


## MODULARIZACE VÝUKY EVOLUČNÍ A EKOLOGICKÉ BIOLOGIE

CZ.1.07/2.2.00/15.0204



# ÚVOD DO FYLOGENETICKÉ ANALÝZY I.



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

## Úvod

zákl. pojmy, počet stromů, typy dat

## Práce se sekvencemi DNA a proteinů

databáze (GenBank, ENTREZ, BLAST), seřazení sekvencí (Clustal)

## Rozdělení metod a kritéria jejich hodnocení

### Maximální úspornost (Maximum parsimony, MP)


MP a konzistence

### Evoluční modely a distanční metody


výběr modelu, UPGMA, neighbor-joining

# Definice základních pojmu

rooted tree




unrooted tree








- fylogenetický strom = fylogenie (phylogeny) s kořenem, bez kořene
- větve (branches, edges) vnější, vnitřní, centrální
- uzly (nodes, vertices) vnitřní, terminální (externí)
- dichotomie, polytomie
- OTU, HTU
- topologie


c)




d)



# Kolik existuje stromů?




$$\frac{(2n-5)!}{2^{n-3}(n-3)!}$$



$$\frac{(2n-3)!}{2^{n-2}(n-2)!}$$

No. Taxons	Unrooted trees	Rooted trees
3	1	3
4	3	15
5	15	105
6	105	945
7	945	10 395
8	10 395	135 135
9	135 135	2 027 025
10	2 027 025	34 459 425
11	34 459 425	654 729 075
12	654 729 075	13 749 310 575
13	13 749 310 575	316 234 143 225
14	316 234 143 225	7 905 853 580 625
15	7 905 853 580 625	213 458 046 676 875
20	213 458 046 676 875	8 200 794 532 637 891 559 375
30	8 200 794 532 637 891 559 375	$4,9518 \times 10^{38}$
40	$4,9518 \times 10^{38}$	$1,00986 \times 10^{57}$
50	$1,00986 \times 10^{57}$	$2,75292 \times 10^{76}$

# Jaké typy dat můžeme použít?



# Typy dat

## 1. Nukleotidové a proteinové sekvence:

H\_sapiens MTPMRKINPLMKLINHSFIDLPTPSNISAWWNFGS


báze = stav znaku

P\_troglod ATGACCCCGA CACGCAAAATTAAACCCACTAATAAAA



pozice (site) = znak


## 2. Restrikční data:



Restrikční místo = znak

přítomnost/absence = stav znaku

- \* restriction-site data
- \* restriction-fragment data (RFLP)



fragment = znak

přítomnost/absence =  
stav znaku

absence nezávislosti!

# Typy dat

## 3. Alozymy:

alela = znak, přítomnost/absence = stav znaku

lokus = znak, alela = stav znaku

lokus = znak, alelová frekvence = stav znaku

## 4. Pořadí genů


## 5. Retroelementy: SINE (*Alu*, B1, B2), LINE

## 6. VNTR, STR, SNP

**Vlastnosti znaků:**

- \* nezávislost (morfologie, alozymy, pořadí genů)
- \* homologie

## Problém homologie sekvencí



# Práce se sekvencemi

## DNA databáze:

- EMBL (European Molecular Biology Laboratory) – European Bioinformatics Institute, Hinxton, UK: <http://www.ebi.ac.uk/embl/>
- GenBank – NCBI (National Center for Biotechnology Information), Bethesda, Maryland, USA: <http://www.ncbi.nlm.nih.gov/Genbank/>
- DDBJ (DNA Data Bank of Japan) – National Institute of Genetics, Mishima, Japan: <http://www.ddbj.nig.ac.jp/>

## Proteinové databáze:

- SWISS-PROT – University of Geneve & Swiss Institute of Bioinformatics:  
<http://www.expasy.ch/sprot/> a <http://www.ebi.ac.uk/swissprot/>
- PIR (Protein Information Resource) – NBRF (National Biomedical Research Foundation, Washington, D.C., USA) & Tokyo University & JIPID (Japanese International Protein Information Database, Tokyo) & MIPS (Martinsried Institute for Protein Sequences, Martinsried, Germany): <http://www-nbrf.georgetown.edu/>
- PRF/SEQDB (Protein Resource Foundation) – Ósaka, Japan:  
<http://www.prf.or.jp/en/os.htm>
- PDB (Protein Data Bank) – University of New Jersey, San Diego & Super-computer Center, University of California & National Institute of Standards and Technology:  
<http://www.rcsb.org/pdb/>

