

Montagem de regiões gênicas

Pedro Ivo Gomes de Faria

Departamento de Ciência da Computação
Instituto de Matemática e Estatística
Universidade de São Paulo

Orientador: Prof. Dr. Alan Durham

1

Conceitos

- Introdução à biologia molecular
- Alinhamento de sequências e suas variações

2

Problema

- Introdução
- Complicações teóricas
- Complicações práticas

3

Abordagem

4

Resultados

Sumário

1

Conceitos

- Introdução à biologia molecular
- Alinhamento de sequências e suas variações

2

Problema

- Introdução
- Complicações teóricas
- Complicações práticas

3

Abordagem

4

Resultados

Sumário

1

Conceitos

- **Introdução à biologia molecular**
- Alinhamento de sequências e suas variações

2

Problema

- Introdução
- Complicações teóricas
- Complicações práticas

3

Abordagem

4


Resultados

Classificação

Os seres vivos podem ser divididos em dois grupos (táxons):

- eucariotos: células com núcleo delimitado por uma membrana (animais, fungos, plantas);
- procariotos: células sem núcleo (bactérias, arqueias);


Localização e estrutura do DNA (em eucariotos)



Dogma central da biologia molecular


Descreve a transmissão e a expressão da hereditariedade, que ocorre utilizando três tipos de moléculas:

- DNA: armazena a informação;
- RNA: transfere a informação;
- proteína: executa uma função.



Estrutura dos genes (em eucariotos)

Gene: unidade molecular da hereditariedade; sequência de DNA que pode ser transcrita em uma versão de RNA.



Sumário

1

Conceitos

- Introdução à biologia molecular
- **Alinhamento de seqüências e suas variações**

2

Problema

- Introdução
- Complicações teóricas
- Complicações práticas

3

Abordagem

4

Resultados

Motivação

- modo de organizar sequências de DNA, RNA, ou proteínas para identificar regiões de similaridade;
- regiões similares podem ser consequência de relações funcionais, estruturais ou evolutivas entre as sequências;
- processo que possui várias aplicações em bioinformática.

Alinhamento global

- compara seqüências ao longo de toda a sua extensão;
- usado para identificar genes ou proteínas com funções similares, ou para estudar relações evolutivas entre seqüências supostamente homólogas (i.e., que possuem um ancestral em comum).

Exemplo:

```

QUERIDA---ROSAVERMELHA
| | | |         | | | | | | |
QUEROUMAMOROSOVERME---
  
```

Alinhamento local

- encontra *substrings* das sequências com alta similaridade entre si;
- utilizado para detectar padrões de nucleotídeos ou aminoácidos (domínios proteicos) conservados.

Exemplos (de dois alinhamentos locais entre as sequências QUERIDAROSAVERMELHA e QUEROUMAMOROSOVERME):

QUER		ROSAVERME
	e	
QUER		ROSOVERME

Alinhamento semiglobal

- encontra sufixos de uma seqüência que tenham alta similaridade com prefixos de outra seqüência;
- utilizado na montagem de seqüências.

Exemplo:

```
---ROSAVERMELHA
  | | | | | | |
AMOROSOVERME---
```

Medidas

Identidade e cobertura


- identidade (do alinhamento): porcentagem de colunas idênticas do alinhamento;
- cobertura (de uma seqüência): porcentagem de caracteres da seqüência presentes na região alinhada.
- exemplo: para as seqüências $s = \text{QUERIDAROSAVERMELHA}$ ($|s| = 19$), $t = \text{QUEROUMAMOROSOVERME}$ ($|t| = 19$) e para o alinhamento local $a = \begin{Bmatrix} \text{ROSAVERME} \\ \text{ROSOVERME} \end{Bmatrix}$, temos:
 - $\text{cobertura}(s, a) = |\text{ROSAVERME}| / |s| = 9/19 \approx 0,47$;
 - $\text{cobertura}(t, a) = |\text{ROSOVERME}| / |t| = 9/19 \approx 0,47$;
 - $\text{identidade}(a) = 8/9 \approx 0,89$.

Medidas

Pontuação (*score*)

- é uma medida da similaridade entre as seqüências na região do alinhamento;
- colunas similares são “premiadas” (pontuação positiva) e colunas não similares são “penalizadas” (pontuação negativa);
- objetivo é encontrar um alinhamento de pontuação máxima.

