

## ***Conceitos fundamentais:***

*Comprimento de ramo*

*Estimativas de tempo absoluto*

*Suporte e resolução*

*Descrição de relações de parentesco*

*Notação parentética*

*Diagramas (árvores) de consenso*


*Cosenso estrito*

*Consenso de maioria*


# O desenvolvimento da Cladística

## Dados moleculares e modelos probabilísticos

Aristóteles – 384-322 A.C.



Darwin  
1809-1882



1859

Período essencialista

Mundo dinâmico

Resistência e Nova Síntese

Sistemática Evolutiva

1936 - 1947

1960's

Fenética

1970's

Cladística

1990's

Probabilismo

Carolus Linnaeus  
1707-1778



Buffon  
1707-1788



Lamarck  
1744 -1829




St-Hilair  
1772 -1844




Cuvier  
1769 -1832



Ernest Mayr  
1904 - 2005



Paul Erlich



G.G. Simpson  
1902 - 1984




Theodosius Dobzhansky  
1900 -1975



James Rohlf R. Sokal  
1926 -



Willi Hennig  
1913 - 1976



Steve Farris



Joe Felsenstein



David Hillis



# Motivação para o uso de Verossimilhança:





FIG. 3.—True unknown phylogeny (with root omitted) used to find cases in which unrooted Wagner tree parsimony methods will be inconsistent.



Joe Felsenstein  
University of  
Washington

## CASES IN WHICH PARSIMONY OR COMPATIBILITY METHODS WILL BE POSITIVELY MISLEADING<sup>1</sup>

JOSEPH FELSENSTEIN

### *Abstract*

Felsenstein, J. (Department of Genetics, University of Washington, Seattle, WA 98195) 1978. Cases in which parsimony or compatibility methods will be positively misleading. *Syst. Zool.* 27:401-410.—For some simple three- and four-species cases involving a character with two states, it is determined under what conditions several methods of phylogenetic inference will fail to converge to the true phylogeny as more and more data are accumulated. The methods are the Camin-Sokal parsimony method, the compatibility method, and Farris's unrooted Wagner tree parsimony method. In all cases the conditions for this failure (which is the failure to be statistically consistent) are essentially that parallel changes exceed informative, nonparallel changes. It is possible for these methods to be inconsistent even when change is improbable a priori, provided that evolutionary rates in different lineages are sufficiently unequal. It is by extension of this approach that we may provide a sound methodology for evaluating methods of phylogenetic inference. [Numerical cladistics; phylogenetic inference; maximum likelihood estimation; parsimony; compatibility.]

Parsimony or minimum evolution methods were first introduced into phylogenetic inference by Camin and Sokal (1965). This class of methods for inferring an evolutionary tree from discrete-character data involves making a reconstruction of the changes in a given set of characters on a given tree, counting the smallest number of times that a given kind of event need have happened, and using this as the measure of the adequacy of the evolutionary tree. (Alternatively, one can compute the weighted sum of the numbers of times several different kinds of events have occurred.) One attempts to find that evolutionary tree which requires the fewest of these evolutionary events to explain the observed data. Camin and Sokal treated the case of irreversible changes along a character state tree, minimizing the number of changes

of character states required. A number of other parsimony methods have since appeared in the systematic literature (Kluge and Farris, 1969; Farris, 1969, 1970, 1972, 1977; Farris, Kluge, and Eckhardt, 1970) and parsimony methods have also found widespread use in studies of molecular evolution (Fitch and Margoliash, 1967, 1970; Dayhoff and Eck, 1968; see also Fitch, 1973). Cavalli-Sforza and Edwards (1967; Edwards and Cavalli-Sforza, 1964) earlier formulated a minimum evolution method for continuous-character data.

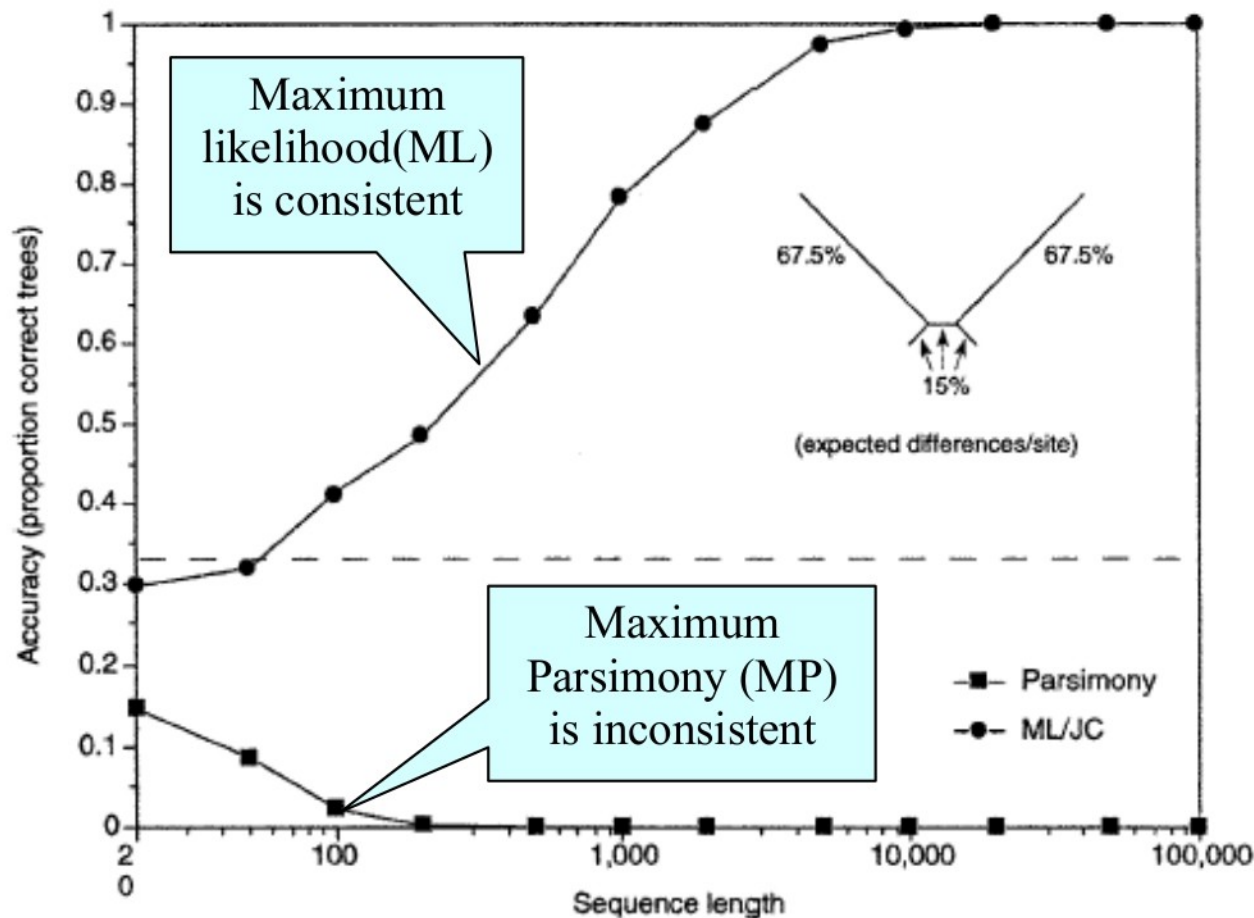
An alternative methodology for phylogenetic inference is the compatibility method, introduced by Le Quesne (1969, 1972). He suggested that phylogenetic inference be based on finding the largest possible set of characters which could simultaneously have all states be uniquely derived on the same tree. The estimate of the phylogeny is then taken to be that tree. While Le Quesne's specific suggestions as to how this might be done have been criticized by Farris (1969), his general approach, which is based on Camin and Sokal's (1965) concept of the compatibility of two characters, has been made rigorous and extended in a series of papers by G. F. Estabrook, C. S. Johnson, Jr., and F. R. McMorris (Estabrook,

<sup>1</sup> This report was prepared as an account of work sponsored by the United States Government. Neither the United States nor the United States Department of Energy, nor any of their employees, nor any of their contractors, subcontractors, or their employees, makes any warranty, express or implied, or assumes any legal liability or responsibility for the accuracy, completeness or usefulness of any information, apparatus, product or process disclosed, or represents that its use would not infringe privately-owned rights.