# Formáty souborů

## GenBank:

### ORIGIN

```
1 tggaaatgaag atattcttctt ctcaagacat caagaagaag gaactactcc ccaccaccag
 61 cacccaaagc tggcattcta attaaactac ttcttgta cataaattta catagtacaa
121 tagtacattt atgtatatcg tacattaaac tattttcccc aagcatataa gcaagtacat
181 ttaatcaatg atataggcca taaaacaatt atcaacataa actgatacaa accatgaata
241 ttatactaat acatcaaatt aatgctttaa agacatatct gtgttatctg acatacacca
301 tacagtcata aactcttctc ttccatatga ctatcccctt ccccatttgg tctattaatc
361 taccatcctc cgtgaaacca acaacccgcc caccaatgcc cctcttctcg ctccgggccc
421 attaaacttg gggtagcta aactgaaact ttatcagaca tctggttttt acttcagggc
481 catcaaatgc gttatcgccc atacgttccc cttaaataag acatctcgat ggtatcggtt
541 ctaatcagcc catgaccaac ataactgtgg tgtcatgcat ttggattttt ttatttgg
601 cctactttca tcaacatagc cgtcaaggca tgaaaggaca gcacacagtc tagacgcacc
661 tacggtaag aatcatttgt ccgcggggcc caatcaccta aggctaatta ttcatgctt
721 ttagacataa atgctactca ataccaaatt ttaactctcc aaacccccc accccctcct
781 cttaatgcc aacccaaaaa acactaagaa cttgaaagac atatatttt aactatcaaa
841 ccctatgtcc tgatcgattc tagtagttcc caaaatatga ctcatatttt agtacttgta
901 aaaattttac aaaatcatgc tccgtgaacc aaaactctaa tcacactcta ttacgcaata
961 aatattaaca agttaatgta gcttaataac aaagcaaagc actgaaaatg ctttagatgga
1021 taattttatac cca
```

//

# Formáty souborů

## FASTA:

```
>H_sapiens
ATGACCCCAATACGAAAATTAAACCCCTAATAAAATTAAATTAACCACTCATTCATCGACCTCCCCACCC
CATCCAACATCTCCGCATGATGAAACTTCGGCTCACTCCTGGCGCCTGCCTGATCCTCAAATCACCAC
AGGACTATTCTAGCCATACACTACTCACCAAGACGCCCTCAACCGCCTTTCATCAATGCCAACATCACT
CGAGACGTAAATTATGGCTGAATCATCCGCTACCTTCACGCCAATGGCGCCTCAATATTCTTATCTGCC
TCTTCCTACACATCGGGCGAGGCCTATATTACGGATCATTCTACTCAGAACCTGAAACATCGGCAT
...
>P_troglod
ATGACCCCGACACGAAAATTAAACCCACTAATAAAATTAAATCACTCATTATCGACCTCCCCACCC
CATCCAACATTTCCGCATGATGGAACTTCGGCTCACTTCTGGCGCCTGCCTAATCCTCAAATTACCAC
AGGATTATTCTAGCTATACACTACTCACCAAGACGCCCTCAACCGCCTCTCGTCGATGCCAACATCACC
CGAGACGTAAACTATGGTTGGATCATCCGCTACCTCCACGCTAACGGCGCCTCAATATTTTATCTGCC
TCTTCCTACACATCGGCCGAGGTCTATATTACGGCTCATTCTACCTAGAACCTGAAACATTGGCAT
...
>P_paniscus
ATGACCCCAACACGAAAATCAACCCACTAATAAAATTAAATCACTCATTATCGACCTCCCCACCC
CATCCAATATTCCACATGATGAAACTTCGGCTCACTTCTGGCGCCTGCCTAATCCTCAAATCACCAC
AGGACTATTCTAGCTATACACTACTCACCAAGACGCCCTCAACCGCCTCTCATCGATGCCAACATTACC
CGAGACGTAAACTATGGTTGAATCATCCGCTACCTTCACGCTAACGGCGCCTCAATACTTTATCTGCC
TCTTCCTACACGTCGGTCGAGGCCTATATTACGGCTCATTCTACCTAGAACCTGAAACATTGGCAT
...
```

# Formáty souborů

## PHYLIP (“interleaved” format):

```
6 1120
H_sapiens    ATGACCCCAA TACGAAAAAT TAACCCCTA ATAAAATTAA TTAACCACTC
P_troglod     ATGACCCCGA CACGAAAAAT TAACCCACTA ATAAAATTAA TTAATCACTC
P_paniscus   ATGACCCCAA CACGAAAAAT CAACCCACTA ATAAAATTAA TTAATCACTC
G_gorilla    ATGACCCCTA TACGAAAAAC TAACCCACTA GCAAAACTAA TTAACCACTC
P_pygmaeus   ATGACCCCAA TACGAAAAAC CAACCCACTA ATAAAATTAA TTAACCACTC
H_lar        ATGACCCCCC TGCGAAAAAC TAACCCACTA ATAAAACTAA TCAACCACTC

ATTCATCGAC  CTCCCCACCC CATCCAACAT CTCCGCATGA TGAAACTTCG
ATTTATCGAC  CTCCCCACCC CATCCAACAT TTCCGCATGA TGAAACTTCG
ATTTATCGAC  CTCCCCACCC CATCCAATAT TTCCCACATGA TGAAACTTCG
ATTCAATTGAC CTCCCTACCC CGTCCAACAT CTCCCACATGA TGAAACTTCG
ACTCATCGAC  CTCCCCACCC CATCAAACAT CTCTGCATGA TGAAACTTCG
ACTTATCGAC  CTTCCAGCCC CATCCAACAT TTCTATATGA TGAAACTTTG
```