Exemplo (para um alinhamento semiglobal):



$$\begin{aligned}
 3 \times (-2) &= -6 \\
 2 \times (-4) &= -8 \\
 2 \times (-3) &= -6 \\
 23 \times (+1) &= 23 \\
 \hline
 &= 3
 \end{aligned}$$

3

Gap opening	-4 pontos
Gap extension	-3 pontos
Mismatch	-2 pontos
Match	+1 ponto

Sumário

1

Conceitos

- Introdução à biologia molecular
- Alinhamento de seqüências e suas variações

2

Problema

- Introdução
- Complicações teóricas
- Complicações práticas

3

Abordagem

4

Resultados

Sumário

1

Conceitos

- Introdução à biologia molecular
- Alinhamento de sequências e suas variações

2

Problema

- **Introdução**
- Complicações teóricas
- Complicações práticas

3

Abordagem

4

Resultados

Motivação e definição

- genomas possuem tamanhos variando de milhões (bactérias) a bilhões (animais, plantas) de pares de bases (pb);
- tecnologia atual apenas consegue sequenciar fragmentos (*reads*) de cerca de 1000 pb (no máximo);
- o problema consiste em determinar a sequência original a partir dos fragmentos (processo chamado de montagem do genoma).

Modelagem

A modelagem pode ser feita pelo problema da *superstring* comum mais curta (versão de otimização):

- instância: um alfabeto finito Σ ($= \{A, T, C, G\}$) e um conjunto finito de *strings* $R \subset \Sigma^*$;
- solução viável: uma *string* $w \in \Sigma^*$ tal que cada *string* $x \in R$ seja uma *substring* de w (i.e, $\forall x \in R, \exists w_0, w_1 \in \Sigma^* : w = w_0 x w_1$);
- objetivo: minimizar o tamanho de w ($|w|$).

Sumário

1

Conceitos

- Introdução à biologia molecular
- Alinhamento de sequências e suas variações

2

Problema

- Introdução
- **Complicações teóricas**
- Complicações práticas

3

Abordagem

4

Resultados

Complicações teóricas

Considerando as classes de complexidade computacional, o problema:

- é NP-completo (versão de decisão), ou seja, está em NP e é NP-difícil;
- é APX-completo (versão de otimização), ou seja, está em APX (melhor aproximação conhecida - devido a Sweedyk - possui fator 2,5) e é APX-difícil (não possui PTAS - aproximação de fator $(1 + \epsilon)$, $\forall \epsilon > 0$ - a menos que $P = NP$).

Sumário

1

Conceitos

- Introdução à biologia molecular
- Alinhamento de sequências e suas variações

2

Problema

- Introdução
- Complicações teóricas
- **Complicações práticas**

3

Abordagem

4

Resultados

Erros de sequenciamento

- Os métodos de sequenciamento geralmente identificam cada uma das bases através de sequências de reações químicas que geram algum sinal detectável;
- Interferências ou interpretações incorretas do sinal geram fragmentos com erros.

Sequência original:
TTACCGTGC

Entrada:
ACCGT
CGTGC
TTAC
T**G**CCGT

Saída:
--ACCGT--
----CGTGC
TTAC-----
-T**G**CCGT--


TTACCGTGC

Regiões de repetição


- consistem de *substrings* que aparecem duas ou mais vezes na molécula de DNA original;
- são o maior desafio da montagem de genomas, principalmente em eucariotos;
- podem fazer com que fragmentos não contíguos possuam sobreposição em suas extremidades, o que faz com que sejam incorretamente sobrepostos durante a montagem (considerando a modelagem como o problema da *superstring* comum mais curta).

Problemas causados por regiões de repetição

(A) Problemas com DNA repetitivo em tandem



(B) Problemas com repetições em escala genômica




Sumário

- 1 Conceitos
 - Introdução à biologia molecular
 - Alinhamento de sequências e suas variações
- 2 Problema
 - Introdução
 - Complicações teóricas
 - Complicações práticas
- 3 Abordagem
- 4 Resultados


Estratégias de sequenciamento

- em vez de gerar fragmentos para todo o genoma (sequenciamento *shotgun*), dividi-lo em partes menores, determinar qual a ordem entre essas partes e sequenciar cada uma individualmente (sequenciamento BAC a BAC);
- sequenciamento *shotgun* é rápido, barato e impreciso, enquanto sequenciamento BAC a BAC é lento, custoso e preciso.