# Motivação para o uso de Verossimilhança:

## "Felsenstein Zone" Trees




Accuracy is proportion correct out of 1000 simulation replicates

Dashed line is 1/3, the probability of getting the tree correct by pure random chance


Fig. 3, p. 531, from Swofford et al. 2001. Bias in phylogenetic estimation and its relevance to the choice between parsimony and likelihood methods. *Systematic Biology* 50: 525-539.

*Motivação pára o uso de Verossimilhança:*

ML



MP



# O que é verossimilhança?



Sir Ronald Aylmer Fisher  
(17 February 1890 – 29 July  
1962)

$$L(\theta|x) \approx P(x|\theta)$$

A verossimilhança ( $L$ ) de um conjunto de parâmetros ( $\theta$ ), dado alguma observação ( $x$ ) é proporcional a probabilidade daquela observação ter ocorrido dados os valores daqueles parâmetros.

**Parâmetros** estatísticos podem ser vistos como as características numéricas de um modelo.

Um **modelo** estatístico é a formalização matemática da relação entre variáveis que correspondem a observações potenciais que inclui a descrição das incertezas sobre estas observações devido à variabilidade natural, erros ou informação incompleta.

# O que é verossimilhança?



Sir Ronald Aylmer Fisher  
(17 February 1890 – 29 July  
1962)

$$L(\theta|x) \approx P(x|\theta)$$

$$f(k; n, p) = \binom{n}{k} p^k (1-p)^{n-k}$$

**Parâmetros** estatísticos podem ser vistos como as características numéricas de um modelo.

Um **modelo** estatístico é a formalização matemática da relação entre variáveis que correspondem a observações potenciais que inclui a descrição das incertezas sobre estas observações devido à variabilidade natural, erros ou informação incompleta.

# *Estimativa de parâmetros:*



Sir Ronald Aylmer Fisher  
(17/02/1890 – 29/07/1962)

$$L(\theta|x) \approx P(x|\theta)$$

Fisher (1912) empregou a função de verossimilhança  $f(\theta|x)$  com a ideia de que o(s) valor(es) de  $\theta$  que maximizam a probabilidade dos dados observados ( $x$ ) seria um bom estimador de  $\theta$ .

Qual é a probabilidade de uma estudante portador de XX fazer uma pergunta durante a aula?



# *Estimativa de parâmetros:*

## Modelo probabilístico:

Em teoria das probabilidades e estatística, a **distribuição binomial** é a distribuição de probabilidade discreta do número de sucessos numa sequência de tentativas tais que:

Cada tentativa tem exclusivamente como resultado duas possibilidades, sucesso ou fracasso (binomial, a que se chama de tentativa de Bernoulli), e;

Cada tentativa é independente das demais, e;

A probabilidade de sucesso a cada tentativa permanece constante independente das demais, e;

A variável de interesse, ou pretendida, é o número de sucessos nas tentativas

# *Estimativa de parâmetros:*

Qual é a probabilidade de uma estudante do sexo feminino fazer uma pergunta durante a aula?

## Modelo probabilístico:

Em teoria das probabilidades e estatística, a **distribuição binomial** é a distribuição de probabilidade discreta do número de sucessos numa sequência de tentativas.

$$f(k; n, p) = \binom{n}{k} p^k (1-p)^{n-k}$$

onde  $k$  é no número de eventos de sucesso (i.e., pergunta de aluna),  $n$  é o número de perguntas feitas, e  $p$  é a probabilidade deste evento ocorrer, neste caso, ele é o parâmetro ( $\theta$ ) que queremos estimar.

# *Estimativa de parâmetros:*

Qual é a probabilidade de uma estudante do sexo feminino fazer uma pergunta durante a aula?

## Modelo probabilístico:

Em teoria das probabilidades e estatística, a **distribuição binomial** é a distribuição de probabilidade discreta do número de sucessos numa sequência de tentativas .

$$f(k; n, p) = \binom{n}{k} p^k (1-p)^{n-k}$$

## Observações de perguntas em PSB 2016:

104 perguntas em 3 aulas

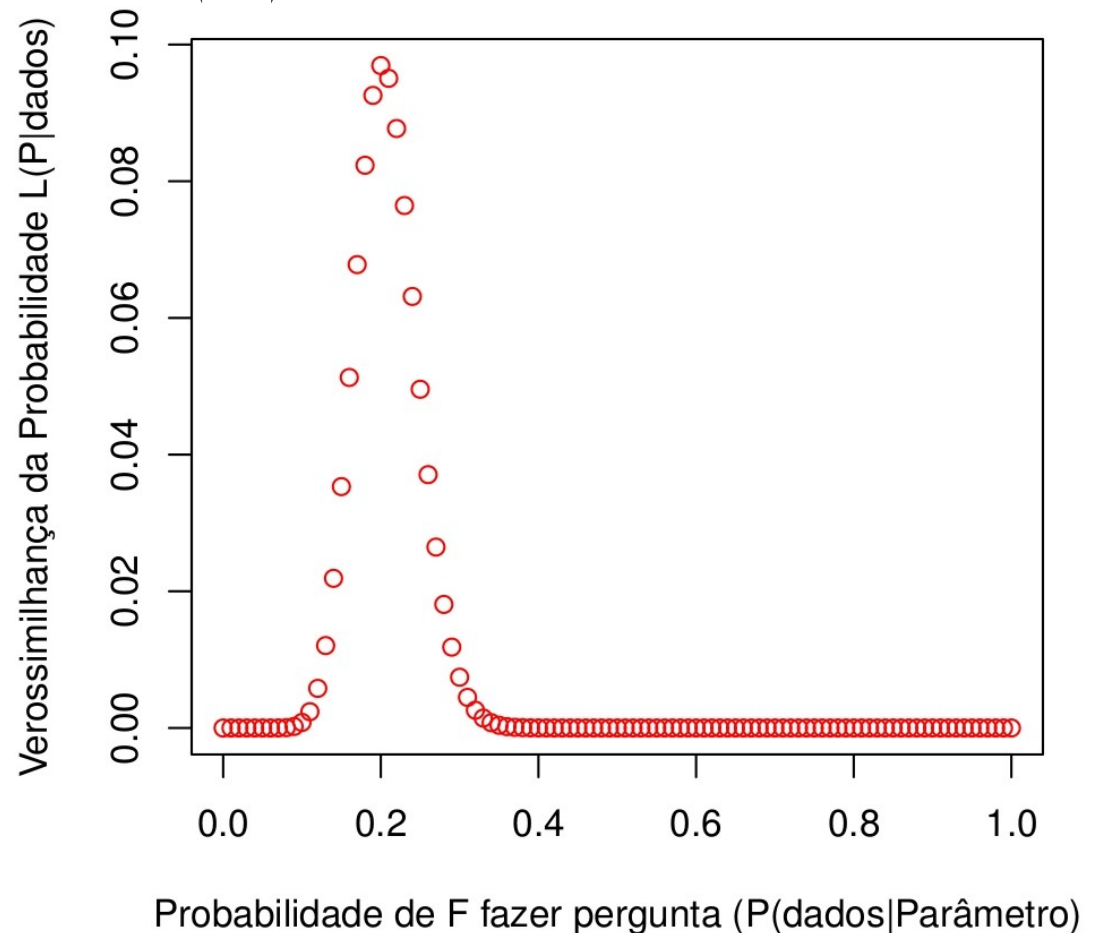
21 provenientes de portadores de XX

# Estimativa de parâmetros:

Modelo probabilístico:

$$f(21; 104, \theta) = \binom{n}{k} p^k (1-p)^{n-k}$$

$$L(\theta|x) \approx P(x|\theta)$$



# Verossimilhanças e seleção de modelos:



Sir Ronald Aylmer Fisher  
(17/02/1890 – 29/07/1962)

$$L(\theta|x) \approx P(x|\theta)$$

Fisher (1912) empregou a função de verossimilhança  $f(\theta|x)$  com a ideia de que o(s) valor(es) de  $\theta$  que maximizam a probabilidade dos dados observados ( $x$ ) seria um bom estimador de  $\theta$ .

# Cálculo de probabilidades:

**Regra 1a:** A probabilidade de um evento **A** ocorrer é  $P_{(A)} = A/S$ , onde S é o espaço de soluções possíveis.

**Regra 1b:** A probabilidade de um evento **A** não ocorrer é  $P_{(A^c)} = 1 - P_{(A)}$




Copyright © Ron Leishman

$$P_{(\text{1})} = A/S = 1/6$$

$$P_{(\text{1})^c} = 1 - P_{(A)} = 1 - 1/6$$

Se dois eventos não possuem soluções em comum, eles são chamados de **disjuntos** e suas probabilidades obedecem à seguinte regra:




**Regra 2:** Se dois eventos A e B são disjuntos, então a probabilidade de qualquer um destes eventos e a soma das probabilidades dos dois eventos:  $P_{(A \text{ ou } B)} = P_{(a)} + P_{(b)}$



# Probabilidades e modelos

Considere que você jogue dois dados:



A probabilidade de obter “olhos de serpente” é expressa pela seguinte regra:











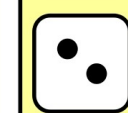
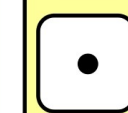
**Regra 3:** Se dois eventos A e B são independentes, então a probabilidade dos dois eventos ocorrerem um após o outro (i.e., intersecção de eventos, ou **probabilidade conjunta**) é o produto das probabilidades de cada evento:  $P_{(A \text{ e } B)} = P_{(A)} * P_{(B)}$ .

## Combinando as regras:

Qual a probabilidade de se obter a soma 7 ao jogar dois dados?

E

$1/6 * 1/6$

$(1/36)+(1/36)+(1/36)+(1/36)+(1/36)+(1/36) = 1/6$

OU      OU      OU      OU      OU


# *Verossimilhanças e seleção de modelos:*

$$L(\theta|x) \approx P(x|\theta)$$


Considere:

Você jogou 20 dados sobre uma mesa e todos apresentaram 5!  
Portanto:

$x =$



$$L(\theta|x) \approx P(x|\theta)$$



Considere que você deseja avaliar a  $L$  de dois modelos ( $\theta_1$  e  $\theta_2$ ):


**Modelo 1** ( $\theta_1$ ) – dado honesto – assume que cada face do dado possui um número de 1 a 6 cuja a probabilidade conjunta (i.e.,  $P_{(A \text{ e } B)} = P_{(A)} \times P_{(B)}$ ) de obter 20 dados apresentando 5 é igual a  $(1/6)^{20}$ .

**Modelo 2** ( $\theta_2$ ) – dado duvidoso (Feito em **Brasilia/DF**) – assume que todas as faces do dado tem o número 5. Portanto, a probabilidade conjunta (i.e.,  $P_{(A \text{ e } B)} = P_{(A)} \times P_{(B)}$ ) de obter 20 dados apresentando 5 é igual a  $(1)^{20}$ .

Um **modelo** estatístico é a formalização matemática da relação entre variáveis que correspondem a observações potenciais que inclui a descrição das incertezas sobre estas observações devido à variabilidade natural, erros ou informação incompleta.

# Verossimilhanças e seleção de modelos:

$$L(\theta|x) \approx P(x|\theta)$$



Considere que você deseja avaliar a  $L$  de dois modelos ( $\theta_1$  e  $\theta_2$ ):

**Modelo 1** ( $\theta_1$ ) – dado honesto – assume que cada face do dado possui um número de 1 a 6 cuja a probabilidade conjunta (i.e.,  $P_{(A \text{ e } B)} = P_{(A)} \times P_{(B)}$ ) de obter 20 dados apresentando 5 é igual a  $(1/6)^{20}$ .

$$L(\theta_1|x) \approx P_{(x|\theta_1)} = (1/6)^{20} = 1/3.656.158.440.062.976$$

**Modelo 2** ( $\theta_2$ ) – dado duvidoso – assume que todas as faces do dado tem o número 5. Portanto, a probabilidade conjunta (i.e.,  $P_{(A \text{ e } B)} = P_{(A)} \times P_{(B)}$ ) de obter 20 dados apresentando 5 é igual a  $(1)^{20}$ .

$$L(\theta_2|x) \approx P_{(x|\theta_2)} = (1)^{20} = 1$$

# Verossimilhança vs. Probabilidade

$$x = \text{[16 dice icons]} = \text{observação} = O$$

**Modelo 1** ( $\theta_1$ ) – dado honesto = Hipótese 1 =  $H_1$

**Modelo 2** ( $\theta_2$ ) – dado duvidoso = Hipótese 2 =  $H_2$

$$L(\theta|x) \approx P(x|\theta) \quad x = \text{[16 dice icons]}$$

$$P(O|H) \neq P(H|O)$$

# Verossimilhança vs. Probabilidade

$$P(O|H) \neq P(H|O)$$

Considere:

$O$  = Professor ouve um barulho na goiabeira.

$H$  = Jesus subiu na goiabeira.

$$L_{(H|O)} \approx P_{(O|H)} = \text{Alta}$$

A verossimilhança desta hipótese é muito alta, pois se Jesus subiu na goiabeira, a probabilidade de haver barulho é alta.

$$P_{(H|O)} = \text{Baixa}$$

No entanto, certamente você não pensa que o barulho é evidência (torna-se provável) de que Jesus subiu na goiabeira!!!\*



\* O MDH adverte: a Ministra de Estado da Mulher, da Família e dos Direitos Humanos discorda!



