

7.4 圧縮接尾辞配列

甲本 健太

1. 圧縮接尾辞配列

- i. 圧縮接尾辞配列の概要
- ii. 関数 Ψ の性質
- iii. 圧縮接尾辞配列上で $SA[i]$ を求める
- iv. 圧縮接尾辞配列の計算量
- v. CSA のさらなる省スペース化 / 高速化
- vi. CSA の実用上の実装

2. 自己索引化

圧縮接尾辞配列の概要 (1/2)

圧縮接尾辞配列 (CSA: compressed suffix array):

→ 接尾辞配列のサイズを小さくしたもの

接尾辞配列との比較

データ構造	サイズ	$SA[i]$ の計算
接尾辞配列 (非圧縮)	$n \lg n$ bits	$O(1)$ 時間
圧縮接尾辞配列	$O(n \lg \sigma)$ bits	$O(\lg^\epsilon n)$ 時間

計算時間について

圧縮接尾辞配列の各要素は $\text{polylog}(n)$ 時間で復元できる^[1].

→ 検索速度はあまり落ちない

[1] $\text{polylog}(n) := O(\lg^k n)$

圧縮接尾辞配列の概要 (2/2)

圧縮接尾辞配列 (CSA) は以下のように実現される.


1. 接尾辞配列の要素を間引く

- 任意の自然数 h に対して, n/h 個の要素のみを格納
- h はデータ構造のパラメータ

2. 間引かれた要素は, 関係を用いて表す

- 残された要素同士の間隔を関数 ψ で表す

i	0	1	2	3	4	5	6
SA	7	6	4	2	1	5	3
SA ₀		6					3



関数 Ψ の性質 (1/5)

文字列 T の接尾辞配列を SA とする．このとき Ψ 関数を次のように定義する．

$$\Psi[i] := \begin{cases} SA^{-1}[SA[i] + 1] & \text{if } SA[i] < n, \\ SA^{-1}[1] & \text{if } SA[i] = n. \end{cases}$$

気持ち

- $SA[i]$: $\{T[j..] \mid 1 \leq j \leq n\}$ を辞書順に並べたとき i 番目にあたる j の値
- $SA^{-1}[j]$: $T[j..]$ は辞書順で何番目にあたるか



- $\Psi[i]$: 辞書順で i 番目にあたる接尾辞 $T[j..]$ から先頭 1 文字を削除した文字列 $T[j + 1..]$ は辞書順で何番目にあたるか

関数 Ψ の性質 (2/5)

$T = \text{“banana”}$ としたときの例.

i	$SA[i]$	$T[SA[i]..n+1]$	$SA[i] + 1$	$\Psi[i]$
0	7	\$	1	4
1	6	a\$	7	0
2	4	ana\$	5	5
3	2	anana\$	3	6
4	1	banana\$	2	3
5	5	na\$	6	1
6	3	nana\$	4	2

j	$SA^{-1}[j]$
1	4
2	3
3	6
4	2
5	5
6	1
7	0

関数 Ψ の性質 (3/5)

関数 Ψ は補題 7.2 の性質を満たす.

補題 7.2

$0 \leq i < j \leq n$ に対し, $T[SA[i]] = T[SA[j]]$ ならば $\Psi[i] < \Psi[j]$.

証明

定義より $\Psi[i] = SA^{-1}[SA[i] + 1]$, $\Psi[j] = SA^{-1}[SA[j] + 1]$ である. つまり, $\Psi[i]$ と $\Psi[j]$ の大小関係は接尾辞 $T[SA[i] + 1..n + 1]$ と $T[SA[j] + 1..n + 1]$ の辞書順で定義される.

今, $T[SA[i]] = T[SA[j]]$ であるため, 接尾辞 $T[SA[i] + 1..n + 1]$ と $T[SA[j] + 1..n + 1]$ の大小関係は $T[SA[i]..n + 1]$ と $T[SA[j]..n + 1]$ の大小関係と等しい. $i < j$ であり, 接尾辞配列の定義から $T[SA[i]..n + 1] < T[SA[j]..n + 1]$ であるため, $\Psi[i] < \Psi[j]$ となる. $\square$

気持ち

文字列 S, T について, $S < T$ かつ $S[1] = T[1]$ であるとき, $S[2..] < T[2..]$ である.

