

LGN5830 - BIOMETRIA DE MARCADORES GENÉTICOS

AULA 4: MAPAS GENÉTICOS III

Antonio Augusto Franco Garcia
Roland Vencovsky

Departamento de Genética
ESALQ/USP
2007

CONTEÚDO

- 1 ANÁLISES MULTIPONTO**
 - Cadeias de Markov
 - Processo Markoviano Oculto
 - Algoritmo de Lander e Green (1987)
- 2 FUNÇÕES DE MAPEAMENTO**
 - Função de Morgan
 - Função de Haldane
 - Função de Kosambi
- 3 INTRODUÇÃO AO MAPMAKER/EXP**

CONTEÚDO

- 1 ANÁLISES MULTIPONTO
 - Cadeias de Markov
 - Processo Markoviano Oculto
 - Algoritmo de Lander e Green (1987)
- 2 FUNÇÕES DE MAPEAMENTO
 - Função de Morgan
 - Função de Haldane
 - Função de Kosambi
- 3 INTRODUÇÃO AO MAPMAKER/EXP

CONTEÚDO

- 1 ANÁLISES MULTIPONTO
 - Cadeias de Markov
 - Processo Markoviano Oculto
 - Algoritmo de Lander e Green (1987)
- 2 FUNÇÕES DE MAPEAMENTO
 - Função de Morgan
 - Função de Haldane
 - Função de Kosambi
- 3 INTRODUÇÃO AO MAPMAKER/EXP


CONTEÚDO

- 1 ANÁLISES MULTIPONTO**
 - **Cadeias de Markov**
 - Processo Markoviano Oculto
 - Algoritmo de Lander e Green (1987)
- 2 FUNÇÕES DE MAPEAMENTO**
 - Função de Morgan
 - Função de Haldane
 - Função de Kosambi
- 3 INTRODUÇÃO AO MAPMAKER/EXP**

INTRODUÇÃO

- *Material extraído do seminário de Marcelo Mollinari (2007) (Seminários LGN)*

CADEIAS DE MARKOV




PROPRIEDADE MARKOVIANA (RABINER, 1989)

- A probabilidade de ocorrência de um estado no tempo t depende apenas do estado anterior ($t - 1$).
- Em outras palavras, **independência condicional**.
- *“Dado o presente, o futuro não depende do passado”*

INTRODUÇÃO

- *Material extraído do seminário de Marcelo Mollinari (2007) (Seminários LGN)*

CADEIAS DE MARKOV




PROPRIEDADE MARKOVIANA (RABINER, 1989)

- A probabilidade de ocorrência de um estado no tempo t depende apenas do estado anterior ($t - 1$).
- Em outras palavras, **independência condicional**.
- *“Dado o presente, o futuro não depende do passado”*

INTRODUÇÃO

- *Material extraído do seminário de Marcelo Mollinari (2007) (Seminários LGN)*

CADEIAS DE MARKOV




PROPRIEDADE MARKOVIANA (RABINER, 1989)

- A probabilidade de ocorrência de um estado no tempo t depende apenas do estado anterior ($t - 1$).
- Em outras palavras, **independência condicional**.
- *“Dado o presente, o futuro não depende do passado”*

INTRODUÇÃO

- *Material extraído do seminário de Marcelo Mollinari (2007) (Seminários LGN)*

CADEIAS DE MARKOV




PROPRIEDADE MARKOVIANA (RABINER, 1989)

- A probabilidade de ocorrência de um estado no tempo t depende apenas do estado anterior ($t - 1$).
- Em outras palavras, **independência condicional**.
- *“Dado o presente, o futuro não depende do passado”*


PROCESSO MARKOVIANO DISCRETO

EXEMPLO - CONDIÇÕES CLIMÁTICAS




- Seqüência de observações do estado em que o clima se encontra;
- Estados: Chuvoso (S_1), Nublado (S_2) e Ensolarado (S_3);
- Tempo: de 24 em 24 horas, até um dado tempo final T : $T = 1, \dots, T$;

