

# **Substitučné modely**

**Broňa Brejová**

**15.11.2018**

## Substitučné modely, označenie

Nech  $P(b|a, t)$  je pravdepodobnosť, že ak začneme s bázou  $a$ , tak po čase  $t$  budeme mať bázu  $b$ .

Matica pravdepodobností prechodu:

$$S(t) = \begin{pmatrix} P(A|A, t) & P(C|A, t) & P(G|A, t) & P(T|A, t) \\ P(A|C, t) & P(C|C, t) & P(G|C, t) & P(T|C, t) \\ P(A|G, t) & P(C|G, t) & P(G|G, t) & P(T|G, t) \\ P(A|T, t) & P(C|T, t) & P(G|T, t) & P(T|T, t) \end{pmatrix}$$

## Substitučné modely, požiadavky

- $S(0) = I$

- $\lim_{t \rightarrow \infty} S(t) = \begin{pmatrix} \pi_A & \pi_C & \pi_G & \pi_T \\ \pi_A & \pi_C & \pi_G & \pi_T \\ \pi_A & \pi_C & \pi_G & \pi_T \\ \pi_A & \pi_C & \pi_G & \pi_T \end{pmatrix}$

Rozdelenie  $\pi$  nazývame limitné (equilibrium)

- $S(t_1 + t_2) = S(t_1)S(t_2)$  (multiplikatívnosť)
- Pre Jukes-Cantorov model by navyše malo platit'

$$S(t) = \begin{pmatrix} 1 - 3s(t) & s(t) & s(t) & s(t) \\ s(t) & 1 - 3s(t) & s(t) & s(t) \\ s(t) & s(t) & 1 - 3s(t) & s(t) \\ s(t) & s(t) & s(t) & 1 - 3s(t) \end{pmatrix}$$

$$S(t) = \begin{pmatrix} 1 - 3s(t) & s(t) & s(t) & s(t) \\ s(t) & 1 - 3s(t) & s(t) & s(t) \\ s(t) & s(t) & 1 - 3s(t) & s(t) \\ s(t) & s(t) & s(t) & 1 - 3s(t) \end{pmatrix}$$

$$\begin{aligned} S(2t) &= S(t)^2 = \\ &= \begin{pmatrix} 1 - 6s(t) + 12s(t)^2 & 2s(t) - 4s(t)^2 & 2s(t) - 4s(t)^2 & 2s(t) - 4s(t)^2 \\ 2s(t) - 4s(t)^2 & 1 - 6s(t) + 12s(t)^2 & 2s(t) - 4s(t)^2 & 2s(t) - 4s(t)^2 \\ 2s(t) - 4s(t)^2 & 2s(t) - 4s(t)^2 & 1 - 6s(t) + 12s(t)^2 & 2s(t) - 4s(t)^2 \\ 2s(t) - 4s(t)^2 & 2s(t) - 4s(t)^2 & 2s(t) - 4s(t)^2 & 1 - 6s(t) + 12s(t)^2 \end{pmatrix} \\ &\approx \begin{pmatrix} 1 - 6s(t) & 2s(t) & 2s(t) & 2s(t) \\ 2s(t) & 1 - 6s(t) & 2s(t) & 2s(t) \\ 2s(t) & 2s(t) & 1 - 6s(t) & 2s(t) \\ 2s(t) & 2s(t) & 2s(t) & 1 - 6s(t) \end{pmatrix} \end{aligned}$$

pre  $t \rightarrow 0$

## Matica rýchlosťí (matica intenzít, substitution rate matrix)

- Matica rýchlosťí pre Jukes-Cantorov model:

$$R = \begin{pmatrix} -3\alpha & \alpha & \alpha & \alpha \\ \alpha & -3\alpha & \alpha & \alpha \\ \alpha & \alpha & -3\alpha & \alpha \\ \alpha & \alpha & \alpha & -3\alpha \end{pmatrix}$$

- Pre veľmi malý čas  $t$  je  $S(t) \approx I + Rt$
- Rýchlosť  $\alpha$  je pravdepodobnosť zmeny za jednotku času pre veľmi krátke  $t$ , resp. derivácia  $s(t)$  vzhľadom na  $t$  v bode 0
- Riešením diferenciálnych rovíc pre Jukes-Cantorov model dostávame  $s(t) = (1 - e^{-4\alpha t})/4$

