

O Problema da Subseqüência Comum Máxima sem Repetições

Christian Tjandraatmadja (christj@ime.usp.br)

Supervisora: Cristina Gomes Fernandes (cris@ime.usp.br)

Orientador: Carlos Eduardo Ferreira (cef@ime.usp.br)

Instituto de Matemática e Estatística

Universidade de São Paulo

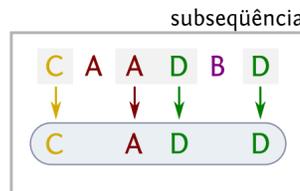
Apoio financeiro: FAPESP (processo 07/54282-6)

Introdução

Objetivo: Estudar o problema do RFLCS, definido a seguir, e implementar um algoritmo para a sua resolução.

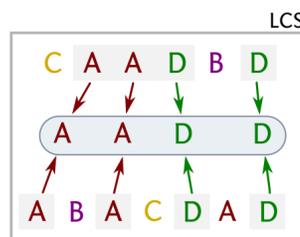
Considere seqüências s e t sobre um alfabeto.

Uma **subseqüência** de s é obtida escolhendo elementos de s de forma a manter a ordem relativa entre eles.

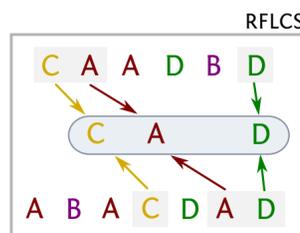


Uma **subseqüência comum** de s e t é uma subseqüência tanto de s e como de t .

Dizemos que tal subseqüência é um **LCS** (*longest common subsequence*, ou **subseqüência comum máxima**) se ela tem comprimento máximo.



Dizemos que ela é um **RFLCS** (*repetition free longest common subsequence*, ou **subseqüência comum máxima sem repetições**) se ela tem comprimento máximo entre as que não têm mais de uma ocorrência de um mesmo símbolo.



O problema em que estamos interessados é, dadas duas seqüências, encontrar um RFLCS delas.

Abordagens principais:

- Programação inteira
- Combinatória poliédrica

Aplicações:

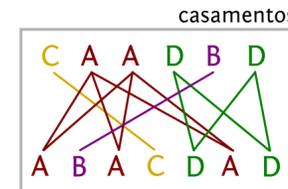
- LCS: Diferenciação de arquivos, compressão de dados
- LCS e RFLCS: Biologia Computacional (similaridade entre genomas)

Complexidade:

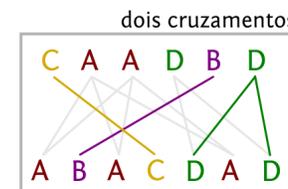
- LCS: Existe algoritmo polinomial (para número fixo de seqüências)
- RFLCS: NP-difícil

LCS

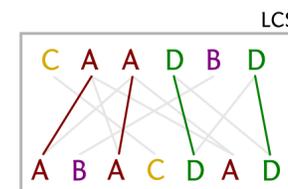
Definimos **casamento** como um par (i,j) que liga o i -ésimo elemento de s ao j -ésimo elemento de t se eles são do mesmo símbolo.



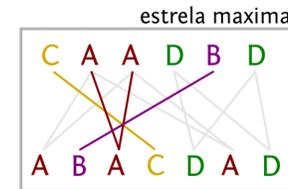
Dizemos que dois casamentos (i,j) e (k,l) se **cruzam** se $(i \leq k \text{ e } j \geq l)$ ou $(k \leq i \text{ e } l \geq j)$.



Um LCS pode ser visto como uma escolha do maior número de casamentos que não se cruzam, pois um cruzamento troca a ordem relativa entre os elementos.



Definimos **estrela** como um conjunto de casamentos que se cruzam dois a dois. Dizemos que ela é **maximal** se não há outro casamento fora do conjunto que cruza com todos do conjunto. Observe que o LCS pode ser visto como escolher o maior número de casamentos tal que não haja dois em uma mesma estrela maximal.



Assim, podemos formular o problema do LCS como um problema de programação inteira da seguinte forma:

Sejam C o conjunto de casamentos e $z \in \{0,1\}^C$ o vetor em que $z_{ij} = 1$ se e somente se escolhermos o casamento (i,j) .

$$\max \sum_{(i,j) \in C} z_{ij} \quad \rightarrow \text{maximizar a escolha de casamentos de forma que}$$

$$\text{sujeito a } \sum_{(i,j) \in S} z_{ij} \leq 1 \quad \rightarrow \text{para cada estrela maximal, podemos selecionar no máximo 1 casamento,}$$

para toda estrela maximal S

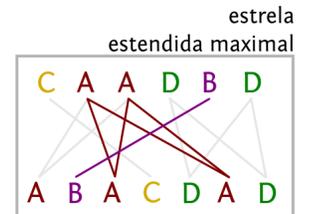
$$z_{ij} \in \{0,1\} \quad \rightarrow \text{cada casamento é escolhido 0 ou 1 vezes.}$$

para todo casamento (i,j)

Podemos provar que, do ponto de vista de combinatória poliédrica, não existe formulação melhor.

RFLCS

No RFLCS, surge a restrição de que existe no máximo uma ocorrência de cada símbolo na solução. Isto é, não podemos escolher mais de um casamento associado ao mesmo símbolo.



Definimos então **estrela estendida** como um conjunto de casamentos que, dois a dois, ou se cruzam ou estão associados ao mesmo símbolo. Note que, em particular, os conjuntos de todos os casamentos de mesmo símbolo são estrelas estendidas.

Podemos obter, então, a seguinte formulação:

Sejam C o conjunto de casamentos e $z \in \{0,1\}^C$ o vetor em que $z_{ij} = 1$ se e somente se escolhermos o casamento (i,j) .

$$\max \sum_{(i,j) \in C} z_{ij} \quad \rightarrow \text{maximizar a escolha de casamentos de forma que}$$

$$\text{sujeito a } \sum_{(i,j) \in S} z_{ij} \leq 1 \quad \rightarrow \text{para cada estrela estendida maximal, podemos selecionar no máximo 1 casamento,}$$

para toda estrela estendida maximal S

$$z_{ij} \in \{0,1\} \quad \rightarrow \text{cada casamento é escolhido 0 ou 1 vezes.}$$

para todo casamento (i,j)

O algoritmo implementado para o projeto se baseia na formulação acima. Como o número de estrelas estendidas maximais é exponencial no tamanho do problema, as restrições de estrelas estendidas são adicionadas conforme elas são violadas durante a execução do algoritmo.

Resultados

- Conhecimento da estrutura dos problemas do LCS e do RFLCS e das suas caracterizações poliédricas;
- Implementação de um algoritmo para a resolução do problema do RFLCS baseado na técnica *branch and cut* com o uso do pacote glpk.