PROCESSO MARKOVIANO



- a_{ij} é a probabilidade do estado atual ser S_j dado que o anterior foi S_i
- Matriz de transição assumida (Modelo)
- As linhas devem somar 1

PROCESSO MARKOVIANO




- a_{ij} é a probabilidade do estado atual ser S_j dado que o anterior foi S_i
- Matriz de transição assumida (**Modelo**)

$$A = \{a_{ij}\} = \begin{array}{c} \begin{array}{ccc} \text{☁} & \text{☁} & \text{☀} \\ \text{☁} & \text{☀} & \text{☀} \\ \text{☀} & \text{☀} & \text{☀} \end{array} \\ \left[\begin{array}{ccc} 0,4 & 0,3 & 0,3 \\ 0,2 & 0,6 & 0,2 \\ 0,1 & 0,1 & 0,8 \end{array} \right] \end{array}$$

- As linhas devem somar 1

PROCESSO MARKOVIANO



- a_{ij} é a probabilidade do estado atual ser S_j dado que o anterior foi S_i
- Matriz de transição assumida (**Modelo**)

$$A = \{a_{ij}\} = \begin{array}{c} \begin{array}{ccc} \text{☁️} & \text{☁️} & \text{☀️} \\ \text{☁️} & \text{☀️} & \text{☀️} \\ \text{☀️} & \text{☀️} & \text{☀️} \end{array} \begin{bmatrix} 0,4 & 0,3 & 0,3 \\ 0,2 & 0,6 & 0,2 \\ 0,1 & 0,1 & 0,8 \end{bmatrix} \end{array}$$

- As linhas devem somar 1


PROCESSO MARKOVIANO

- Pode-se questionar qual é a probabilidade de que nos próximos n dias ocorra uma determinada seqüência de estados.

EXEMPLO

Dia 1	<i>ensolarado</i>
Dia 2	<i>chuvoso</i>
Dia 3	<i>ensolarado</i>
Dia 4	<i>nublado</i>
Dia 5	<i>ensolarado</i>

$$\begin{aligned}
 P(seq|Modelo) &= a_{31} \times a_{13} \times a_{32} \times a_{23} \\
 &= 0,1 \times 0,3 \times 0,1 \times 0,2 \\
 &= 0,0006
 \end{aligned}$$



PROCESSO MARKOVIANO

- Podemos calcular a probabilidade de uma seqüência de observações dado um modelo:

$$P[O|Modelo]$$

- A **verossimilhança** é proporcional à $P[O|Modelo]$
- É possível comparar modelos usando suas verossimilhanças (ou quantidades baseadas na verossimilhança)

PROCESSO MARKOVIANO

- Podemos calcular a probabilidade de uma seqüência de observações dado um modelo:

$$P[O|Modelo]$$

- A **verossimilhança** é proporcional à $P[O|Modelo]$
- É possível comparar modelos usando suas verossimilhanças (ou quantidades baseadas na verossimilhança)

PROCESSO MARKOVIANO

- Podemos calcular a probabilidade de uma seqüência de observações dado um modelo:

$$P[O|Modelo]$$

- A **verossimilhança** é proporcional à $P[O|Modelo]$
- É possível comparar modelos usando suas verossimilhanças (ou quantidades baseadas na verossimilhança)


CONTEÚDO

- 1 ANÁLISES MULTIPONTO
 - Cadeias de Markov
 - **Processo Markoviano Oculto**
 - Algoritmo de Lander e Green (1987)
- 2 FUNÇÕES DE MAPEAMENTO
 - Função de Morgan
 - Função de Haldane
 - Função de Kosambi
- 3 INTRODUÇÃO AO MAPMAKER/EXP


O MODELO DE MARKOV OCULTO

HMM - Hidden Markov Model - (RABINER, 1989)