## Riešenie pre Jukes-Cantorov model

$$S(t) = \begin{pmatrix} (1 + 3e^{-4\alpha t})/4 & (1 - e^{-4\alpha t})/4 & (1 - e^{-4\alpha t})/4 & (1 - e^{-4\alpha t})/4 \\ (1 - e^{-4\alpha t})/4 & (1 + 3e^{-4\alpha t})/4 & (1 - e^{-4\alpha t})/4 & (1 - e^{-4\alpha t})/4 \\ (1 - e^{-4\alpha t})/4 & (1 - e^{-4\alpha t})/4 & (1 + 3e^{-4\alpha t})/4 & (1 - e^{-4\alpha t})/4 \\ (1 - e^{-4\alpha t})/4 & (1 - e^{-4\alpha t})/4 & (1 - e^{-4\alpha t})/4 & (1 + 3e^{-4\alpha t})/4 \end{pmatrix}$$

Matica rýchlosťí sa zvykne normalizovať tak, aby na jednotku času pripadla v priemere jedna substitúcia, čo dosiahneme ak  $\alpha = 1/3$

## Substitučné matice, zhrnutie

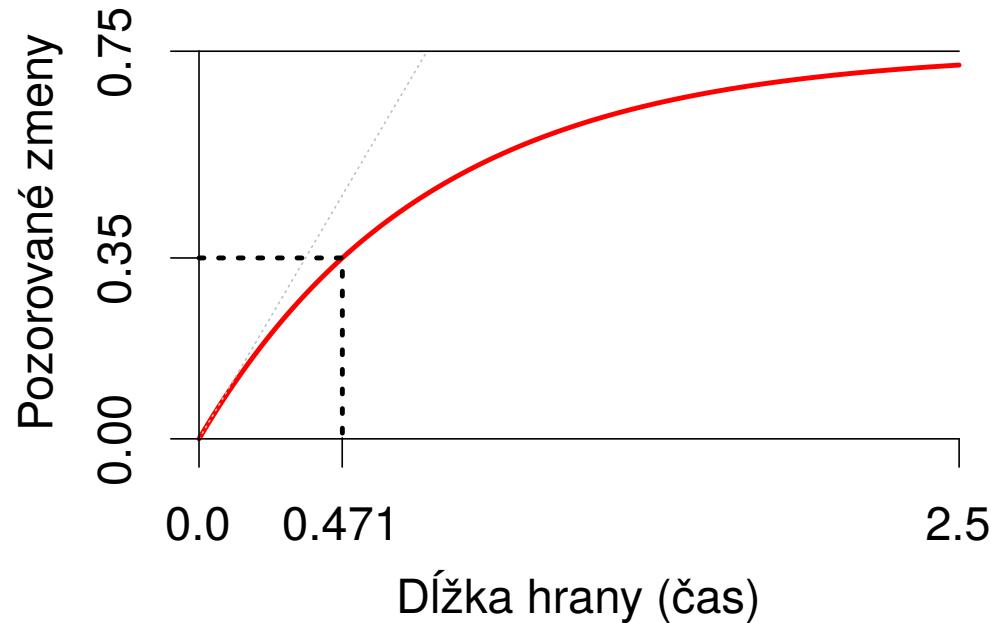
- $S(t)$ : matica  $4 \times 4$ , kde políčko  $S(t)_{a,b} = P(b|a, t)$  je pravdepodobnosť, že ak začneme s bázou  $a$ , tak po čase  $t$  budeme mať bázu  $b$ .
- Jukes-Cantorov model predpokladá, že  $P(b|a, t)$  rovnaká pre každé  $a \neq b$
- Pre daný čas  $t$  máme mimo diagonály  $s(t)$ , na diagonále  $1 - 3s(t)$
- Matica rýchlosťí  $R$ : pre J-C model mimo diagonály  $\alpha$ , na diagonále  $-3\alpha$
- Pre veľmi malé  $t$  máme  $S(t) \approx I - Rt$
- Rýchlosť  $\alpha$  je pravdepodobnosť zmeny za jednotku času pre veľmi malé  $t$ , resp. derivácia  $s(t)$  vzhľadom na  $t$  v bode  $t = 0$
- Riešením diferenciálnych rovíc pre J-C model dostávame
$$s(t) = (1 - e^{-4\alpha t})/4$$
- Matica rýchlosťí sa zvykne normalizovať tak, aby na jednotku času pripadla v priemere jedna substitúcia, čo dosiahneme ak  $\alpha = 1/3$