# Formáty souborů

## NEXUS (PAUP\*, “interleaved”):

```
#NEXUS
begin data;
dimensions ntax=6 nchar=1120;
format datatype=DNA interleave datatype=DNA missing=? gap=- ;
matrix
P_troglod    ATGACCCCGACACGCAAAATTAAACCCACTAATAAAAATTAAATCACTC
P_paniscus   ATGACCCCAACACGCAAAATCAACCCACTAATAAAAATTAAATCACTC
H_sapiens    ATGACCCCAATACGCAAAATTAAACCCCTAATAAAAATTAAACCACTC
G_gorilla    ATGACCCCTATAACGCAAAACTAACCCACTAGCAAAACTAATTAAACCACTC
P_pygmaeus   ATGACCCCAATACGCAAAACCAACCCACTAATAAAAATTAAACCACTC
H_lar        ATGACCCCCCTGCGCAAAACTAACCCACTAATAAAAACTAATCAACCACTC

P_troglod    ATTTATCGACCTCCCCACCCCATCCAACATTTCCGATGGAACCTCG
P_paniscus   ATTTATCGACCTCCCCACCCCATCCAATATTCCACATGATGAAACCTCG
H_sapiens    ATTCAATCGACCTCCCCACCCCATCCAACATCTCCGATGATGAAACCTCG
G_gorilla    ATTCAATTGACCTCCCTACCCCGTCCAACATCTCCACATGATGAAACCTCG
P_pygmaeus   ACTCATCGACCTCCCCACCCCATCAAACATCTCTGCATGATGGAACCTCG
H_lar        ACTTATCGACCTTCCAGCCCCATCCAACATTTCTATATGATGAAACCTTG

end;
```

# Formáty souborů

## Clustal:

```
P_troglod    ATGACCCCGACACGAAAATTAACCCACTAATAAAATTAATTAAATCACTCATTATCGAC
P_paniscus   ATGACCCAACACGAAAATCAACCCACTAATAAAATTAATTAAATCACTCATTATCGAC
H_sapiens    ATGACCCAATACGAAAATTAACCCCCTAATAAAATTAATTAAACCACTCATTATCGAC
G_gorilla    ATGACCCCTATACGAAAACCAACCCACTAATAAAATTAATTAAACCACTCATTGAC
P_pygmaeus   ATGACCCAATACGAAAACCAACCCACTAATAAAATTAATTAAACCACTCACTCATCGAC
H_lar        ATGACCCCCCTGCGAAAACCAACCCACTAATAAAACTAATCAACCACTCACCTATCGAC
*****       *****      *     ***   ***   ***   ***   *   ***   *   **   ***
```

```
P_troglod    CTCCCCACCCATCCAACATTTCCGCATGATGGAACCTCGGCTCACTTCTCGGCGCCTGC
P_paniscus   CTCCCCACCCATCCAATATTCACATGATGAAACCTCGGCTCACTTCTCGGCGCCTGC
H_sapiens    CTCCCCACCCATCCAACATCTCCGCATGATGAAACCTCGGCTCACTCCTGGCGCCTGC
G_gorilla    CTCCCTACCCCGTCCAACATCTCCACATGATGAAACCTCGGCTCACTCCTGGTGCCTGC
P_pygmaeus   CTCCCCACCCATCAAACATCTCTGCATGATGGAACCTCGGCTCACTTCTAGGCGCCTGC
H_lar        CTTCCAGCCCCATCCAACATTTCTATATGATGAAACTTGGTCACTCCTAGGCGCCTGC
**   *   ***   *   *   *   *   *   ***   ***   *   ***   *   *   ***
```

# Seřazení sekvencí (alignment)

Sekvence 1 TTGTACGACGG

Sekvence 2 TTGTACGACG

TTGTACGACGG	TTGT---ACGACGG
TTGTACGACG	TTGTACGACG


gap penalty

Sekvence 1 ACTTGCTTTC

Sekvence 2 ACGTGCTGCTC

Path 1	ACTTG-TGCTTTC
	ACGTGCTGCTC

Path 2	ACTTGCTTTC
	AC--GTGCTGCTC




$$GP = g + hl$$

$g$  - gap penalty

$h$  – gap extension  
penalty


$l$  – gap length



# Progresivní seřazení - ClustalX

## 3 fáze:

1. Seřazení dvojic sekvencí → párové distance
2. Konstrukce „guide tree“ (NJ)
3. Seřazení všech sekvencí podle stromu



# Problém progresivního seřazení

6 druhů:

gorila

kůň

panda

AGGTT

AG-TT

AG-TT

tučňák

kuře

pštros

A-GTT

A-GTT

AGGTT



AGGTT

AG-TT

AG-TT

AG-TT

AG-TT

AGGTT

gorila

kůň

panda

tučňák

kuře

pštros

AGGTT

AG-TT

AG-TT

A-GTT

A-GTT

AGGTT

AGGTT

A-GTT

A-GTT

A-GTT

A-GTT

AGGTT



# Rozdělení metod

## Typy dat

Metody konstrukce stromů  
kritérium optimality  
algorithms

distance	znaky
<ul style="list-style-type: none"><li>• UPGMA</li><li>• neighbor-joining</li></ul>	
<ul style="list-style-type: none"><li>• Fitch-Margoliash</li><li>• minimum evolution</li></ul>	<ul style="list-style-type: none"><li>• maximum parsimony</li><li>• maximum likelihood</li><li>• Bayesian a.</li></ul>