● Cadeia observável




Urna 1



Urna 2



Urna 3




Urna 4

Tempos	1	2	3	4	5
Estados (Urnas)	4	2	4	3	1
Cores	verde	azul	verde	amarelo	vermelha


O MODELO DE MARKOV OCULTO

HMM - Hidden Markov Model - (RABINER, 1989)


● Cadeia oculta




Urna 1



Urna 2



Urna 3



Urna 4

Tempos	1	2	3	4	5
Cores	verde	azul	verde	amarelo	vermelha


- Levando-se em conta as cores observadas, qual seria a seqüência de estados mais provável?
- As urnas mais prováveis das quais as bolas foram retiradas, dado que foram observadas as cores verde, azul, verde, amarelo e vermelha seriam:

4, 2, 4, 3 e 1


O MODELO DE MARKOV OCULTO

HMM - Hidden Markov Model - (RABINER, 1989)


● Cadeia oculta




Urna 1



Urna 2



Urna 3



Urna 4

Tempos	1	2	3	4	5
Cores	verde	azul	verde	amarelo	vermelha


- Levando-se em conta as cores observadas, qual seria a seqüência de estados mais provável?
- As urnas mais prováveis das quais as bolas foram retiradas, dado que foram observadas as cores verde, azul, verde, amarelo e vermelha seriam:

4, 2, 4, 3 e 1


O MODELO DE MARKOV OCULTO

HMM - Hidden Markov Model - (RABINER, 1989)


● Cadeia oculta




Urna 1



Urna 2



Urna 3



Urna 4

Tempos	1	2	3	4	5
Cores	verde	azul	verde	amarelo	vermelha


- Levando-se em conta as cores observadas, qual seria a seqüência de estados mais provável?
- As urnas mais prováveis das quais as bolas foram retiradas, dado que foram observadas as cores verde, azul, verde, amarelo e vermelha seriam:

4, 2, 4, 3 e 1

O MODELO DE MARKOV OCULTO

FUNÇÃO DE EMISSÃO

- Para cada estado, existe uma função de probabilidade que liga as urnas à cor observada.
- Esta é chamada de **Função de Emissão**



Urna 4


- $P[\text{vermelha}|urna4] = \frac{3}{79}$
- $P[\text{azul}|urna4] = \frac{3}{79}$
- $P[\text{amarela}|urna4] = \frac{3}{79}$
- $P[\text{verde}|urna4] = \frac{70}{79}$

$$P[\text{cor}_j | \text{urna}_i]$$

O MODELO DE MARKOV OCULTO

FUNÇÃO DE EMISSÃO

- Para cada estado, existe uma função de probabilidade que liga as urnas à cor observada.
- Esta é chamada de **Função de Emissão**



Urna 4


- $P[\text{vermelha}|urna4] = \frac{3}{79}$
- $P[\text{azul}|urna4] = \frac{3}{79}$
- $P[\text{amarela}|urna4] = \frac{3}{79}$
- $P[\text{verde}|urna4] = \frac{70}{79}$

$$P[\text{cor}_j | \text{urna}_i]$$

O MODELO DE MARKOV OCULTO

FUNÇÃO DE EMISSÃO

- Para cada estado, existe uma função de probabilidade que liga as urnas à cor observada.
- Esta é chamada de **Função de Emissão**



Urna 4


- $P[\text{vermelha}|urna4] = \frac{3}{79}$
- $P[\text{azul}|urna4] = \frac{3}{79}$
- $P[\text{amarela}|urna4] = \frac{3}{79}$
- $P[\text{verde}|urna4] = \frac{70}{79}$

$$P[\text{cor}_j | \text{urna}_i]$$

O MODELO DE MARKOV OCULTO

FUNÇÃO DE EMISSÃO

- Para cada estado, existe uma função de probabilidade que liga as urnas à cor observada.
- Esta é chamada de **Função de Emissão**