# Voltemos a ideia original:

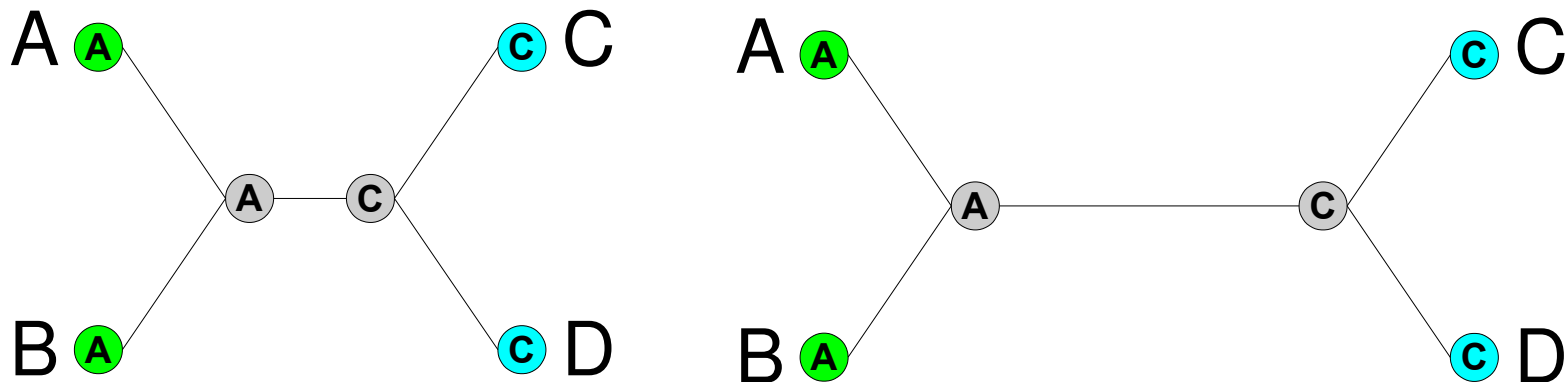


Sir Ronald Aylmer Fisher  
(17/02/1890 – 29/07/1962)

$$L(\theta|x) \approx P(x|\theta)$$

Fisher (1912) empregou a função de verossimilhança  $f(\theta|x)$  com a ideia de que o(s) valor(es) de  $\theta$  que maximizam a probabilidade dos dados observados ( $x$ ) seria um bom estimador de  $\theta$ .

## Estimativa de máxima verossimilhança: TOPOLOGIA 1



Relevância da estimativa de comprimento de ramos

# Voltemos a ideia original:



Sir Ronald Aylmer Fisher  
(17/02/1890 – 29/07/1962)

$$L(\theta|x) \approx P(x|\theta)$$

Fisher (1912) empregou a função de verossimilhança  $f(\theta|x)$  com a ideia de que o(s) valor(es) de  $\theta$  que maximizam a probabilidade dos dados observados ( $x$ ) seria um bom estimador de  $\theta$ .

Estimativa de máxima verossimilhança:

OTU **CCACGTACGTACGTACGTACGTACGTACGTACGTAC**



$$\theta = \alpha t = v$$

onde  $v$  é a "distância evolutiva entre essas sequências."

HTU **TTACGTACGTACGTACGTACGTACGTACGTACGTAC**

# Voltemos a ideia original:



Sir Ronald Aylmer Fisher  
(17/02/1890 – 29/07/1962)

$$L(\theta|x) \approx P(x|\theta)$$

Qual o valor de  $\theta$  que maximiza a probabilidade dos dados observados?

Estimativa de máxima verossimilhança:

OTU **CCACGTACGTACGTACGTACGTACGTACGTACGTAC**



$$\theta = \alpha t = v$$

onde  $v$  é a “distância evolutiva entre essas sequências.

HTU **TTACGTACGTACGTACGTACGTACGTACGTACGTAC**

# Voltemos a ideia original:

$$L(\theta|x) \approx P(x|\theta)$$

Qual o valor de  $\theta$  que maximiza a probabilidade dos dados observados?

Estimativa de máxima verossimilhança:

probabilidade de não mudança de estado\*

OTU **CCACGTACGTACGTACGTACGTACGTACGTACGTAC**

$$P(ii) = \left[ \left( \frac{1}{4} \right) * \left( \frac{1}{4} + \frac{3}{4} e^{-4v} \right) \right]$$



$$\theta = \alpha t = v$$

probabilidade de mudança de estado\*

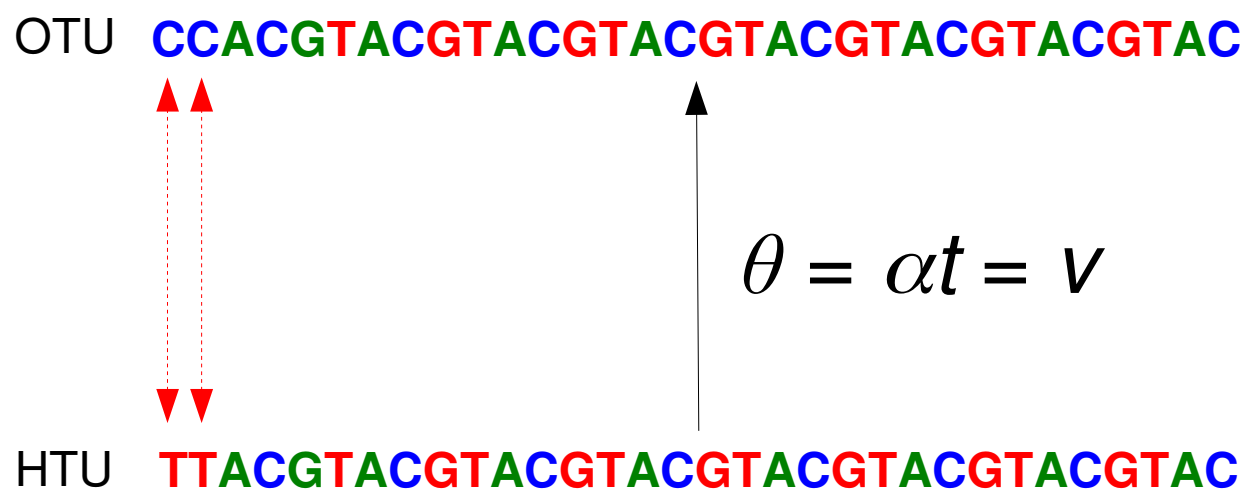
HTU **TTACGTACGTACGTACGTACGTACGTACGTACGTAC**

$$P(ij) = \left[ \left( \frac{1}{4} \right) * \left( \frac{1}{4} - \frac{1}{4} e^{-4v} \right) \right]$$

\* baseado no modelo de JC69 (distribuição de Poisson) e frequências iguais de pares de base.

# Voltemos a ideia original:

Estimativa de **máxima** verossimilhança:



probabilidade de não  
mudança de estado\*

$$P(ii) = \left[ \left( \frac{1}{4} \right) * \left( \frac{1}{4} + \frac{3}{4} e^{-4v} \right) \right]$$

probabilidade de  
mudança de estado\*

$$P(ij) = \left[ \left( \frac{1}{4} \right) * \left( \frac{1}{4} - \frac{1}{4} e^{-4v} \right) \right]$$

$$L = \left[ \left( \frac{1}{4} \right) * \left( \frac{1}{4} - \frac{1}{4} e^{-4v} \right) \right]^2 * \left[ \left( \frac{1}{4} \right) * \left( \frac{1}{4} + \frac{3}{4} e^{-4v} \right) \right]^{30}$$

\* baseado no modelo de JC69 (distribuição de Poisson) e frequências iguais de pares de base.