# Jak hodnotit jednotlivé metody?




- **výkonnost (efficiency)**: jak rychlá je metoda?
- **síla (power)**: kolik znaků je třeba?
- **konzistence (consistency)**: vede zvyšující se počet znaků ke správnému stromu?
- **robustnost (robustness)**: jak metoda funguje při neplatnosti předpokladů?
- **falzifikovatelnost (falsifiability)**: umožňuje testování platnosti předpokladů?

# Maximální úspornost (maximum parsimony, MP)

	I	II	III
A	1	0	1
B	0	0	1
C	1	0	0
D	0	1	0
E	1	0	1




William of Occam (c. 1285 - c. 1349):  
Occamova břitva

minimální počet kroků = 3  
skutečný počet kroků = 5  
⇒ 2 extra kroky → homoplasie




# Odhad počtu kroků

## Fitchův (1971) algoritmus



**DELTRAN**  
(**DE**layed **TR**ANsformation)



**ACCTRAN**  
(**AC**celerated **TR**ANsformation)

1. arbitrární kořen

2. top → bottom:

w = C nebo T

x = T

y = A nebo T

z = T

3. bottom → top:

z = T nebo A

celková délka = 3

## Problém homoplasie:

- parsimony-informative and non-informative characters (sites)
  - invariant sites (symplesiomorphies)
  - singletons (autapomorphies)

- index konzistence (consistency i., CI)
- retenční index (retention i., RI)
- upravený CI (rescaled CI, RC)
- index homoplasie (homoplasy i., HI)

$$\text{CI} = \frac{\sum_i m_i}{\sum_i s_i} \quad \text{RI} = \frac{\sum_i g_i - \sum_i s_i}{\sum_i g_i - \sum_i m_i}$$

$$\text{RC} = \text{CI} \times \text{RI}$$

$$\text{HI} = 1 - \text{CI}$$


$m$  = min. no. of possible steps

$s$  = min. no. needed for explaining the tree

$g$  = max. no. of steps for any tree

## Metody parsimonie


- Fitch parsimony:  $X \rightarrow Y$  and  $Y \rightarrow X$   
unordered characters ( $A \rightarrow T$  or  $A \rightarrow G$  etc.)
- Wagner parsimony:  $X \rightarrow Y$  and  $Y \rightarrow X$   
ordered characters ( $1 \rightarrow 2 \rightarrow 3$ )
- Dollo parsimony:  $X \rightarrow Y$  and  $Y \rightarrow X$ , then no  $X \rightarrow Y$   
... restriction-site and  
restriction-fragment data
- Camin-Sokal p.:  $X \rightarrow Y$ ,  
no  $Y \rightarrow X$   
... SINE, LINE
- weighed (transversion) p.  
“relaxed Dollo criterion”
- generalized parsimony: cost matrix (step matrix)



# Hledání optimálního stromu a měření spolehlivosti

## 1. Exaktní metody:


- a) vyčerpávající hledání (exhaustive search)
- b) branch-and-bound




## 2. Heuristický přístup:

- stepwise addition
- star decomposition
- branch swapping

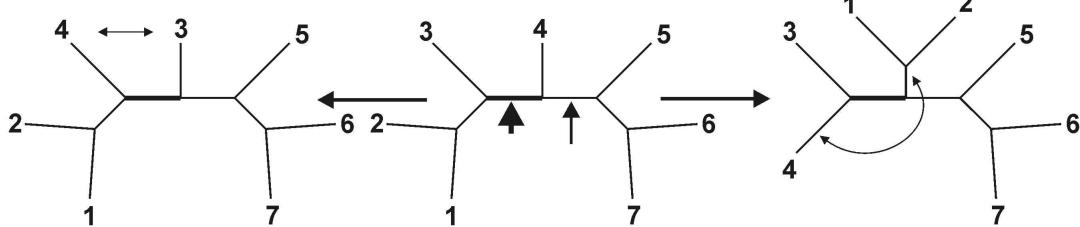
a)




b)




## NNI



## SPR



## TBR





\* nearest-neighbor  
interchanges (NNI)