Estratégias de montagem

- em vez de utilizar apenas o conjunto de fragmentos (ab initio), utilizar uma sequência de referência (montagem comparativa);
- sequência de referência deve possuir similaridade suficiente com a sequência que originou os fragmentos.



Sorgo: genoma modelo para cana-de-açúcar

- sorgo (*S. bicolor*) é a planta cultivada mais próxima evolutivamente da cana-de-açúcar (*S. officinarum*);
- divergência entre ambas ocorreu há cerca de 5 milhões de anos;
- ambas pertencem à família das gramíneas (Poaceae), subfamília Panicoideae, tribo Andropogoneae.




Figura: Sorgo (*Sorghum bicolor*).



Figura: Cana-de-açúcar (*Saccharum officinarum*).

Comparação dos genomas de cana-de-açúcar e sorgo



- 1 - número diploide ($2n$): número de cromossomos numa célula somática.
- 2 - número haploide (n): número de cromossomos num gameta.
- 3 - número monoploide (x): número de cromossomos num conjunto não redundante.

Passos dos pipelines de montagem e validação desenvolvidos

Para cada conjunto de sequências de DNA de um BAC de cana-de-açúcar:

- 1 mascarar as sequências contaminantes (EGene);
- 2 alinhar as sequências (usando Blat) de DNA filtradas no proteoma de sorgo (≈ 30000 proteínas);
- 3 montar separadamente (usando Newbler) cada conjunto de sequências que se alinhou na mesma proteína;
- 4 tentar estender o máximo possível (usando Genseed) cada conjunto montado anteriormente, utilizando as sequências que não foram mapeadas nas proteínas de sorgo;
- 5 alinhar os *contigs* gerados na sequência já disponível do BAC (supostamente correta);
- 6 verificar a ocorrência de quimeras (i.e., *contigs* montados incorretamente) via cobertura dos *contigs* e identidade dos alinhamentos.

Sumário

1

Conceitos

- Introdução à biologia molecular
- Alinhamento de sequências e suas variações

2

Problema

- Introdução
- Complicações teóricas
- Complicações práticas

3

Abordagem

4

Resultados

Resultados

Para o BAC SHCRBa_218_D04, os resultados foram:

nome do contig	nome da prot.	tam. reg. 5' (pb)	tam. reg. 3' (pb)	ident. na prot.	cobert. no BAC	ident. no BAC
C ₁	P ₁	708	X	0,99	0,95	1
C ₂	P ₂	515	X	0,90	1	0,99
C ₃	P ₂	X	X	0,97	0,99	1
C ₄	P ₂	X	266	0,92	0,98	0,99
C ₅	P ₃	20	X	0,96	1	1
C ₆	P ₄	282	X	0,93	0,94	1
C ₇	P ₅	740	X	0,96	0,97	0,99
C ₈	P ₅	X	855	0,96	0,93	0,99
C ₉	P ₆	940	X	0,94	0,93	0,99
C ₁₀	P ₆	X	605	0,96	1	0,99
C ₁₁	P ₇	618	450	0,96	0,91	0,99

Conclusão

Para os 6 BACs que puderam ser montados e validados:

- aproximadamente 70% das regiões gênicas puderam ser estendidas em algum sentido;
- de modo geral, não houve ocorrência de quimeras.

Logo, o *pipeline* poderia ser utilizado como uma forma razoavelmente confiável (embora limitada) de montar regiões gênicas, com alguma chance de conseguir estender a montagem até a região promotora do gene.

Referências I



SETUBAL, J.; MEIDANIS, J.

Introduction to computational molecular biology.

1^a ed.

Boston: PWS, 1997.



ALBERTS, B. et al.

Biologia molecular da célula.

5^a ed.

Porto Alegre: Artmed, 2010.



GRIVET, L.; ARRUDA, P.

Sugarcane genomics: depicting the complex genome of an important tropical crop.

Current Opinion in Plant Biology 5:122–127, 2001.

Obrigado!