Urna 4

- $P[\text{vermelha}|urna4] = \frac{3}{79}$
- $P[\text{azul}|urna4] = \frac{3}{79}$
- $P[\text{amarela}|urna4] = \frac{3}{79}$
- $P[\text{verde}|urna4] = \frac{70}{79}$

$$P[\text{cor}_j | \text{urna}_i]$$

O MODELO DE MARKOV OCULTO




Associando-se a **função de emissão** e a **matriz de transição**, obtemos a **VEROSSIMILHANÇA** do *HMM*.

$$\sum_{\text{todos } Qs} P(O|Modelo) = P(O|Q, Modelo)P(Q|Modelo), \text{ em que:}$$

O: observações

Q: seqüência de estados

O MODELO DE MARKOV OCULTO



Associando-se a **função de emissão** e a **matriz de transição**, obtemos a **VEROSSIMILHANÇA** do *HMM*.

$$P(O|Modelo) = \sum_{\text{todos } Qs} P(O|Q, Modelo)P(Q|Modelo), \text{ em que:}$$

O: observações


Q: seqüência de estados

CONTEÚDO

- 1 ANÁLISES MULTIPONTO
 - Cadeias de Markov
 - Processo Markoviano Oculto
 - Algoritmo de Lander e Green (1987)
- 2 FUNÇÕES DE MAPEAMENTO
 - Função de Morgan
 - Função de Haldane
 - Função de Kosambi
- 3 INTRODUÇÃO AO MAPMAKER/EXP


LANDER E GREEN, 1987

- Utilizaram Cadeias de Markov para construção de mapas genéticos obtendo **estimativas multipontos**.





- Considerando uma população experimental F_2 , podemos definir uma cadeia com 3 estados:

$$H = \begin{bmatrix} (1-r_k)^2 & 2r_k(1-r_k) & r_k^2 \\ r_k(1-r_k) & (1-r_k)^2 + r_k^2 & r_k(1-r_k) \\ r_k^2 & 2r_k(1-r_k) & (1-r_k)^2 \end{bmatrix}$$




MAPAS GENÉTICOS MULTIPONTO



MAPAS GENÉTICOS MULTIPONTO

- Exemplo de um indivíduo proveniente de uma população experimental F_2



$$H = \begin{bmatrix} (1 - r_k)^2 & 2r_k(1 - r_k) & r_k^2 \\ r_k(1 - r_k) & (1 - r_k)^2 + r_k^2 & r_k(1 - r_k) \\ r_k^2 & 2r_k(1 - r_k) & (1 - r_k)^2 \end{bmatrix}$$


- Podemos calcular a **verossimilhança** da ordem acima:

$$\begin{aligned}
 P(\overbrace{M_1 M_1}^{S_1}, \overbrace{M_2 m_2}^{S_2}, \overbrace{M_3 m_3}^{S_2}, \overbrace{m_4 m_4}^{S_3}, \overbrace{M_5 M_5}^{S_1} | Modelo) &= h_{12} \times h_{22} \times h_{23} \times h_{31} \\
 &= 2r_1(1 - r_1) \times (1 - r_2)^2 + r_2^2 \\
 &\quad \times 2r_3(1 - r_3) \times r_4^2
 \end{aligned}$$

- Podemos calcular $P(M_k \cdots M_l | Modelo)$ para diversas ordens e verificar qual delas possui a maior verossimilhança (ordem mais provável para os dados em questão)

MAPAS GENÉTICOS MULTIPONTO

- Exemplo de um indivíduo proveniente de uma população experimental F_2



$$H = \begin{bmatrix} (1 - r_k)^2 & 2r_k(1 - r_k) & r_k^2 \\ r_k(1 - r_k) & (1 - r_k)^2 + r_k^2 & r_k(1 - r_k) \\ r_k^2 & 2r_k(1 - r_k) & (1 - r_k)^2 \end{bmatrix}$$