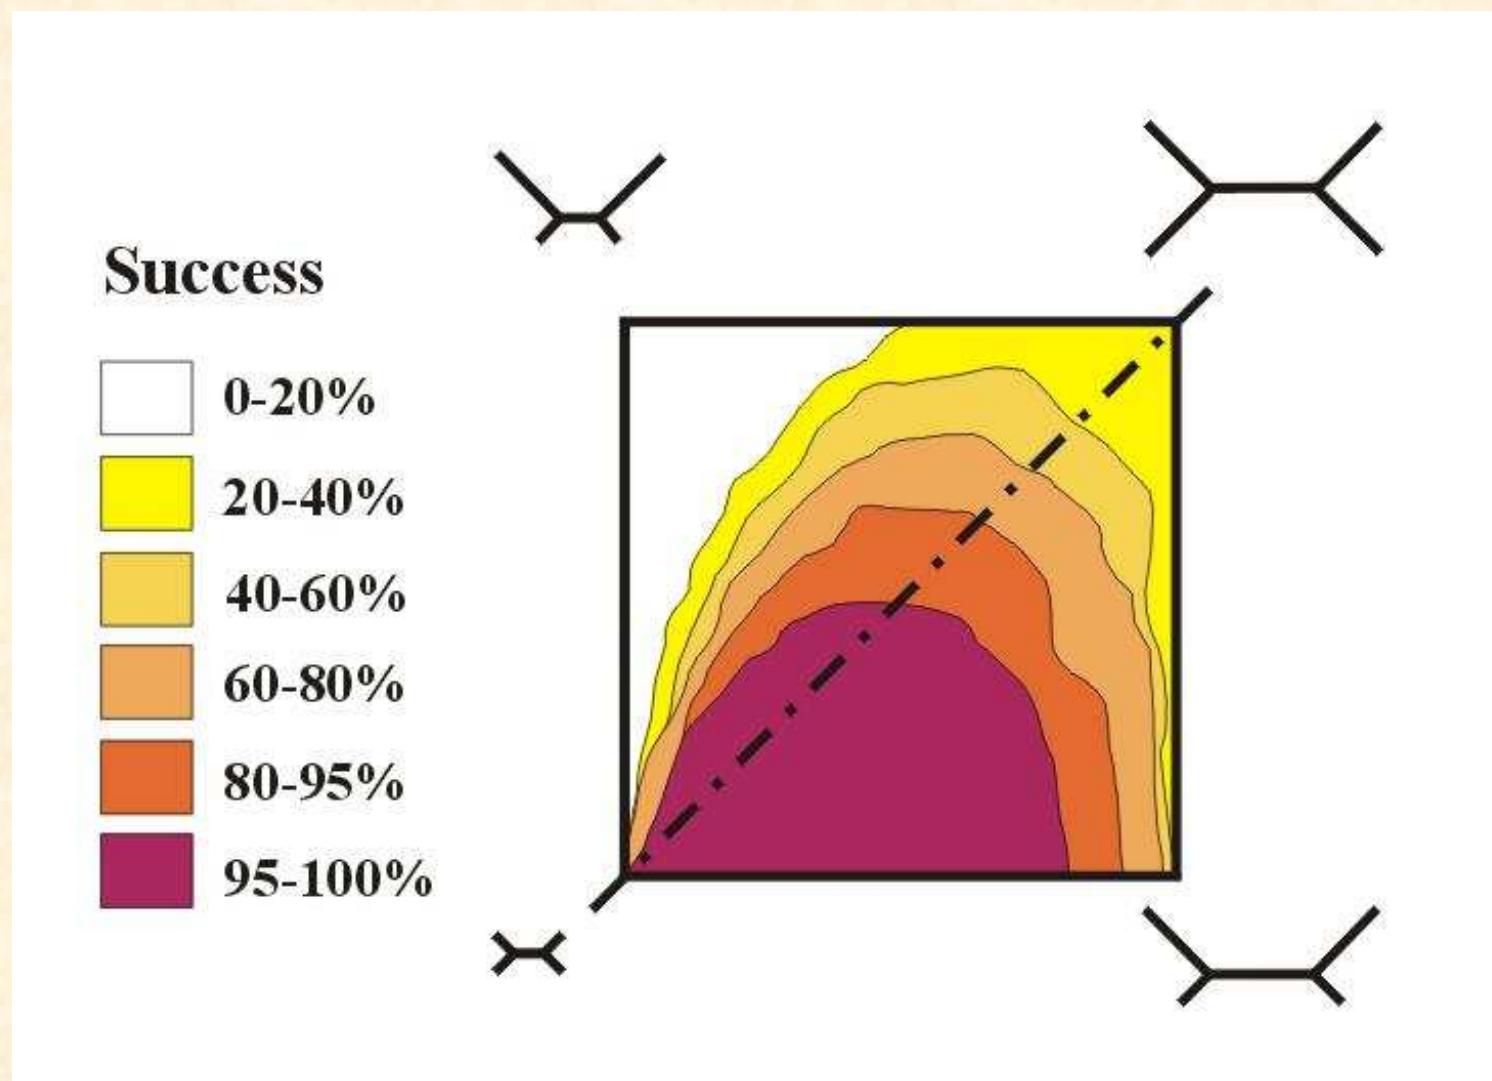
\* subtree pruning  
and regrafting (SPR)

\* tree bisection and  
reconnection (TBR)