## Korekcia evolučných vzdialenosí

$$\Pr(X_{t_0+t} = C \mid X_{t_0} = A) = \frac{1}{4}(1 - e^{-\frac{4}{3}t})$$

Očakávaná frekvencia pozorovaných zmien na bázu za čas  $t$ :

$$D(t) = \Pr(X_{t_0+t} \neq X_{t_0}) = \frac{3}{4}(1 - e^{-\frac{4}{3}t})$$



Korekcia pozorovaných vzdialenosí

$$D = \frac{3}{4}(1 - e^{-\frac{4}{3}t}) \quad \Rightarrow \quad t = -\frac{3}{4} \ln\left(1 - \frac{4}{3}D\right)$$

## Zložitejšie modely

- Všeobecná matica rýchlosí  $R$

$$R = \begin{pmatrix} \cdot & \mu_{AC} & \mu_{AG} & \mu_{AT} \\ \mu_{CA} & \cdot & \mu_{CG} & \mu_{CT} \\ \mu_{GA} & \mu_{GC} & \cdot & \mu_{GT} \\ \mu_{TA} & \mu_{TC} & \mu_{TG} & \cdot \end{pmatrix}$$

- $\mu_{xy}$  je rýchlosť, akou sa báza  $x$  mení na inú bázu  $y$
- Presnejšie  $\mu_{xy} = \lim_{t \rightarrow 0} \frac{\Pr(y | x, t)}{t}$
- Diagonálu dopočítame tak, aby súčet každého riadku bol 0
- Existujú modely s menším počtom parametrov (kompromis medzi J-C a ľubovoľnou maticou)

## Kimurov model

- Zachytáva, že puríny sa častejšie menia na iné puríny (A a G) a pyrimidíny na iné pyrimidíny (C a T)
- Má dva parametre: rýchlosť tranzícii  $\alpha$ , transverzií  $\beta$

$$\bullet R = \begin{pmatrix} -2\beta - \alpha & \beta & \alpha & \beta \\ \beta & -2\beta - \alpha & \beta & \alpha \\ \alpha & \beta & -2\beta - \alpha & \beta \\ \beta & \alpha & \beta & -2\beta - \alpha \end{pmatrix}$$

## HKY model (Hasegawa, Kishino, Yano)

- Rozšírenie Kimurovho modelu, umožňuje aj rôzne pravdepodobnosti A, C, G a T v limite (v ekvilibriu)
- Ak nastavíme čas v evolučnom modeli na nekonečno, nezáleží na tom, z ktorej bázy sme začali, frekvencia výskytu jednotlivých báz sa ustáli v tzv. ekvilibriu.
- V Jukes-Cantorovom modeli je pravdepodobnosť každej bázy v ekvilibriu  $1/4$ .
- V HKY si zvolíme aj frekvencie jednotlivých nukleotidov v ekvilibriu  $\pi_A, \pi_C, \pi_G, \pi_T$  so súčtom 1
- Parameter  $\kappa$ : pomer tranzícii a transverzií ( $\alpha/\beta$ )
- Matica rýchlosťí:

$$\mu_{x,y} = \begin{cases} \kappa\pi_y & \text{ak mutácia z } x \text{ na } y \text{ je tranzícia} \\ \pi_y & \text{ak mutácia z } x \text{ na } y \text{ je transverzia} \end{cases}$$

## Od $R$ k $S(t)$

- Pre zložité modely nevieme odvodiť explicitný vzorec na výpočet  $S(t)$ , ako sme mali pri Jukes-Cantorovom modeli
- Vo všeobecnosti  $S(t) = e^{Rt}$
- Exponenciálna funkcia matice  $A$  sa definuje ako  $e^A = \sum_{k=0}^{\infty} \frac{1}{k!} A^k$
- Ak  $R$  diagonalizujeme  $R = UDU^{-1}$ , kde  $D$  je diagonálna matica, tak  $e^{Rt} = Ue^{Dt}U^{-1}$  a exponenciálnu funkciu uplatníme iba na prvky na uhlopriečke  $D$
- Diagonalizácia vždy existuje pre symetrické  $R$  (na diagonále vlastné hodnoty)