- Podemos calcular a **verossimilhança** da ordem acima:

$$\begin{aligned} P(\overbrace{M_1 M_1}^{S_1}, \overbrace{M_2 m_2}^{S_2}, \overbrace{M_3 m_3}^{S_2}, \overbrace{m_4 m_4}^{S_3}, \overbrace{M_5 M_5}^{S_1} | Modelo) &= h_{12} \times h_{22} \times h_{23} \times h_{31} \\ &= 2r_1(1 - r_1) \times (1 - r_2)^2 + r_2^2 \\ &\quad \times 2r_3(1 - r_3) \times r_4^2 \end{aligned}$$

- Podemos calcular $P(M_k \cdots M_l | Modelo)$ para diversas ordens e verificar qual delas possui a maior verossimilhança (ordem mais provável para os dados em questão)

MAPAS GENÉTICOS MULTIPONTO

- Exemplo de um indivíduo proveniente de uma população experimental F_2



$$H = \begin{bmatrix} (1 - r_k)^2 & 2r_k(1 - r_k) & r_k^2 \\ r_k(1 - r_k) & (1 - r_k)^2 + r_k^2 & r_k(1 - r_k) \\ r_k^2 & 2r_k(1 - r_k) & (1 - r_k)^2 \end{bmatrix}$$

- Podemos calcular a **verossimilhança** da ordem acima:

$$\begin{aligned} P(\overbrace{M_1 M_1}^{S_1}, \overbrace{M_2 m_2}^{S_2}, \overbrace{M_3 m_3}^{S_2}, \overbrace{m_4 m_4}^{S_3}, \overbrace{M_5 M_5}^{S_1} | Modelo) &= h_{12} \times h_{22} \times h_{23} \times h_{31} \\ &= 2r_1(1 - r_1) \times (1 - r_2)^2 + r_2^2 \\ &\quad \times 2r_3(1 - r_3) \times r_4^2 \end{aligned}$$

- Podemos calcular $P(M_k \cdots M_l | Modelo)$ para diversas ordens e verificar qual delas possui a maior verossimilhança (ordem mais provável para os dados em questão)

MODELO DE MARKOV OCULTO

- Marcadores dominantes e/ou dados não observáveis (perdidos) não possibilitam saber com certeza qual é o genótipo de um determinado fenótipo molecular.
- Utilizamos probabilidades de emissão para tratar este problema.

EXEMPLO - F_2

MODELO DE MARKOV OCULTO


- Marcadores dominantes e/ou dados não observáveis (perdidos) não possibilitam saber com certeza qual é o genótipo de um determinado fenótipo molecular.
- Utilizamos probabilidades de emissão para tratar este problema.

EXEMPLO - F_2

MODELO DE MARKOV OCULTO

- Marcadores dominantes e/ou dados não observáveis (perdidos) não possibilitam saber com certeza qual é o genótipo de um determinado fenótipo molecular.
- Utilizamos probabilidades de emissão para tratar este problema.

EXEMPLO - F_2



HMM


- Imaginemos que no indivíduo do exemplo anterior, o marcador M_2 é dominante e o marcador M_4 não foi observado.
- Nesse caso, usamos as probabilidades de emissão.

HMM

- Imaginemos que no indivíduo do exemplo anterior, o marcador M_2 é dominante e o marcador M_4 não foi observado.
- Nesse caso, usamos as probabilidades de emissão.

HMM

- Imaginemos que no indivíduo do exemplo anterior, o marcador M_2 é dominante e o marcador M_4 não foi observado.
- Nesse caso, usamos as probabilidades de emissão.



HMM

Com o modelo contendo as probabilidades de emissão e de transição, é possível:

- Reconstruir o mapa, ou seja, podemos estimar as probabilidades dos dados **não observados** usando as probabilidades de transição e de emissão.