# Voltemos a ideia original:




Sir Ronald Aylmer Fisher  
(17/02/1890 – 29/07/1962)

$$L(\theta|x) \approx P(x|\theta)$$

Qual o valor de  $\theta$  que maximiza a probabilidade dos dados observados?

$$L = \left[ \left( \frac{1}{4} \right) * \left( \frac{1}{4} - \frac{1}{4} e^{-4v} \right) \right]^2 * \left[ \left( \frac{1}{4} \right) * \left( \frac{1}{4} + \frac{3}{4} e^{-4v} \right) \right]^{30}$$

Estimativa de Máxima Verossimilhança (v)



Estimativa de distância evolutiva (v)

Valor estimado para v: 0.021752



# Lógica da inferência filogenética


Avaliação e critério de seleção: soluções possíveis

Critério de seleção: **verossimilhança**  
(*Likelihood*)

A probabilidade das observações calculadas utilizando **um modelo** nos diz o quão surpresos nós estaríamos com os dados observados

*O modelo escolhido é aquele que menos surpreende!*

Considere que eu jogue 20 dados sobre uma mesa e obtenha o seguinte resultados:



Obtenção de dados  
[observação]

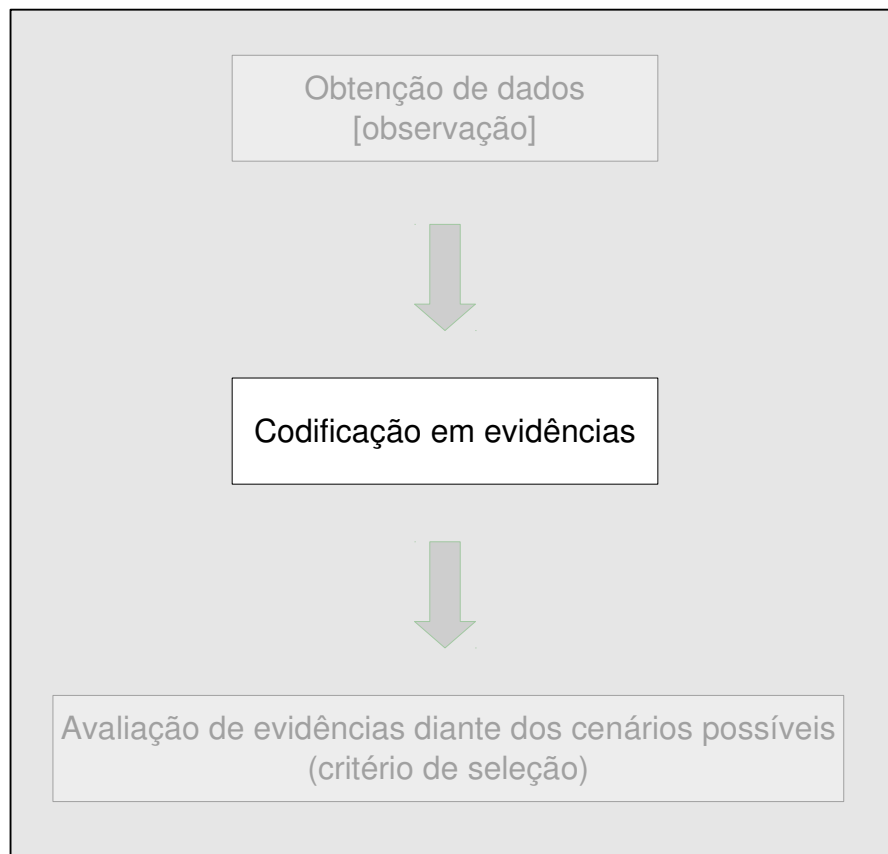


Codificação em evidências



Avaliação de evidências diante dos cenários possíveis  
(critério de seleção)

# Lógica da inferência filogenética



↓ ↓ ↓  
 sp.X CTGGCTACGT  
 sp.A TGGAGTAAGT  
 sp.B CCTAGCAAGT  
 sp.C CCTGATTGCA

## Parcimônia:

EVIDÊNCIAS: transformação de estados de caracteres


- 1a. posição: C ↔ T
- 3a. posição: G ↔ T
- 10a. posição: T ↔ A

CODIFICAÇÃO: matriz de dados

	c <sub>1</sub>	c <sub>2</sub>	c <sub>3</sub>	c <sub>4</sub>	c <sub>5</sub>	c <sub>6</sub>	c <sub>7</sub>	c <sub>8</sub>	c <sub>9</sub>	c <sub>10</sub>
sp.X	1	3	2	2	1	3	0	1	2	3
sp.A	3	2	2	0	2	3	0	0	2	3
sp.B	1	1	3	0	2	1	0	0	2	3
sp.C	1	1	3	2	0	3	3	2	1	0

## Probabilística (ML):

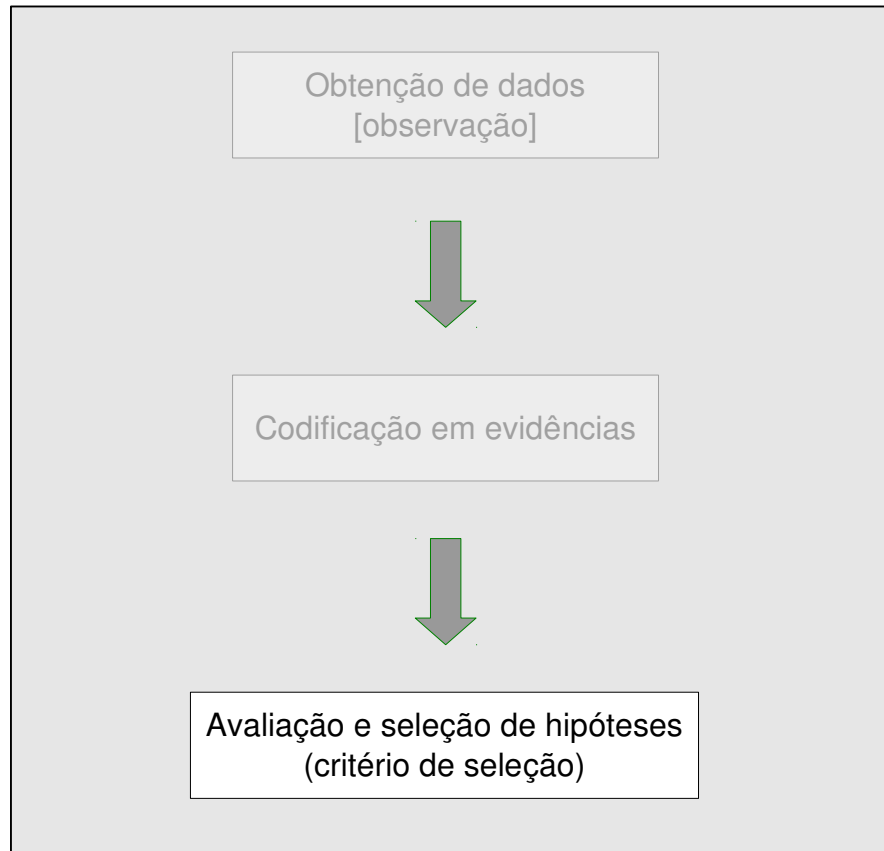
EVIDÊNCIAS: modelo de transformações + topologia que melhor explicam seus dados.



sp.X CTGGCTACGT  
 sp.A TGGAGTAAGT  
 sp.B CCTAGCAAGT  
 sp.C CCTGATTGCA

# Lógica da inferência filogenética


Avaliação e critério de seleção: verossimilhança máxima (ML)



$$L(\theta|x) \approx P(x|\theta)$$

$$L(\theta | \begin{matrix} \text{sp. X} & \text{CTGGCTACGT} \\ \text{sp. A} & \text{TGGAGTAAGT} \\ \text{sp. B} & \text{CCTAGCAAGT} \\ \text{sp. C} & \text{CCTGATTGCA} \end{matrix}) \approx P(\begin{matrix} \text{sp. X} & \text{CTGGCTACGT} \\ \text{sp. A} & \text{TGGAGTAAGT} \\ \text{sp. B} & \text{CCTAGCAAGT} \\ \text{sp. C} & \text{CCTGATTGCA} \end{matrix} | \theta)$$

Qual o valor de  $\theta$  que maximiza a probabilidade dos dados observados?



