

KOALESCENCE

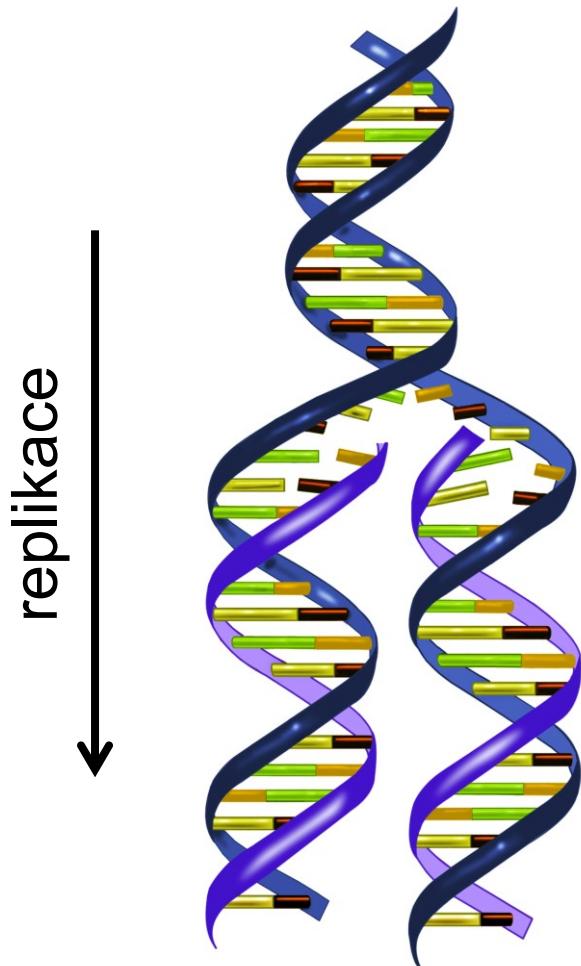
GENOVÉ GENEALOGIE A TEORIE KOALESCENCE

Dosud: co se s populací stane v příští generaci?

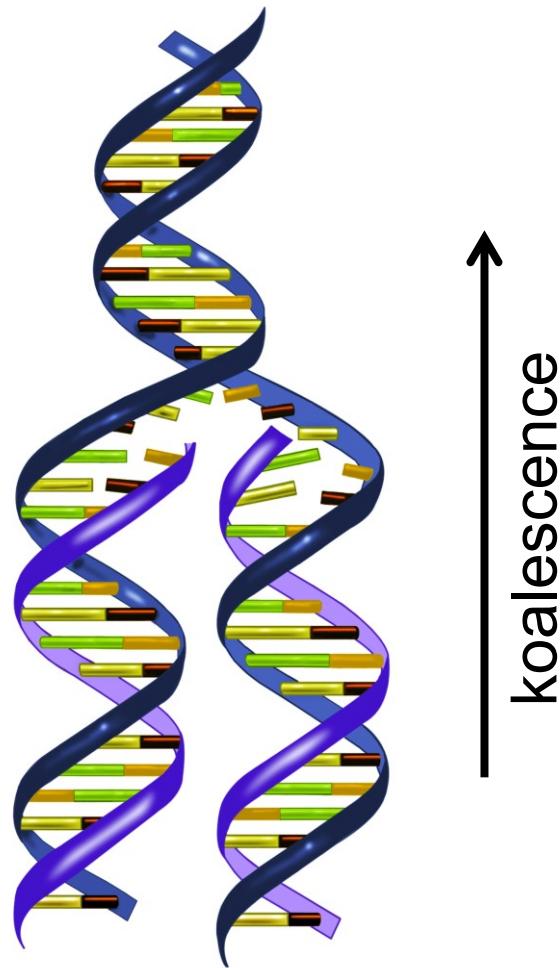
Ted': co předcházelo současnému stavu?

⇒ „pohled zpět“

Základní premisa populační genetiky: DNA replikuje...



Základní premisa populační genetiky: DNA replikuje...



