

Problem F
Sakura Poetry

桜詩 ~願はくは花の下にて春死なむ~

原案: 野田
解答作成: 野田・田山・岩田
解説作成: 田山

概要

- 接続辞書に従って詩を作りなさい
 - 季語が一度だけ登場するように
- 詩は何通りに作られる？
 - MOD 1,000,000,007 で

方針

- 言うまでもなく全探索はダメ
- DP
 - (長さ m の)
 - (単語 w で終わる)
 - (i 番目の単語に頭 j 文字までマッチした)
 - (既に単語を c 個含んでいる)
 - 文字列の個数を求めていく

季語のマッチ状態

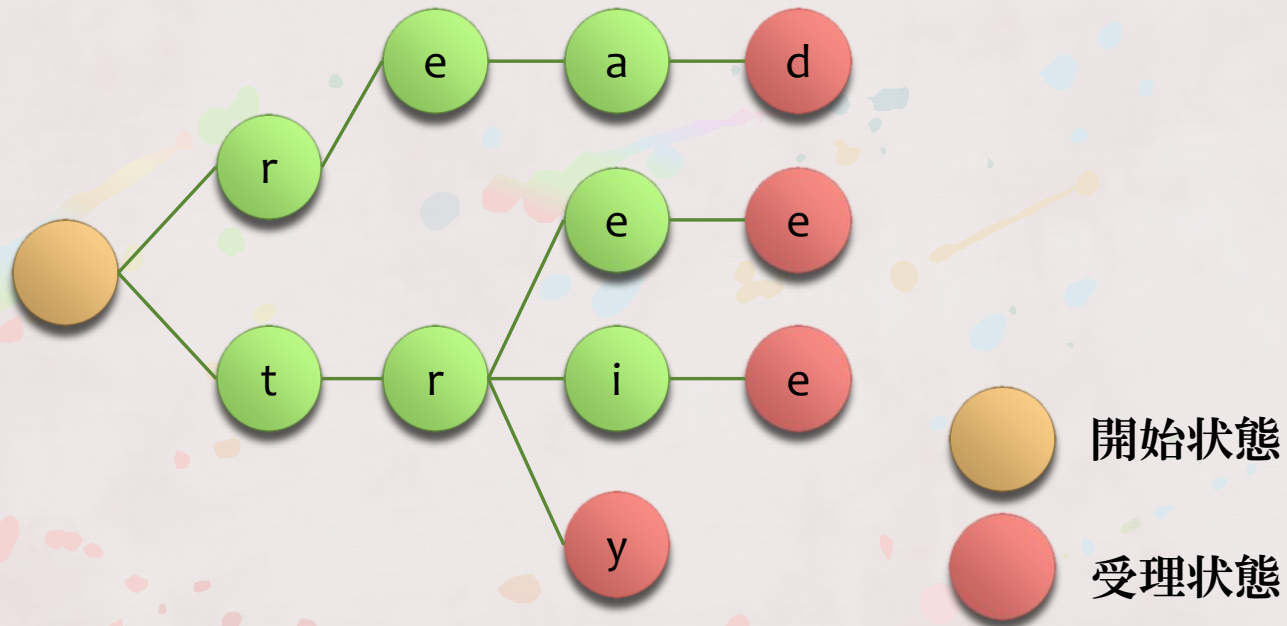
- (i番目の季語に頭j文字までマッチした)
 - 状態数 K^L
 - $L = \text{季語の最大長} = 20$
 - とても大きいので工夫が必要
 - 「どの文字列にどこまでマッチしているか」という情報を簡潔に表せる構造がほしい
 - K^L 個の状態のほとんどはありえない状態
 - ‘sakura’ の頭2文字、‘hana’ の頭1文字に同時にマッチする文字列などない

パターンマッチングオートマトン

- 季語の集合に対してパターンマッチングオートマトン (PMA) を構成する
 - 文字列 s の接尾辞がパターンにマッチすること
 - 文字列 s を PMA に入力したとき受理状態にあること
- この2つが同値であるようなオートマトン
- Aho-Corasick algorithm として知られる
 - パターンが1つだけの場合
Knuth-Morris-Pratt algorithm