# Lógica da inferência filogenética

Avaliação e critério de seleção: verossimilhança máxima (ML)

$$L(\theta|x) \approx P(x|\theta)$$

$$L(\theta | \begin{matrix} \text{sp. X} & \text{CTGGCTACGT} \\ \text{sp. A} & \text{TGGAGTAAGT} \\ \text{sp. B} & \text{CCTAGCAAGT} \\ \text{sp. C} & \text{CCTGATTGCA} \end{matrix}) \approx P(\begin{matrix} \text{sp. X} & \text{CTGGCTACGT} \\ \text{sp. A} & \text{TGGAGTAAGT} \\ \text{sp. B} & \text{CCTAGCAAGT} \\ \text{sp. C} & \text{CCTGATTGCA} \end{matrix} | \theta)$$

Maximização do L  $\theta$ :


$$\theta = \begin{array}{c} \text{A} \\ \text{A} \\ \text{G} \end{array} \begin{array}{c} 0.05 \\ 0.1 \\ 0.1 \end{array} \begin{array}{c} \text{A} \\ \text{A} \\ \text{G} \end{array} \begin{array}{c} 0.05 \\ 0.1 \\ 0.1 \end{array} + GRT = \begin{bmatrix} P_{AA}(t)P_{AC}(t)P_{AG}(t)P_{AT}(t) \\ P_{CA}(t)P_{CC}(t)P_{CG}(t)P_{CT}(t) \\ P_{GA}(t)P_{GC}(t)P_{GG}(t)P_{GT}(t) \\ P_{TA}(t)P_{TC}(t)P_{TG}(t)P_{TT}(t) \end{bmatrix}$$

# Lógica da inferência filogenética

Avaliação e critério de seleção: verossimilhança máxima (ML)

$$\theta = \left[ \begin{array}{c} \text{Diagrama de árvore} \end{array} \right] + GRT = \left[ \begin{array}{cccc} P_{AA}(t) & P_{AC}(t) & P_{AG}(t) & P_{AT}(t) \\ P_{CA}(t) & P_{CC}(t) & P_{CG}(t) & P_{CT}(t) \\ P_{GA}(t) & P_{GC}(t) & P_{GG}(t) & P_{GT}(t) \\ P_{TA}(t) & P_{TC}(t) & P_{TG}(t) & P_{TT}(t) \end{array} \right]$$

Possíveis reconstruções para HTUs




+ Diferentes topologias  
Diferentes comprimentos de ramos

$$L = \Pr \left( \begin{array}{c} \text{sp.X CTGGCTACGT} \\ \text{sp.A TGGAGTAAGT} \\ \text{sp.B CCTAGCAAGT} \\ \text{sp.C CCTGATTGCA} \end{array} \middle| \left[ \begin{array}{c} \text{Diagrama de árvore} \\ + \left[ \begin{array}{cccc} P_{(AA)} & P_{(AC)} & P_{(AG)} & P_{(AT)} \\ P_{(CA)} & P_{(CC)} & P_{(CG)} & P_{(CT)} \\ P_{(GA)} & P_{(GC)} & P_{(GG)} & P_{(GT)} \\ P_{(TA)} & P_{(TC)} & P_{(TG)} & P_{(TT)} \end{array} \right] \right) \right)$$

# Lógica da inferência filogenética: Likelihood

Função objetiva:

$$C \Rightarrow P(\text{sp. X CTGGCTACGT} \\ \text{sp. A TGGAGTAAGT} \\ \text{sp. B CCTAGCAAGT} \\ \text{sp. C CCTGATTGCA} \mid \theta)$$



Modelo de substituição:

	<b>A</b>	<b>C</b>	<b>G</b>	<b>T</b>
<b>A</b>	$P_{(A,A)}$	$P_{(A,C)}$	$P_{(A,G)}$	$P_{(A,T)}$
<b>C</b>	$P_{(C,A)}$	$P_{(C,C)}$	$P_{(C,G)}$	$P_{(C,T)}$
<b>G</b>	$P_{(G,A)}$	$P_{(G,C)}$	$P_{(G,G)}$	$P_{(G,T)}$
<b>T</b>	$P_{(T,A)}$	$P_{(T,C)}$	$P_{(T,G)}$	$P_{(T,T)}$

$$P_{ij}(t) = \frac{1}{4} - \frac{1}{4}e^{-4\nu/3}$$

probabilidade de  
mudança de estado


$$P_{ii}(t) = \frac{1}{4} + \frac{3}{4}e^{-4\nu/3}$$

probabilidade de não  
mudança de estado


		$\nu = 0.1$			
		<b>A</b>	<b>C</b>	<b>G</b>	<b>T</b>
<b>A</b>		0.9064	0.0312	0.0312	0.0312
<b>C</b>		0.0312	0.9064	0.0312	0.0312
<b>G</b>		0.0312	0.0312	0.9064	0.0312
<b>T</b>		0.0312	0.0312	0.0312	0.9064

		$\nu = 0.05$			
		<b>A</b>	<b>C</b>	<b>G</b>	<b>T</b>
<b>A</b>		0.9516	0.0161	0.0161	0.0161
<b>C</b>		0.0161	0.9516	0.0161	0.0161
<b>G</b>		0.0161	0.0161	0.9516	0.0161
<b>T</b>		0.0161	0.0161	0.0161	0.9516

# Cálculo de verossimilhança para Reconstruções:



T1: Rec 1




**Regra 3:** lintersecção de eventos, ou probabilidade conjunta:  $P_{(A \text{ e } B)} = P_{(A)} * P_{(B)}$ .

$$\text{Reconstrução 1} = P_1 * P_2 * P_3 * P_4 * P_5$$

	<b>A</b>	<b>C</b>	<b>G</b>	<b>T</b>
<b>A</b>	$P_{(A,A)}$	$P_{(A,C)}$	$P_{(A,G)}$	$P_{(A,T)}$
<b>C</b>	$P_{(C,A)}$	$P_{(C,C)}$	$P_{(C,G)}$	$P_{(C,T)}$
<b>G</b>	$P_{(G,A)}$	$P_{(G,C)}$	$P_{(G,G)}$	$P_{(G,T)}$
<b>T</b>	$P_{(T,A)}$	$P_{(T,C)}$	$P_{(T,G)}$	$P_{(T,T)}$


T1: Rec 1



$$P_{(T1: \text{Rec } 1)} = P_{(AA)}^3 * P_{(AG)}^2$$

# Cálculo de verossimilhança para reconstruções:


Neste caso, todas as reconstruções possíveis....