関数 Ψ の性質 (4/5)

補題 7.2 より, Ψ 関数は高々 σ 個の狭義単調増加列に分解できる.

→ 単調増加列の圧縮といえば… Elias-Fano 符号とそれを拡張したデータ構造 GV.

復習: Elias-Fano 符号

Elias-Fano 符号 (イライアス・ファノ符号と読む) は, 広義単調増加する非負整数の列に対する符号である.

符号化方法

n 個の非負整数 $0 \leq x_1 \leq \dots \leq x_n = u$ とする. $\{x_i\}$ の符号は以下のように行う.

1. x_i の下位 s ビットを r_i , 下位 s ビットを除いたものを q_i とする.
2. $\{q_i\}$ は広義単調増加になっていることから,
 q_i の代わりに直前の値との差分 $d_i := q_i - q_{i-1}$ を 1 進数符号で符号化する.
3. $\{r_i\}$ は s ビットの 2 進数で符号化する.

(データ構造 GV は [第 7 回資料](#) を参照)

関数 Ψ の性質 (5/5)

補題 7.2 より, Ψ 関数は高々 σ 個の狭義単調増加列に分解できる. さらに,

$$\Psi'[i] = T[SA[i]] \cdot (n + 1) + \Psi[i]$$

と定義すると, Ψ' 関数は狭義単調増加関数になる.

(ただし, $T[SA[i]]$ は整数にエンコードしてあるものとする.)



関数 Ψ' はデータ構造 GV を用いて,

- $n(2 + \lg \sigma) + O(n \lg \lg n / \lg n)$ ビットで表現できる.
- $\Psi'[i], \Psi[i], T[SA[i]]$ は定数時間で求まる.
 - $\Psi[i] = \Psi'[i] \bmod (n + 1)$
 - $T[SA[i]] = \lfloor \Psi'[i] / (n + 1) \rfloor$

とすればよい.

圧縮接尾辞配列上で $SA[i]$ を求める (1/2)

CSA は、以下の 2 つの情報からなる.

1. SA の要素で, $SA[i]$ が h の倍数であるもののみからなる配列
2. 関数 $\Psi[i]$ を GV で圧縮したもの

このとき, 1 に格納されていない SA の要素は次のように求める.

CSA($h = 3$)			
i	$SA[i]$	$\Psi[i]$	$T[SA[i]..n+1]$
0	7	4	\$
1	6	0	a\$
2	4	5	ana\$
3	2	6	anana\$
4	1	3	banana\$
5	5	1	na\$
6	3	2	nana\$

3 の倍数のみ格納

GV で圧縮

例) $SA[4]$ を求める

1. $SA[4]$ は格納されている?
→ No.
2. $\Psi[4] = 3$, $SA[3]$ は格納されている?
→ No.
3. $\Psi[3] = 6$, $SA[6]$ は格納されている?
→ Yes. $SA[6] = 3$
4. よって, $SA[\Psi^2[4]] = 3$
 $SA[\Psi[i]] = SA[i] + 1 \Rightarrow SA[4] = 1.$

圧縮接尾辞配列上で $SA[i]$ を求める (2/2)

先のページの内容をちゃんと言うと、次のようになる。


補題 a

配列 SA_0 を用いることで、すべての i に対して高々 $2h - 2$ 回の Ψ の計算で $SA[i]$ を求めることができる。

証明

$j = SA[i]$ を求める場合、 $SA[\Psi[i]] = j + 1$ であることから、 $SA[\Psi^k[i]]$ が h の倍数である最小の k を求めればよい。

通常は $k \leq h - 1$ であるが、文字列の末尾で Ψ を求めると SA の値が 1 になるため、さらに $h - 1$ 回の Ψ の計算が必要である。 □