	M_1 M_1	M_2 —	M_3 m_3	— —	M_5 M_5
M M	1,00	0,27	0,00	0,27	1,00
M m	0,00	0,73	1,00	0,53	0,00
m m	0,00	0,00	0,00	0,20	0,00

- Calcular $P(M_k \cdots M_l | Modelo)$.

HMM

Com o modelo contendo as probabilidades de emissão e de transição, é possível:

- Reconstruir o mapa, ou seja, podemos estimar as probabilidades dos dados **não observados** usando as probabilidades de transição e de emissão.

	M_1 M_1	M_2 —	M_3 m_3	— —	M_5 M_5
M M	1,00	0,27	0,00	0,27	1,00
M m	0,00	0,73	1,00	0,53	0,00
m m	0,00	0,00	0,00	0,20	0,00

- Calcular $P(M_k \cdots M_l | Modelo)$.

ANÁLISES MULTIPONTO

PROBLEMA

- Como estimar os parâmetros (frações de recombinação) do modelo?
- **Resp:** Usando o algoritmo EM
- Através do algoritmo EM, obtemos estimativas multiponto de máxima verossimilhança das frações de recombinação entre os marcadores
- Com isso completa-se a construção do mapa: estimativa da **ordem** e das **distâncias**
- Note que todas as frações de recombinação são estimadas simultaneamente.
- Sempre que possível, essa **abordagem multiponto** deve ser empregada, já que produz resultados muito superiores

ANÁLISES MULTIPONTO

PROBLEMA

- Como estimar os parâmetros (frações de recombinação) do modelo?
 - **Resp:** Usando o algoritmo EM
-
- Através do algoritmo EM, obtemos estimativas multiponto de máxima verossimilhança das frações de recombinação entre os marcadores
 - Com isso completa-se a construção do mapa: estimativa da **ordem** e das **distâncias**
 - Note que todas as frações de recombinação são estimadas simultaneamente.
 - Sempre que possível, essa **abordagem multiponto** deve ser empregada, já que produz resultados muito superiores

ANÁLISES MULTIPONTO

PROBLEMA

- Como estimar os parâmetros (frações de recombinação) do modelo?
 - **Resp:** Usando o algoritmo EM
-
- Através do algoritmo EM, obtemos estimativas multiponto de máxima verossimilhança das frações de recombinação entre os marcadores
 - Com isso completa-se a construção do mapa: estimativa da **ordem** e das **distâncias**
 - Note que todas as frações de recombinação são estimadas simultaneamente.
 - Sempre que possível, essa **abordagem multiponto** deve ser empregada, já que produz resultados muito superiores

ANÁLISES MULTIPONTO

PROBLEMA

- Como estimar os parâmetros (frações de recombinação) do modelo?
 - **Resp:** Usando o algoritmo EM
-
- Através do algoritmo EM, obtemos estimativas multiponto de máxima verossimilhança das frações de recombinação entre os marcadores
 - Com isso completa-se a construção do mapa: estimativa da **ordem** e das **distâncias**
 - Note que todas as frações de recombinação são estimadas simultaneamente.
 - Sempre que possível, essa **abordagem multiponto** deve ser empregada, já que produz resultados muito superiores

ANÁLISES MULTIPONTO

PROBLEMA

- Como estimar os parâmetros (frações de recombinação) do modelo?
 - **Resp:** Usando o algoritmo EM
-
- Através do algoritmo EM, obtemos estimativas multiponto de máxima verossimilhança das frações de recombinação entre os marcadores
 - Com isso completa-se a construção do mapa: estimativa da **ordem** e das **distâncias**
 - Note que todas as frações de recombinação são estimadas simultaneamente.
 - Sempre que possível, essa **abordagem multiponto** deve ser empregada, já que produz resultados muito superiores

FRAÇÃO DE RECOMBINAÇÃO vs DISTÂNCIA

- Desenvolvidas para corrigir os problemas decorrentes do fato das frações de recombinação não serem aditivas
- Relação: $r_{12} = r_1 + r_2 - 2Cr_1r_2$
- $m_{ij} = f(r_{ij})$
- Unidade para m_{ij} : Morgan ou cM