... opakem replikace je koalescence

Wrightova-Fisherova populace:

diploidní, hermafrodit

velikost omezená, žádné fluktuace N

náhodné oplození

kompletní izolace (žádný tok genů)

diskrétní generace

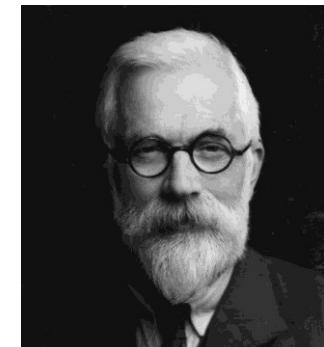
žádná věková struktura

žádná selekce

rozptyl výběru gamet do další generace^{*)}

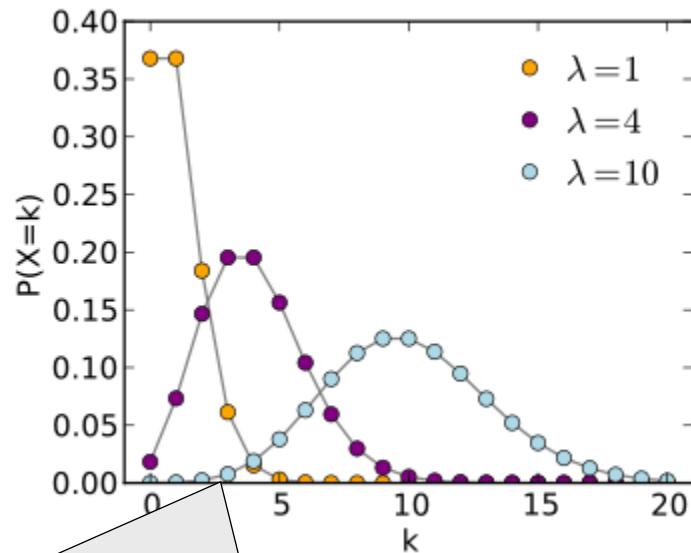
→ Poissonovo rozdělení

^{*)} tj. každý jedinec může přispět
0, 1, 2, 3, ..., ∞ gametami



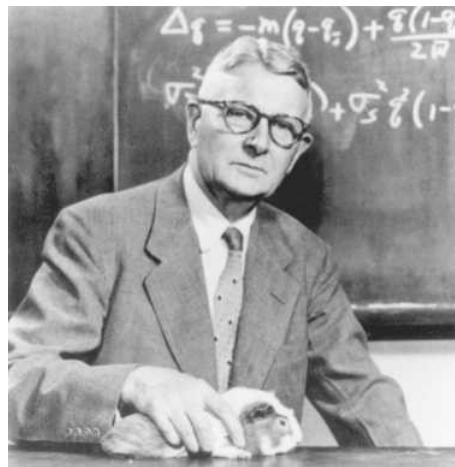
S. Wright

R.A. Fisher

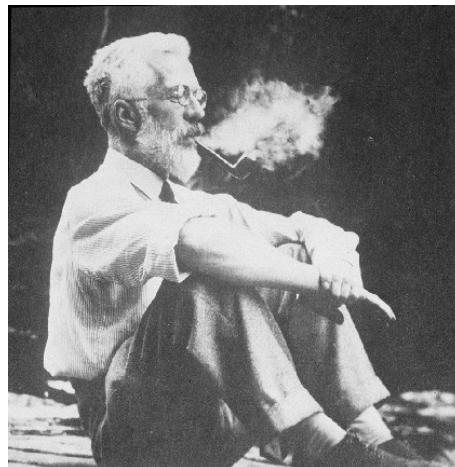


Poissonovo rozdělení \approx binomické pro velký počet pokusů ($n \rightarrow \infty$) a malou pravděpodobnost jevu ($p \rightarrow 0$)
(v praxi $n > 30$; $p \leq 1/10$, pak $\lambda = np$)
např. mutace

Sortování linií ve WF modelu:



Sewall Wright



Ronald A. Fisher

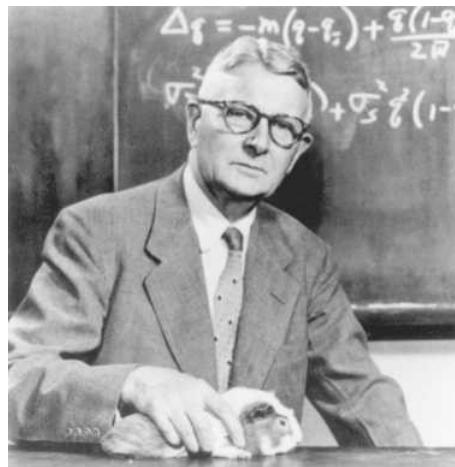
↑
čas

A large red vertical arrow pointing upwards, labeled "čas" (time) at its base.