# Parsimonie a konzistence



# Parsimonie a konzistence



# Parsimonie a konzistence




# Evoluční modely a distanční metody

		Báze po substituci			
		A	C	G	T
Původní báze	A	- $\frac{3}{4}$	$\frac{1}{4}$	$\frac{1}{4}$	$\frac{1}{4}$
	C	$\frac{1}{4}$	- $\frac{3}{4}$	$\frac{1}{4}$	$\frac{1}{4}$
	G	$\frac{1}{4}$	$\frac{1}{4}$	- $\frac{3}{4}$	$\frac{1}{4}$
	T	$\frac{1}{4}$	$\frac{1}{4}$	$\frac{1}{4}$	- $\frac{3}{4}$

$$Q = \begin{pmatrix} - & \alpha & \alpha & \alpha \\ \alpha & - & \alpha & \alpha \\ \alpha & \alpha & - & \alpha \\ \alpha & \alpha & \alpha & - \end{pmatrix}$$

**Jukes-Cantor (JC):** stejné frekvence bází  
stejné frekvence substitucí

## Kimura 2-parameter (K2P): transice ≠ transverze



$$Q = \begin{pmatrix} - & \beta & \alpha & \beta \\ \beta & - & \beta & \alpha \\ \alpha & \beta & - & \beta \\ \beta & \alpha & \beta & - \end{pmatrix}$$

Jestliže  $\alpha = \beta$ , K2P = JC

**Felsenstein (F81):** různé frekvence bází


$$Q = \begin{pmatrix} - & \pi_C & \pi_G & \pi_T \\ \pi_A & - & \pi_G & \pi_T \\ \pi_A & \pi_C & - & \pi_T \\ \pi_A & \pi_C & \pi_G & - \end{pmatrix}$$

Jestliže  $\pi_A = \pi_C = \pi_G = \pi_T$ , F81 = JC

**Hasegawa-Kishino-Yano (HKY):** různé frekvence bází  
transice  $\neq$  transverze

$$Q = \begin{pmatrix} - & \pi_C\beta & \pi_G\alpha & \pi_T\beta \\ \pi_A\beta & - & \pi_G\beta & \pi_T\alpha \\ \pi_A\alpha & \pi_C\beta & - & \pi_T\beta \\ \pi_A\beta & \pi_C\alpha & \pi_G\beta & - \end{pmatrix}$$


**General time-reversible (GTR, REV):** různé frequence bází  
různé frekvence všech substitucí




## Heterogenita substitučních rychlostí v různých částech sekvence

### Gama ( $\Gamma$ ) rozdělení:

- parametr tvaru  $\alpha$
- diskrétní gama model
- invariantní pozice  
 $\rightarrow \text{GTR} + \Gamma + \text{I}$



# Porovnání modelů




## Který model vybrat?

- **Likelihood ratio test (LRT):** nested models  
 $LR = 2(\ln L_2 - \ln L_1)$   
Chi-square,  $p_2 - p_1$  d.f.
- **Akaike information criterion (AIC):** nonnested models  
 $AIC = -2\ln L + 2p$ , where  $p$  = number of free parameters  
better model  $\rightarrow$  smaller AIC
- **Bayesian information criterion (BIC):** nonnested models  
 $BIC = -2\ln L + p\ln N$ , where  $N$  = sample size

