

JAG 模擬地区予選 2017

H: Separate String

原案: camypaper

問題文: darsein


解答: climpet, darsein, not

解説: darsein

問題概要

- 1つの文字列 t と辞書となる文字列集合 S がある
- t を複数の文字列に分割するとき、分割後の文字列すべてが S に含まれるような分割はいくつあるか？
 - S に含まれる文字列が複数回分割に現れてもよい
- 制約: $1 \leq |t| \leq 10^5$, $1 \leq |S| \leq 10^5$, $1 \leq |x| \leq 10^5$ ($x \in S$),
 $\sum_{x \in S} |x| \leq 2 \times 10^5$

$$S = \{a, ab, bc, cd, d\}$$



2通り

想定解法: DP

- $dp[i] := t[1:i]$ を分割する方法の数
($t[l:r] := t$ の $l \sim r$ 文字目の部分文字列)
- $dp[i] = \sum_{1 \leq j \leq i, t[j:i] \in S} dp[j-1]$
 - ただし、 $dp[0] := 1$
- 素直に計算すると $O(|t|^2 \times t[j:i] \in S$ の判定時間)
→ TLE

$$S = \{abcde, cde, e\}$$

$$\begin{aligned} dp[5] &= dp[4] \ abcde\textcolor{red}{f}g \\ &\quad + dp[2] \ ab\textcolor{green}{cde}\textcolor{green}{f}g \\ &\quad + dp[0] \ \textcolor{blue}{abcde}\textcolor{blue}{f}g \end{aligned}$$

考察

- $L = \sum_{x \in S} |x|$ とおく
- $N \leq 10^5, L \leq 2 \times 10^5$
→ 文字列の長さの種類は高々 $\min(N, \sqrt{L}) < 450$
- DPで参照すべき区間 $[j:i]$ は各 i につき高々 450 個
→ 各 i ごとに S のどれかにマッチする区間 I_i を

前処理で求めておけば、

$$dp[i] = \sum_{j \text{ s.t. } [j:i] \in I_i} dp[j-1]$$

とでき、 $O(|t| \min(N, \sqrt{L}))$ で計算可能

想定解法: 文字列マッチングパート

1. 普通にAho-Corasickをする

- 構築: $O(L)$, 判定: $O(|t| + |\text{マッチ箇所}|)$
- マッチ箇所は高々 $O(|t| \min(N, \sqrt{L}))$ 個なので OK


2. 短い文字列(多いかも)と長い文字列(少ない)に分けて別々に前処理

- 両方ローリングハッシュが使えるので実装が楽かも
- 以降詳しく見るが、結局 $O(|t| \min(N, \sqrt{L}))$ ができる

想定解法: for short strings

- もしSの文字列がすべて短かったら...
 - (インクリメンタルに判定できる) 複数文字列検索データ構造を用いる
 - 例: Trie, ローリングハッシュ, etc.
 - S中の文字列の逆文字列に対してデータ構造を構築
 - $t[j:i]$ の計算後、 $t[j-1:i]$ (の逆) を1文字追加で検索
 - 構築: $O(L)$, 判定: $O(\max_{x \in S} |x|)$
 - 前処理に $O(L)$ 、DPに $O(|t| \max_{x \in S} |x|)$ で解ける

$$S = \{aa, b, baa, dea\}$$



想定解法: for few strings

- もし S 中の文字列の数が少なかったら...
 - 普通の文字列検索アルゴリズムで前処理する
 - 例: KMP, Suffix Array, ロリハ, etc.
 - $x \in S$ ごとに普通に文字列検索、出現区間をマーク
 - 全体で構築: $O(L)$, 判定: $O(L + |t|)$ とか
- 前処理に $O(L + |t|)$ 、DP時は $O(|t| |S|)$ で解ける

$x = abcab$

$t = \begin{array}{c} [1:5] \\ \boxed{abcabcab} \\ [4:8] \end{array}$

Writer 解

- climpet: 92 行 1622 bytes (C++, Aho-Corasick)
- darsein: 188 行 3769 bytes (C++, Trie + KMP)
- not: 57 行 1457 bytes (C++, ロリハ)

統計情報

- AC / submissions
 - 17 / 68 (25%)
- First Acceptance
 - hankan_rta (53:18)

文字列アルゴリズム資料

- Knuth-Morris-Pratt (KMP) 法:

<http://snuke.hatenablog.com/entry/2014/12/01/235807>

- Trie (競プロで double array まで必要になることはあまりない):

<http://d.hatena.ne.jp/takeda25/20120219/1329634865>

- Aho-Corasick 法:

d.hatena.ne.jp/naoya/20090405/aho_corasick

- ローリングハッシュ (Rabin-Karp 法):

https://topcoder.g.hatena.ne.jp/spaghetti_source/20130209/1360403866