パターンマッチングオートマトン

- パターンの集合を Trie 木で表す
 - 例: { 'read', 'tree', 'trie', 'try' }



パターンマッチングオートマトン

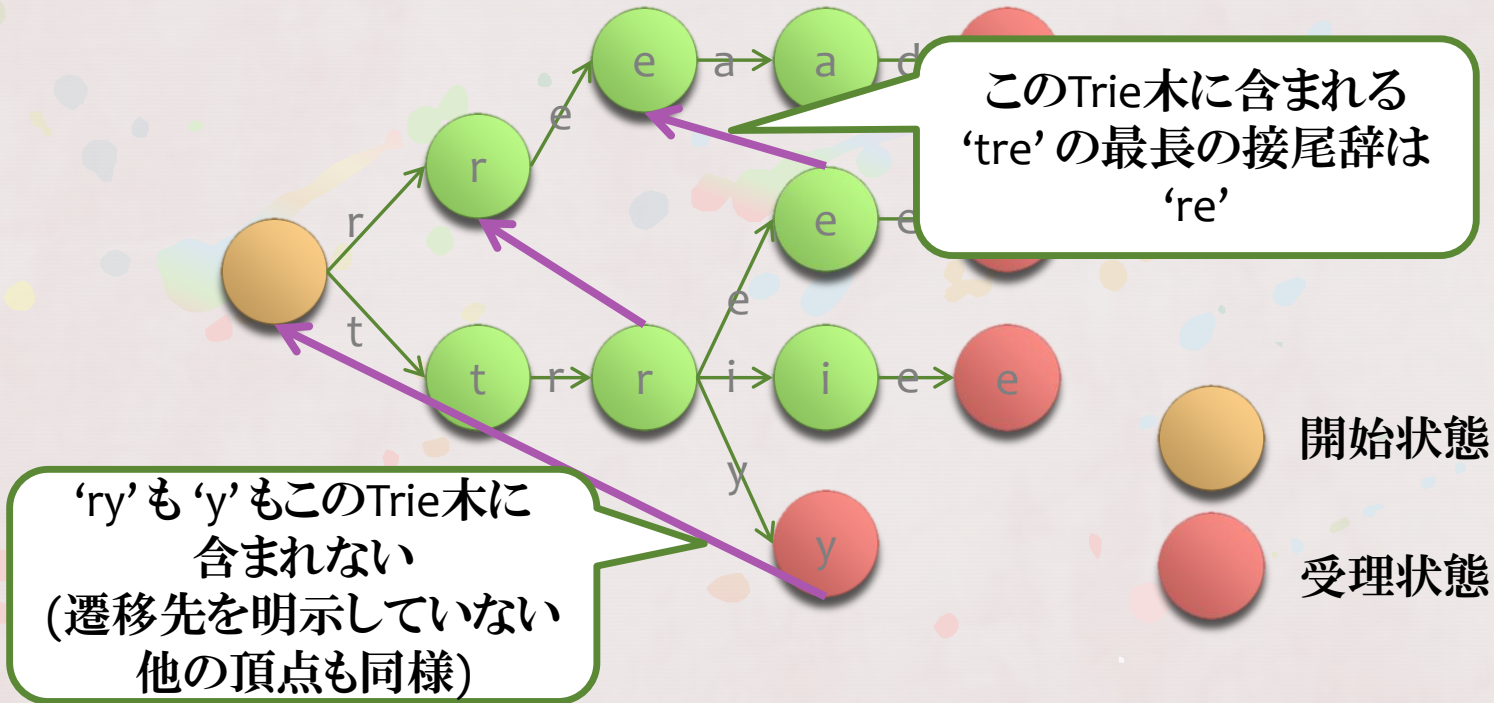
- 一致時の遷移
 - 自明



パターンマッチングオートマトン

- 不一致時の遷移 (failure link)

- Trie 木に含まれる、その頂点の最長の接尾辞へ遷移



Aho Corasick Algorithm

- PMA を用いた文字列の検索

- PMA に文字列を流し込む

- 遷移先の頂点があれば、その頂点に進んで文字列を1文字読み進める
- 無ければ、文字列を読み進めずに failure link で遷移し、マッチを試みる
 - それでも無ければ、もう一度 failure link で遷移してマッチを試みる
 - Trie 木の根でも遷移先が見つからなければ、諦めて文字列を1文字読み進める

- 詳しくは他の資料を

- Failure link の効率的な構築方法なども

- この問題ではDP部分の計算量が支配的なので、PMAの構築は手抜きをしてもよい

方針

- 明らかに全探索はダメ
- DP
 - (長さ m の)
 - (単語 w で終わる)
 - (i番目の単語に頭 j 文字までマッチした)
 - これを PMA の頂点で置き換えられる
 - (既に単語を c 個含んでいる)
 - 文字列の個数を求めていく

DP

- $DP[n][s][w][c] :=$
 - 長さ n で
 - PMA に流し込むと頂点 s に辿り着く
 - 単語 w で終わる
 - 既に完成した単語を c ($= 0$ or 1) 個含んだ
 - 文字列の総数
- を計算していく
 - 単語 w の後に w' を接続できるならば
 $DP[n+\text{length}(w')][s'][w'][c'] += DP[n][s][w][c]$
 - s', c' は Aho-Corasick で求まる

計算量

● 空間計算量

- PMAの総頂点数は季語の長さの総和程度
- 単語数は高々接続辞書のサイズの2倍
- $O(NMKL)$
 - $L = (\text{季語長}) = 20$
 - DPテーブルのサイズは 1.2GB 程度

● 時間計算量

- $O(NMKL)$
 - 数億回のループ

Memory Limit Exceeded

- 国内予選なので実行制限時間がない
 - 数億回のループはなんとかなる
- メモリはなんとかならない
 - 以下のどちらかの工夫が必要
 1. 状態を map で持つ
 2. 配列を使い回す
 - PCの性能によってはなんとかなってしまうかも

状態を map で持つ

- DPテーブルの多くの要素は 0
 - 0 でない要素だけを map で持つ
 - `std::map` (C++), `java.util.TreeMap` (Java), etc.
 - `Map<Status, int> dp[N];`
 - `Status` に `s, w, c` を持たせる
- メモリ消費量は見積もりにくい
 - 実際には実行速度も速い

配列を使い回す

- DPしていく過程で、 $DP[i]$ と $DP[i+L+1]$ が同時に必要になることはない
 - $DP[L+1][S][W][C]$ だけ宣言すれば十分
 - 48MB程度

Judge Solutions

- 野田: 254行 (C++)
- 田山: 194行 (C++)
- 田山: 115行 (C++)
- 岩田: 103行 (Java)

Result

- #Submitted Teams: 3

- #Accepted Teams: 3

1. ~usaaaaagi (1:37:35)

2. _____ (1:50:33)

3. STAFF (2:21:19)

Congratulations!