圧縮接尾辞配列の計算量

- どの要素が SA_0 に格納されているか $\rightarrow$ 長さ n のビットベクトル B で管理
 - $B[i] = 1$ ならば $SA[i]$ が格納されている
 - $SA[i]$ は $SA_0[rank_1(B, i)]$ に格納
- 計算量:
 - $h = \Theta(\lg^{1+\varepsilon} n)$ (ε は任意の正定数) を仮定すると,
 - Ψ' は GV を用いると $n(2 + \lg \sigma) + O(n \lg \lg n / \lg n)$ ビットで表現できる
 - B は FID を用いると $\mathcal{B}(n/h, n) + O(n \lg \lg n / \lg n)$ ビットで格納可能
 - $h = \Omega(\lg n)$ より, $O(n \lg \lg n / \lg n)$ ビット
 - SA_0 は $\lg n \cdot n/h = o(n)$ ビットで格納可能
 - $SA[i]$ は $O(h) = O(\lg^{1+\varepsilon} n)$ 時間で復元可能

以上より, CSA の計算量に関して以下の定理が得られる.

定理 7.1 (データ構造 CSA-GV)

長さ n , アルファベットサイズ σ の文字列の接尾辞配列は, 任意の正定数 h を用いて $n(2 + \lg \sigma) + O(n \lg n / h) + O(n \lg \lg n / \lg n)$ ビットで表現でき, 接尾辞配列の 1 つの要素は $O(h)$ 時間で計算できる.

圧縮接尾辞配列上で $SA[i]$ を求める (疑似コード)

CSA 上で $SA[i]$ を求める関数の疑似コードは以下の通り.

アルゴリズム 7.2 $csa_lookup(i)$: $SA[i]$ を求める.

```
1:   $k \leftarrow 0$ 
2:  while  $B[i] = 0$  do
3:     $k \leftarrow k + 1$ 
4:     $i \leftarrow \Psi[i]$ 
5:  end while
6:   $j \leftarrow SA_0[rank_1(B, i)] - k$ 
7:  if  $j \leq 0$  then
8:     $j \leftarrow j + n + 1$ 
9:  end if
10: return  $j$ 
```

CSA のさらなる省スペース化 / 高速化

- 配列 SA_0 をそのまま格納せず，それを再帰的に表現することもできる
 - i. SA_0 は長さ n/h の別の文字列 T' の接尾辞配列になっている
 - SA から元の文字列を復元: [ARC044: D - suffix array](#)
 - ii. T' の圧縮接尾辞配列を再帰的に作成する
- これにより， $SA[i]$ の復元速度を $O(\lg n)$ 時間から $O(\lg^\varepsilon n / \varepsilon)$ 時間にすることができる．（ ε は任意の定数）
 - $h = O(\lg n)$ を仮定？
- データ構造のサイズは $O(n \lg \sigma / \varepsilon)$ ビットになる．

CSA の実用上の実装 (1/2)

※ 1 枚前のスライドとは関係ないです

今までは、 $SA[i]$ が h の倍数のときに SA_0 に格納していた
→ i が h の倍数のときに SA'_0 に格納するよう、修正

- メリット:
 - ビットベクトル B を保持する必要がなくなるため、省スペース
 - $B[i]$ を求める操作も不要になるため、その分高速になる
- デメリット:
 - i が h の倍数になるまでに Ψ を計算する回数の上限値が抑えられない
 - 期待値としても、回数が Ψ の計算回数が 2 倍になる

次ページに、この方針で実装した場合のアルゴリズムを示す。

CSA の実用上の実装 (2/2)

- SA'_0 : i が h の倍数である $SA[i]$ のみを格納した配列

アルゴリズム 7.3 $csa_lookup2(i)$: $SA[i]$ を求める.

```
1:   $k \leftarrow 0$ 
2:  while  $i \bmod h \neq 0$  do
3:     $k \leftarrow k + 1$ 
4:     $i \leftarrow a[i]$ 
5:  end while
6:   $j \leftarrow SA'_0[i/h] - k$ 
7:  if  $j \leq 0$  then
8:     $j \leftarrow j + n + 1$ 
9:  end if
10: return  $j$ 
```

自己索引化 (1/4)

7.4.1 項で扱った CSA と通常の SA の比較は以下の通り.