# Cálculo de verossimilhança para Reconstruções:

T1: Rec 1




$$P_{(T1: Rec 1)} = P_{(AA)}^3 * P_{(AG)}^2$$

T1: Rec 2



$$P_{(T1: Rec 2)} = P_{(AA)}^2 * P_{(AC)} * P_{(CG)}^2$$


T1: Rec 3



$$P_{(T1: Rec 3)} = P_{(AA)}^2 * P_{(AG)} * P_{(GG)}^2$$


# Cálculo de verossimilhança para Reconstruções:

T1: Rec 4




$$P_{(T1: Rec 4)} = P_{(AA)}^2 * P_{(AT)} * P_{(GG)}^2$$

T1: Rec 5



$$P_{(T1: Rec 5)} = P_{(AC)}^2 * P_{(CA)} * P_{(AG)}^2$$

T1: Rec 16




$$P_{(T1: Rec 16)} = P_{(AT)}^2 * P_{(TT)} * P_{(TG)}^2$$


# Lógica da inferência filogenética: Likelihood

$$L = \Pr \left( \begin{matrix} P_{(AA)} & P_{(AC)} & P_{(AG)} & P_{(AT)} \\ P_{(CA)} & P_{(CC)} & P_{(CG)} & P_{(CT)} \\ P_{(GA)} & P_{(GC)} & P_{(GG)} & P_{(GT)} \\ P_{(TA)} & P_{(TC)} & P_{(TG)} & P_{(TT)} \end{matrix} \right) + \left( \begin{matrix} A & 0.05 & 0.05 & A \\ & A & 0.1 & \\ G & 0.1 & & G \end{matrix} \mid \begin{matrix} \text{sp. X CTGGCTACGT} \\ \text{sp. A TGGAGTAAGT} \\ \text{sp. B CCTAGCAAGT} \\ \text{sp. C CCTGATTGCA} \end{matrix} \right)$$

Avaliação de todas as reconstruções possíveis



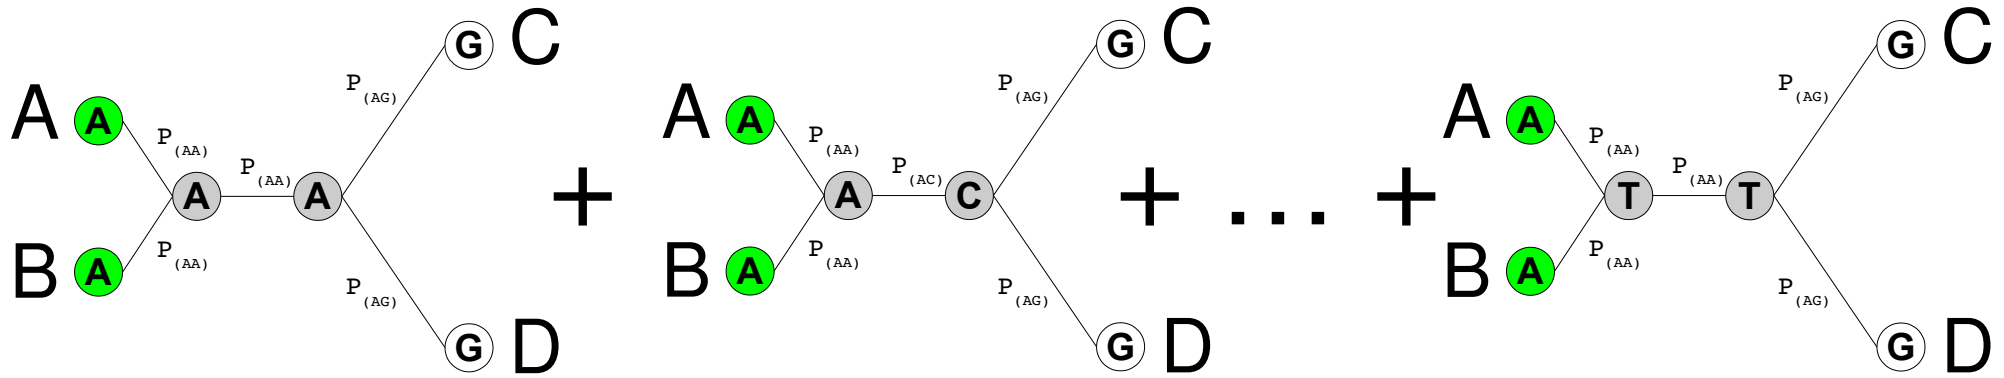
# *Cálculo de verossimilhança para Reconstruções:*



O QUE SIGNIFICA A SOMA DAS  
PROBABILIDADES DAS RECONSTRUÇÕES?

# Cálculo de verossimilhança para topologias:

Regra 2: Eventos disjuntos:  $P_{(A \text{ ou } B)} = P_{(a)} + P_{(b)}$



A Verossimilhança Máxima ( $L^*$ ) de uma determinada hipótese é dada por:

$$L = L_{(1)} * L_{(2)} * L_{(3)} * \dots * L_{(n)} = \prod_{j=1}^N L_{(j)}$$

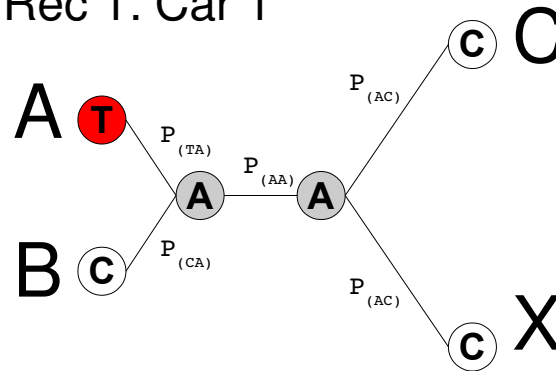
\* tradicionalmente ela é avaliada pela soma dos logaritmos neperianos das probabilidades de cada carácter:

$$\ln L = \ln L_{(1)} + \ln L_{(2)} + \ln L_{(3)} + \dots + \ln L_{(n)} = \sum_{j=1}^N \ln L_{(j)}$$

# Lógica da inferência filogenética: o cálculo

Para,	1	2..	j	N					
sp. X	C	TGG	C	T	...	C	G	T	
sp. A	T	GG	A	G	T	...	A	G	T
sp. B	C	T	A	G	C	...	A	G	T
sp. C	C	T	G	A	T	...	G	C	A

T1: Rec 1: Car 1



COMO VOCÊ FORMULARIA O CÁLCULO  
PARA MAIS DE UM CARÁTER?

# Lógica da inferência filogenética: modelos complexos





## K2P

Kimura Two Parameters

	<b>A</b>	<b>C</b>	<b>G</b>	<b>T</b>
<b>A</b>	$P_{(A,A)}$	$P_{(A,C)}$	$P_{(A,G)} *k$	$P_{(A,T)}$
<b>C</b>	$P_{(C,A)}$	$P_{(C,C)}$	$P_{(C,G)}$	$P_{(C,T)} *k$
<b>G</b>	$P_{(G,A)} *k$	$P_{(G,C)}$	$P_{(G,G)}$	$P_{(G,T)}$
<b>T</b>	$P_{(T,A)}$	$P_{(T,C)} *k$	$P_{(T,G)}$	$P_{(T,T)}$

Considere:

<b>T1</b>	<b>A</b>	<b>C</b>	<b>G</b>	<b>T</b>
<b>T2</b>	<b>C</b>	<b>G</b>	<b>T</b>	<b>A</b>
<b>T3</b>	<b>G</b>	<b>T</b>	<b>A</b>	<b>C</b>
<b>T4</b>	<b>T</b>	<b>A</b>	<b>C</b>	<b>G</b>



... onde  $k$  é a razão entre eventos de transição e transversão (valor estimado neste exemplo).

**Note que utilizando o critério de parcimônia, nenhum caráter seria considerado informativo!**

# *Escolha de critérios de otimalidade*

Qual é o melhor método?

Qual é a melhor árvore (topologia)?