FRAÇÃO DE RECOMBINAÇÃO vs DISTÂNCIA

- Desenvolvidas para corrigir os problemas decorrentes do fato das frações de recombinação não serem aditivas
- Relação: $r_{12} = r_1 + r_2 - 2Cr_1r_2$
- $m_{ij} = f(r_{ij})$
- Unidade para m_{ij} : Morgan ou cM

FRAÇÃO DE RECOMBINAÇÃO vs DISTÂNCIA

- Desenvolvidas para corrigir os problemas decorrentes do fato das frações de recombinação não serem aditivas
- Relação: $r_{12} = r_1 + r_2 - 2Cr_1r_2$
- $m_{ij} = f(r_{ij})$
- Unidade para m_{ij} : Morgan ou cM

FRAÇÃO DE RECOMBINAÇÃO vs DISTÂNCIA


- Desenvolvidas para corrigir os problemas decorrentes do fato das frações de recombinação não serem aditivas
- Relação: $r_{12} = r_1 + r_2 - 2Cr_1r_2$
- $m_{ij} = f(r_{ij})$
- Unidade para m_{ij} : Morgan ou cM

CONTEÚDO

- 1 ANÁLISES MULTIPONTO
 - Cadeias de Markov
 - Processo Markoviano Oculto
 - Algoritmo de Lander e Green (1987)
- 2 FUNÇÕES DE MAPEAMENTO
 - **Função de Morgan**
 - Função de Haldane
 - Função de Kosambi
- 3 INTRODUÇÃO AO MAPMAKER/EXP


MORGAN, 1928

- $m_{ij} = r_{ij}$
- Uso: apenas para pequenos segmentos cromossômicos




MORGAN, 1928

- $m_{ij} = r_{ij}$
- Uso: apenas para pequenos segmentos cromossômicos



MORGAN, 1928

- $m_{ij} = r_{ij}$
- Uso: apenas para pequenos segmentos cromossômicos




CONTEÚDO

- 1 ANÁLISES MULTIPONTO
 - Cadeias de Markov
 - Processo Markoviano Oculto
 - Algoritmo de Lander e Green (1987)
- 2 FUNÇÕES DE MAPEAMENTO
 - Função de Morgan
 - **Função de Haldane**
 - Função de Kosambi
- 3 INTRODUÇÃO AO MAPMAKER/EXP


HALDANE

- Pressuposições:
 - Ausência de interferência ($C = 1$)
 - Distribuição de Poisson para os crossing-over
- $m_{ij} = -\frac{1}{2}\log(1 - 2r_{ij})$
- Note que as distâncias são agora aditivas




HALDANE

- Pressuposições:
 - Ausência de interferência ($C = 1$)
 - Distribuição de Poisson para os crossing-over
- $m_{ij} = -\frac{1}{2}\log(1 - 2r_{ij})$
- Note que as distâncias são agora aditivas



HALDANE

- Pressuposições:
 - Ausência de interferência ($C = 1$)
 - Distribuição de Poisson para os crossing-over
- $m_{ij} = -\frac{1}{2}\log(1 - 2r_{ij})$
- Note que as distâncias são agora aditivas




CONTEÚDO

- 1 ANÁLISES MULTIPONTO
 - Cadeias de Markov
 - Processo Markoviano Oculto
 - Algoritmo de Lander e Green (1987)
- 2 FUNÇÕES DE MAPEAMENTO
 - Função de Morgan
 - Função de Haldane
 - Função de Kosambi
- 3 INTRODUÇÃO AO MAPMAKER/EXP