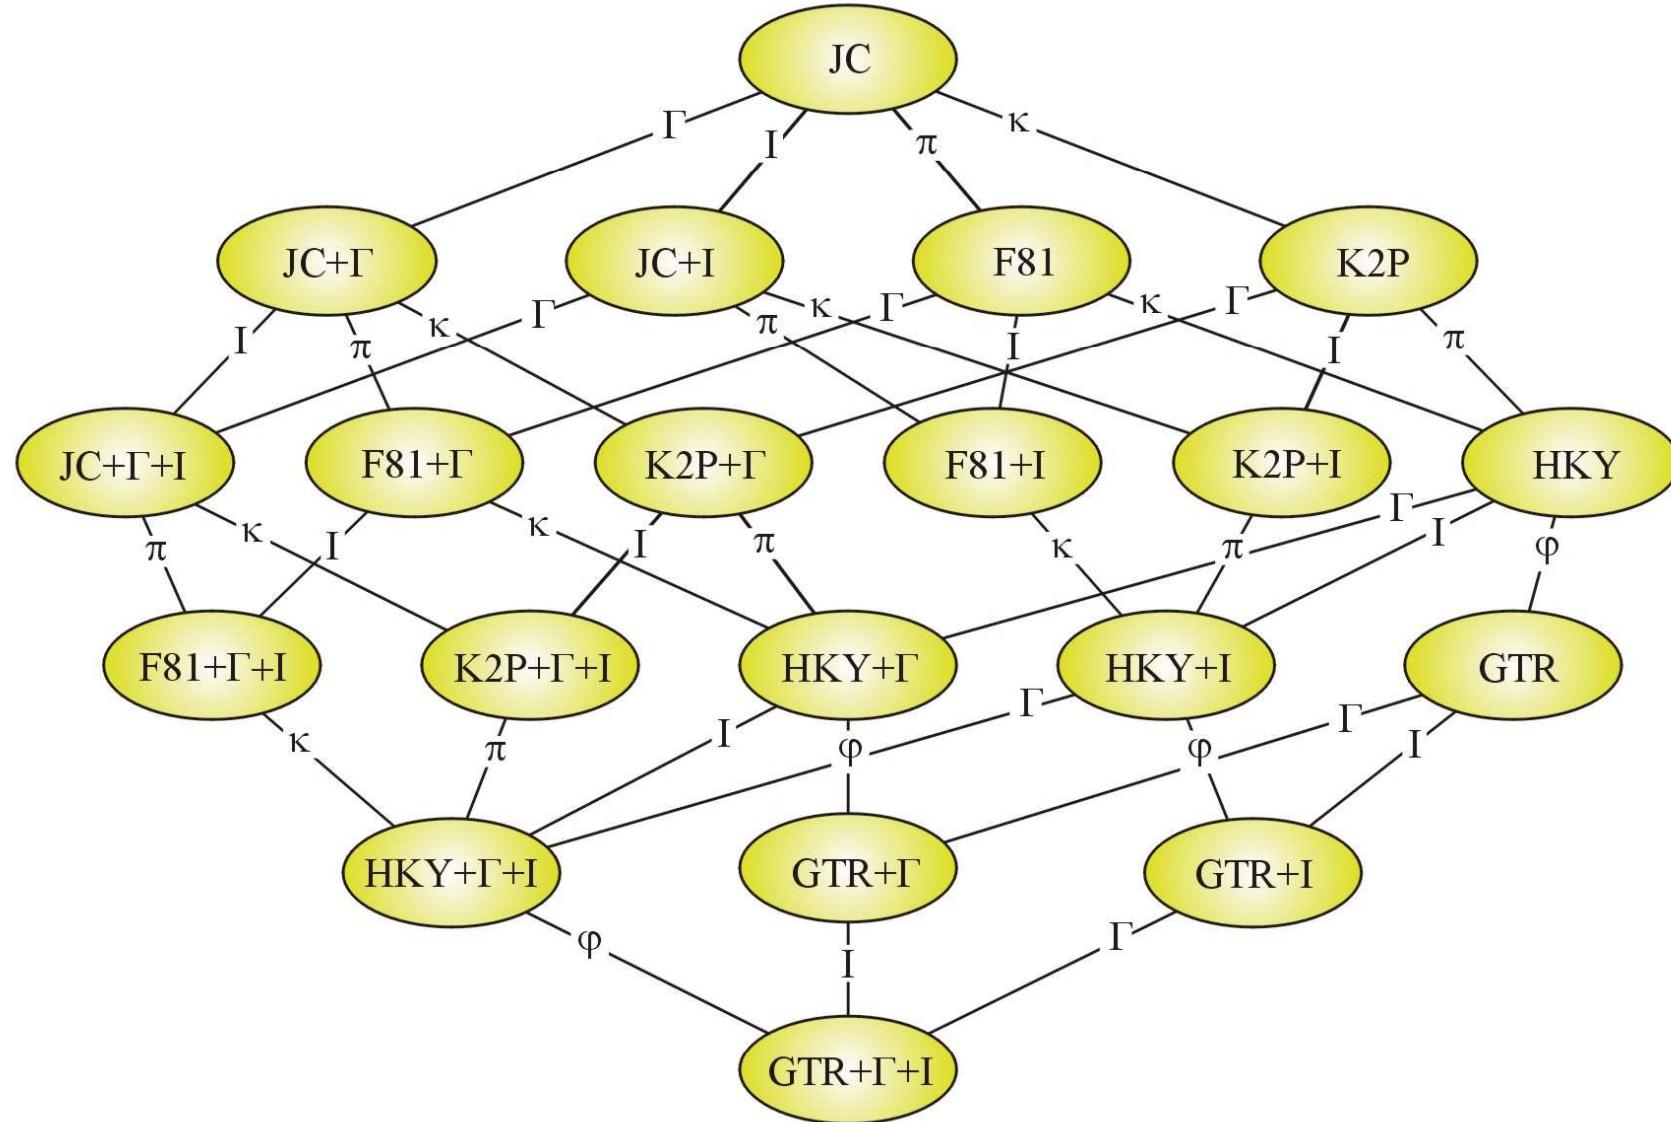
# Porovnání modelů

hierarchický LRT – ModelTest (Crandall and Posada)




# Porovnání modelů

dynamický LRT



# Porovnání modelů



- Více parametrů  $\Rightarrow$  více realismu, ale ...
- ... také více neurčitosti, protože jsou odhadovány ze stejného množství dat

# Distance

- počítány pro každý pár taxonů, z matice distancí (nebo podobnosti) konstruován strom
- distanční metody založeny na předpokladu, že pokud bychom znali skutečné distance mezi všemi studovanými taxony, mohli bychom velmi jednoduše rekonstruovat správnou fylogeneii
- výhoda: velmi rychlé a jednoduché (lze i na kalkulačce)

# Distance

1

10


20

30

sekvence 1: ACCCGTTAAGCTTAACGTACTTGGATCGAT  
sekvence 2: ACCCGTTAGGCTTAATGTACGTGGATCGAT

$$p\text{-distance: } p = k/n = 3/30 = 0.10$$


problém  
saturace:



## Distance pro některé modely:

JC	$d_{xy} = -\frac{3}{4} \ln\left(1 - \frac{4}{3}D\right)$	$D = 1 - (a + f + k + p)$
F81	$d_{xy} = -B \ln\left(1 - \frac{D}{B}\right)$	$D = \text{jako JC}$ $B = 1 - (\pi_A^2 + \pi_C^2 + \pi_G^2 + \pi_T^2)$
K2P	$d_{xy} = \frac{1}{2} \ln\left(\frac{1}{1 - 2P - Q}\right) + \frac{1}{4} \ln\left(\frac{1}{1 - 2Q}\right)$	rozdíly typu transicí: $P = c + h + i + n$ rozdíly typu transverzí: $Q = b + d + e + g + j + l + m + o$
F84	$d_{xy} = -2A \ln\left(1 - \frac{P}{2A} - \frac{(A-B)Q}{2AC}\right) + 2(A-B-C) \ln\left(1 - \frac{Q}{2C}\right)$	$\pi_Y = \pi_C + \pi_T, \pi_R = \pi_A + \pi_G,$ $A = \pi_C \pi_T / \pi_Y + \pi_A \pi_G / \pi_R,$ $B = \pi_C \pi_T + \pi_A \pi_G,$ $C = \pi_R \pi_Y, P \text{ a } Q \text{ jako K2P}$
GTR	$d_{xy} = -\text{stopa} \left[ \prod \ln \left( \prod {}^{-1} \mathbf{F}_{xy} \right) \right]$	$\Pi = \text{diagonální matice průměrných četností bází v sekvencích } X \text{ a } Y$

## Distance pro některé modely:



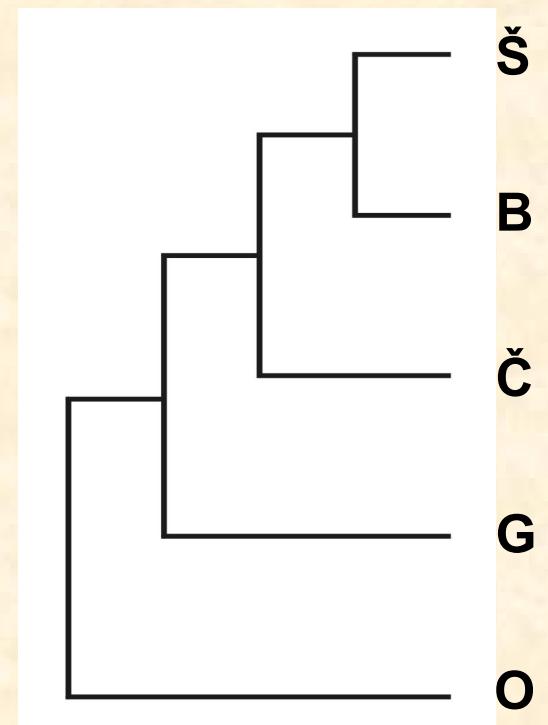
# Shluková analýza - UPGMA

	šimp.	bonobo	gorila	člověk	orang.
šimpanz (Š)	--				
bonobo (B)	0,0118	--			
gorila (G)	0,0427	0,0416	--		
člověk (Č)	0,0382	0,0327	0,0371	--	
orangutan (O)	0,0953	0,0916	0,0965	0,0928	--

1. Najdi min  $d(ij)$
2. Vypočítej novou matici  
 $d(\check{S}B-k) = [d(B-k)+d(\check{S}-k)]/2$
3. Opakuj 1 a 2.

	ŠB	gorila	člověk	orang.
ŠB	--			
gorila (G)	0,0422	--		
člověk (Č)	0,0355	0,0371	--	
orangutan (O)	0,0935	0,0965	0,0928	--

- UPGMA:  $d[(B\check{S}\check{C})G] = \{d(BG)+d(\check{S}G)+d(\check{C}G)\}/3$
- WPGMA:  $d[(B\check{S}\check{C})G] = \{d[(B\check{S})G] + d(\check{C}G)\}/2$
- single-linkage
- complete-linkage






# UPGMA a konzistence


**aditivní distance:**  $d_{AB} + d_{CD} \leq \max (d_{AC} + d_{BD}, d_{AD} + d_{BC})$

- tj. vzdálenost mezi 2 taxony je rovna součtu větví, které je spojují

**ultrametrické distance:**  $d_{AC} \leq \max (d_{AB}, d_{BC})$




aditivní strom




ultrametrický strom

# UPGMA a konzistence



# Spojení sousedů (neighbor-joining, NJ)

- Algoritmická metoda
- Princip minimální evoluce → minimalizuje součet délek větví  $S$
- Každý pár uzelů adjustován na základě divergence od ostatních
- Konstrukce jediného aditivního stromu



## Nevýhody distančních dat:

1. ztráta části informace během transformace
2. jakmile data transformována na distance, nelze se vrátit zpět  
(odlišné sekvence mohou dát stejné distance)
3. nelze sledovat evoluci na různých částech sekvence
4. obtížná biologická interpretace délek větví
5. nelze kombinovat různé distanční matice