*Não há uma única resposta para a pergunta e para ambas perguntas é necessário adotar um critério para avaliação objetivo!*

## MÉTODOS DE DISTÂNCIA E DE TRANSFORMAÇÃO DE CARACTERES

Problemas centrais com o métodos de distância:

Impossibilidade de identificar transformações

Impossibilidade de reconstruir estados ancestrais hipotéticos

Impossibilidade de postular hipóteses de homologia



# Escolha de critérios de otimalidade

Méritos relativos dos métodos:

## Epistemologia

Comportamento estatístico

Performance

Congruência (?)

Como nós "sabemos" as coisas?



Como hipóteses científicas são propostas e testadas?

Qual é a relação entre observação e inferência?

## 1. Navalha de Ockham e argumentação Popperiana

*"The minimization approach of parsimony offers a specific method to achieve the base-line goal of choosing genealogical explanation of variation, and of identifying non-conforming observations that require additional modes of causality."*

(Wheeler 2012:271)



# *Escolha de critérios de otimalidade*

Méritos relativos dos métodos:

## **Epistemologia**

Comportamento estatístico

Performance

Congruência (?)

Como nós "sabemos" as coisas?

Como hipóteses científicas são propostas e testadas?

Qual é a relação entre observação e inferência?

## **1. Navalha de Ockham e argumentação Popperiana**

Popper --> hipóteses devem ser testadas pela busca de evidências contraditórias

> número de observação

> número de oportunidades de falsificar a hipótese

> severamente a hipótese foi testada

*"Parsimonious trees have maximal explanatory power with regard to observed variation, and they do this without the accessory explanatory elements of other methods (e.g., model and tree parameters)."*

(Wheeler 2012:271)

# *Escolha de critérios de otimalidade*

Méritos relativos dos métodos:

## **Epistemologia**

Comportamento estatístico

Performance

Congruência (?)

Como nós "sabemos" as coisas?

Como hipóteses científicas são propostas e testadas?

Qual é a relação entre observação e inferência?

## **2. Parcimônia e processos evolutivos**

procedimento de inferência

vs.

Modelo de evolução

- i. Não assume que evolução ocorre parcimoniamamente (ex. Homoplasia)
- ii. Em ciência utilizada como um processo de descobrimento e teste
- lii. Pode ser defendida sem apelo ao autoritarismo a apriorismo

# *Escolha de critérios de otimalidade*

Méritos relativos dos métodos:

## **Epistemologia**

Comportamento estatístico

Performance

Congruência (?)

Como nós "sabemos" as coisas?

Como hipóteses científicas são propostas e testadas?

Qual é a relação entre observação e inferência?

## **3. Indução e estimativa estatística**

Sistemática, assim como muitas outras disciplinas em Biologia, é uma ciência histórica na qual os eventos que buscamos explicar são únicos no tempo e no espaço.

*"If each character observation is a unique object, it cannot be a random sample drawn from a parameterized distribution expressed as a model of change (e.g., GTR+I+G)."*

*"By this rationale, parsimonious trees have explanatory power in minimizing ad hoc hypotheses, and increased observation will increase the severity of test, but would not reduce any measure of 'sampling error', since there is no sample distribution that is measured."*

(Wheeler 2012:272)

# *Escolha de critérios de otimalidade*

Méritos relativos dos métodos:

## **Epistemologia**

Comportamento estatístico

Performance

Congruência (?)

Como nós "sabemos" as coisas?

Como hipóteses científicas são propostas e testadas?

Qual é a relação entre observação e inferência?

## **4. Teste de hipóteses e critério de otimização**

Inferência hipotético-dedutiva pode ser feita via etapa de falsificação baseada em qualquer função de otimização objetiva:

**Requer:** hipóteses devem competir matematicamente de forma objetiva.

**Questão central:** a função de otimização é apropriada?

# Escolha de critérios de otimalidade


Méritos relativos dos métodos:

**Epistemologia**

Comportamento estatístico

Performance

Congruência (?)



## Probabilidades: duas interpretações

i. Grau de crença:

Confiança relativa em determinado resultado, considere

"Esta moeda tem 80% de chance de ser honesta."

Mas a moeda é ou não é honesta!



# Escolha de critérios de otimalidade


Méritos relativos dos métodos:

## Epistemologia

Comportamento estatístico

Performance

Congruência (?)



## Probabilidades: duas interpretações

ii. Uma proposição verdadeira sobre o universo natural semelhante à eventos repetidos:

Implica em uma proposição sobre o que é ontologicamente real, considere:

"Esta moeda tem 80% de chance de dar coroa em uma jogada."



Oferece uma propriedade da moeda e uma proposição relacionada à sua realidade física.

# *Escolha de critérios de otimalidade*


Méritos relativos dos métodos:

**Epistemologia**

Comportamento estatístico

Performance

Congruência (?)



**Probabilidades:**

**Ciências históricas não permitem facilmente a interpretação frequencista (i.e., ii)**

**Considere:**

"Qual é a probabilidade de que Tiradentes e Joaquim José da Silva Xavier eram a mesma pessoa?"



# *Escolha de critérios de otimização*


Méritos relativos dos métodos:

**Epistemologia**

Comportamento estatístico

Performance

Congruência (?)



**Probabilidades:**

**Ciências históricas não permitem facilmente a interpretação frequencista (i.e., ii)**

**Considere:**

"A e B são grupos-irmãos?"

# *Escolha de critérios de otimalidade*


Méritos relativos dos métodos:

**Epistemologia**

Comportamento estatístico

Performance

Congruência (?)



**Probabilidades:**

**Ciências históricas não permitem facilmente a interpretação frequencista (i.e., ii)**

**Considere:**

"Asas de morcego e asas de passarinho são homólogas?"

# Escolha de critérios de otimalidade


Méritos relativos dos métodos:

## Epistemologia

Comportamento estatístico

Performance

Congruência (?)



## Probabilidades:

**Ciências históricas não permitem facilmente a interpretação frequencista (i.e., ii)**

Nesse contexto, qualquer interpretação de probabilidade está restrita ao nosso grau de crença. Portanto probabilidades associadas a eventos históricos conferem:

- i.* grau de suporte entre hipóteses e não sua realidade;
- ii.* elas não descrevem o universo natural, mas sim nosso entendimento dele.

*"We cannot say whether a given set of historical statements (i.e., a tree) is true, but we can say we have relative degree of belief based on empirical observation and an optimality criterion"*

(Wheeler 2012:274)

# *Escolha de critérios de otimização*

## *Como escolher?*

Epistemologia não oferece caminho inequívoco

- i. Todos os métodos podem participar do processo hipotético-dedutivo.
- ii. Todos estão sujeitos à comportamentos inconsistentes.

Uma possibilidade: sincretismo

- i. Convergência de resultados é trivial, embora rara.
- ii. Na maioria dos casos há incongruências, o que fazer?
  - a. critérios de otimização possuem diferentes motivações e epistemologias subjacentes.
  - b. Consenso é um caminho ilógico.

# *Escolha de critérios de otimização*

## *Como escolher?*

*Critérios de otimização são premissas analíticas utilizadas para interpretar eventos historicamente únicos. Como tal, eles não podem ser testados empiricamente por acurácia. Por outro lado, congruência pode ser um caminho a ser seguido. No entanto, em seu cerne, critérios de otimização são pressupostos que requer suporte e justificativa quando empregados. Pressupostos diferentes levam a resultados diferentes. Somente justificando nossas premissas nós podemos defender nossas conclusões.*