	接尾辞配列	圧縮接尾辞配列
配列のサイズ	$n \lg n$ ビット	$O(n \lg \sigma)$ ビット
$SA[i]$ を求める	$O(1)$ 時間	$O(\lg^\epsilon n)$ 時間
パターン P の出現頻度クエリ	$O(P \lg n)$ 時間	$O((P + \lg^\epsilon n) \lg n)$ 時間

自己索引とは

- CSA を用いると配列のサイズは元のテキストと同じオーダーになった
- 一方, 検索のためには元のテキスト T を保持する必要がある
→ CSA を自己索引化すれば, 元のテキストを保持しなくてよい

自己索引:

データを検索するための索引構造で, 検索時に元データを必要としないデータ構造

復習: SA でのパターン P の検索

- SA の 2 分探索で求める.
 - i. 接尾辞配列の中央の要素 $j = SA[n/2]$ を求める
 - ii. $T[j..j + |P| - 1]$ と P を比較する
 - ⋮

ステップ 2 で元のテキスト T を参照する必要があった.

CSA からの部分文字列の復元

- 実は, T の部分文字列 $T' (:= T[j..j + |P| - 1])$ は Ψ' 関数から復元できる
 - i. T' の 1 文字目 $T[j] = T[SA[i]] = \lfloor \Psi'[i] / (n + 1) \rfloor$
 - ii. T' の 2 文字目 $T[j + 1]$:
 - $\Psi[i]$ が $T[j + 1..n + 1]$ を表すことを利用する.
 - 疑似コードを次ページに示す.

自己索引化 (3/4)

アルゴリズム 7.4 $csa_substring(i, \ell)$: 部分文字列 $T[SA[i]..SA[i] + \ell + 1]$ を求める.

- 1: **for** $k \leftarrow 1, \ell$ **do**
- 2: $S[k] \leftarrow \lfloor \Psi'[i] / (n + 1) \rfloor$ $\triangleright T[SA[i]]$
- 3: $i \leftarrow \Psi'[i] \bmod (n + 1)$ $\triangleright T[\Psi[i]]$
- 4: **end for**
- 5: **return** S

i	$SA[i]$	$\Psi[i]$	$\Psi'[i]$	$T[SA[i]..n + 1]$
0	7	4	4	\$
1	6	0	7	a\$
2	4	5	12	ana\$
3	2	6	13	anana\$
4	1	3	17	banana\$
5	5	1	22	na\$
6	3	2	23	nana\$

a	1
b	2
n	3

自己索引化 (4/4)

T の部分文字列 $T[s..t]$ の復元

- $csa_substring(i, \ell)$ を用いて T の部分文字列 $T[s..t]$ を復元したい
- 接尾辞 $T[s..n+1]$ の辞書順が必要
 - 接尾辞配列の逆関数 $i = SA^{-1}[s]$ を計算する必要がある
 - SA^{-1} も CSA と同様に値を間引いて格納する
 - $SA_0^{-1}[1..n/h]$ を $SA_0^{-1}[i] = SA^{-1}[ih]$ とする
 - 高々 $2h - 2$ 回 Ψ 関数を計算すれば $SA^{-1}[s]$ が求まる
 - 配列 SA_0^{-1} は $n \lg n / h$ ビット

自己索引化のまとめ

定理 7.2

文字列 T 中のパターン $P[1..m]$ の存在または頻度問い合わせは、 T の Ψ' 関数のみを用いて $O(m \lg n)$ 時間で行える。また、 $O(n \lg n / h)$ ビットの補助データ構造を追加することで (h は任意の正定数), T の接尾辞配列の 1 つの要素は $O(h)$ 時間で計算でき、 T の任意の位置の長さ ℓ の部分文字列は $O(\ell + h)$ 時間で復元できる。