KOSAMBI

- Extensão da função de Haldane
- Baseia-se em observações empíricas:
 - Se r_1 e r_2 são pequenas, $r_{12} \sim r_1 + r_2$ ($C = 0$)
 - Se r_1 e r_2 são medianas, $r_{12} \sim r_1 + r_2 + r_1 r_2$ ($C = 1/2$)
 - Se r_1 e r_2 são grandes, $r_{12} \sim r_1 + r_2 - 2r_1 r_2$ ($C = 1$)
- $m_{ij} = \frac{1}{4} \log \frac{1+2r_{ij}}{1-2r_{ij}}$
- Geralmente, mais adequada que a função de Haldane




KOSAMBI

- Extensão da função de Haldane
- Baseia-se em observações empíricas:
 - Se r_1 e r_2 são pequenas, $r_{12} \sim r_1 + r_2$ ($C = 0$)
 - Se r_1 e r_2 são medianas, $r_{12} \sim r_1 + r_2 + r_1 r_2$ ($C = 1/2$)
 - Se r_1 e r_2 são grandes, $r_{12} \sim r_1 + r_2 - 2r_1 r_2$ ($C = 1$)
- $m_{ij} = \frac{1}{4} \log \frac{1+2r_{ij}}{1-2r_{ij}}$
- Geralmente, mais adequada que a função de Haldane




KOSAMBI

- Extensão da função de Haldane
- Baseia-se em observações empíricas:
 - Se r_1 e r_2 são pequenas, $r_{12} \sim r_1 + r_2$ ($C = 0$)
 - Se r_1 e r_2 são medianas, $r_{12} \sim r_1 + r_2 + r_1 r_2$ ($C = 1/2$)
 - Se r_1 e r_2 são grandes, $r_{12} \sim r_1 + r_2 - 2r_1 r_2$ ($C = 1$)
- $m_{ij} = \frac{1}{4} \log \frac{1+2r_{ij}}{1-2r_{ij}}$
- Geralmente, mais adequada que a função de Haldane




KOSAMBI

- Extensão da função de Haldane
- Baseia-se em observações empíricas:
 - Se r_1 e r_2 são pequenas, $r_{12} \sim r_1 + r_2$ ($C = 0$)
 - Se r_1 e r_2 são medianas, $r_{12} \sim r_1 + r_2 + r_1 r_2$ ($C = 1/2$)
 - Se r_1 e r_2 são grandes, $r_{12} \sim r_1 + r_2 - 2r_1 r_2$ ($C = 1$)
- $m_{ij} = \frac{1}{4} \log \frac{1+2r_{ij}}{1-2r_{ij}}$
- Geralmente, mais adequada que a função de Haldane




KOSAMBI

- Extensão da função de Haldane
- Baseia-se em observações empíricas:
 - Se r_1 e r_2 são pequenas, $r_{12} \sim r_1 + r_2$ ($C = 0$)
 - Se r_1 e r_2 são medianas, $r_{12} \sim r_1 + r_2 + r_1 r_2$ ($C = 1/2$)
 - Se r_1 e r_2 são grandes, $r_{12} \sim r_1 + r_2 - 2r_1 r_2$ ($C = 1$)
- $m_{ij} = \frac{1}{4} \log \frac{1+2r_{ij}}{1-2r_{ij}}$
- Geralmente, mais adequada que a função de Haldane



KOSAMBI

- Extensão da função de Haldane
- Baseia-se em observações empíricas:
 - Se r_1 e r_2 são pequenas, $r_{12} \sim r_1 + r_2$ ($C = 0$)
 - Se r_1 e r_2 são medianas, $r_{12} \sim r_1 + r_2 + r_1 r_2$ ($C = 1/2$)
 - Se r_1 e r_2 são grandes, $r_{12} \sim r_1 + r_2 - 2r_1 r_2$ ($C = 1$)
- $m_{ij} = \frac{1}{4} \log \frac{1+2r_{ij}}{1-2r_{ij}}$
- Geralmente, mais adequada que a função de Haldane



MAPMAKER/EXP

- Análise dos dados de Stuber et al. 1992