である数  $a(n,j)$  は,

$$a(n,j) = a(n,j+1) + a(n-1,j-1) \\ = \frac{j+2}{2n-j} \binom{2n-j}{n-j-1}$$

で表される。この  $n$  についての再帰的な関係が, 次節のアルゴリズムのポイントになっている。

#### 4 ランキングアルゴリズム

内部節の数  $n$  と Y-seq が与えられたとき, ランク R を求めるランキングアルゴリズムを示す。逆に,  $n$  と R が与えられたとき, 対応する Y-seq を求めることをアンランギングというが, ここでは省略する。

##### アルゴリズム RANK

入力  $n$ ,  $y$ ; 出力  $R$

ステップ 1 :  $i = n$ .

ステップ 2 :  $y$  を  $y = \gamma + "101" + \delta$  のように 3 つの部分列に分ける。ここに,  $\gamma$  はすべて 1 からなる部分列で, その長さを  $s$  とする。 $x(i) = s + 1$ .

ステップ 3 : 部分列  $\delta$  をさらに  $\delta = \alpha + "0" + \beta$  のように 3 つの部分に分ける。ここに,  $\delta$  の左端のケタが 0 ならば  $\alpha = " "$  とし, そうでなければ,  $\alpha$  は  $(\lfloor \alpha \rfloor \bmod 4 = 0)$  かつ ( $\alpha$  の 1 の個数と 0 の個数が等しい) を満たす部分列とする。

ステップ 4 :  $y = \gamma + \alpha + \beta$ .

ステップ 5 :  $i = 3$  ならばステップ 6 へ, そうでなければ  $i = i - 1$  としてステップ 2 へ。

ステップ 6 :  $y = "11010010"$  ならば  $Z = 1$  とし,  $y = "10110100"$  ならば  $Z = 2$  とする。

ステップ 7 :  $i = 3$ .

ステップ 8 :  $j = x(i)$ ,  $Z = Z + a(i,j)$

ステップ 9 :  $i = n$  ならばステップ 10 へ, そうでなければ  $i = i + 1$  としてステップ 8 へ。

ステップ 10 :  $R = a(n,0) - Z + 1$

(例)  $n = 8$ ,  $y = "11011101110100100010001110100100"$  のとき, ランク R を求める。

まず,  $n = 8$  にたいして,  $j + 1 = 3$  以上のものは対象外であるから,  $a(8,2) = 572$  を除く。Y-seq から "101" と "0" を除くと,  $n = 7$  にたいして  $y = "110111010010001001110100100"$  となる。ここで,  $j + 1 = 4$  以上のものは対象外であるから,  $a(7,3) = 75$  を除く。同様にして対象外のものを求めると,  
 $Z = a(8,2) + a(7,3) + a(6,4) + a(5,3) + a(4,2) + a(3,1) + 1$   
 $= 572 + 75 + 6 + 5 + 4 + 3 + 1 = 666$

となる。最後の 1 は,  $y$  が最終的に  $y = "11010010"$  となるからである。よってランクは

$$R = 1430 - 666 + 1 = 765$$

となる。参考までに,  $y$  の変化を書いておく。丸で囲まれたところが削除される部分である。

$n = 8$  :  $y = "1(\textcircled{1})1101110100100010001110100100"$   
 $n = 7$  :  $y = "11(\textcircled{1})11010010001001110100100"$   
 $n = 6$  :  $y = "111(\textcircled{1})01001001110100100"$   
 $n = 5$  :  $y = "11101(\textcircled{1})01001110100100"$   
 $n = 4$  :  $y = "11010(\textcircled{1})110100100"$   
 $n = 3$  :  $y = "10(\textcircled{1})110100100"$   
 $n = 2$  :  $y = "110100100"$

#### 5 おわりに

Y-seq に関する符号化の問題で残されていることはジェネレーティングである。いまのところ効率のよい方法がみつかっていないが, 部分木のローテーション (rotation) による方法が可能と考えられる。これは分類 (sort) や探索 (search) における 2 分木の更新 (update) を表現しており, ランダムデータとして Y-seq を用いる意味からも興味深い。

#### 文 献

- (1) Zaks S.: Lexicographic Generation of Ordered Trees, Theoretical Computer Science, Vol. 10, pp. 63-82 (1980).