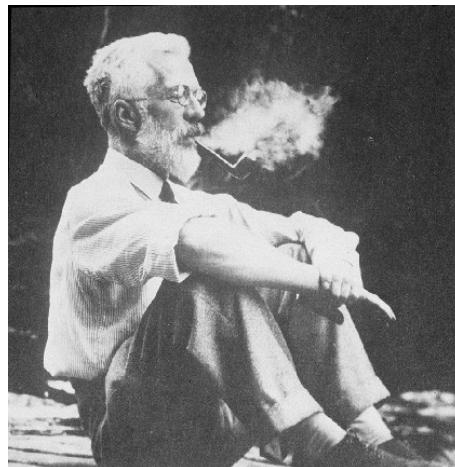
generace 1



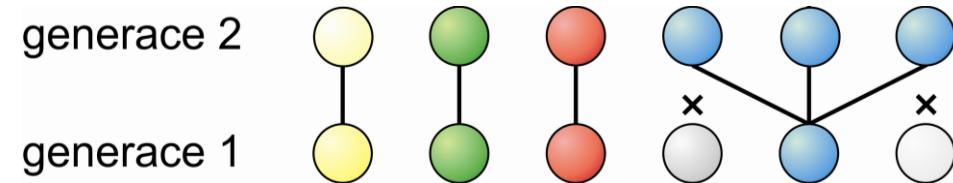
Sortování linií ve WF modelu:



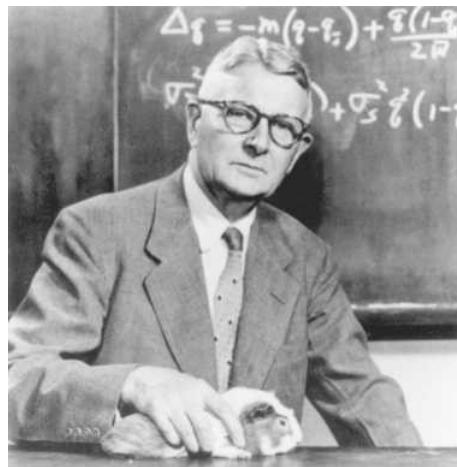
Sewall Wright



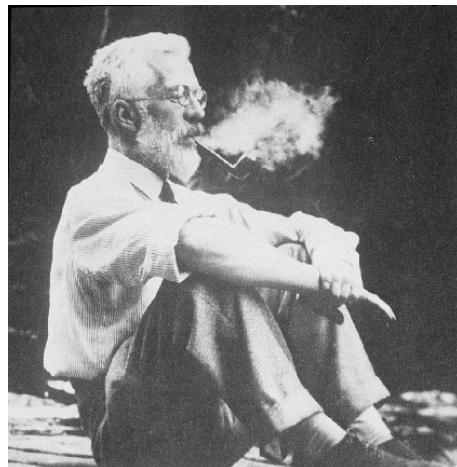
Ronald A. Fisher



Sortování linií ve WF modelu:



Sewall Wright

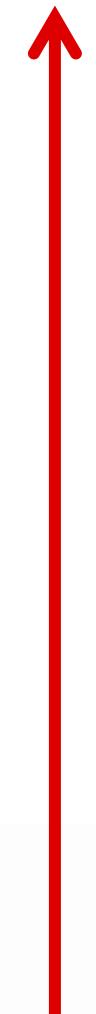
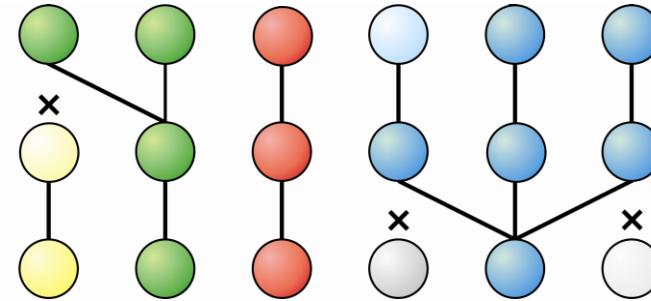


Ronald A. Fisher

generace 3

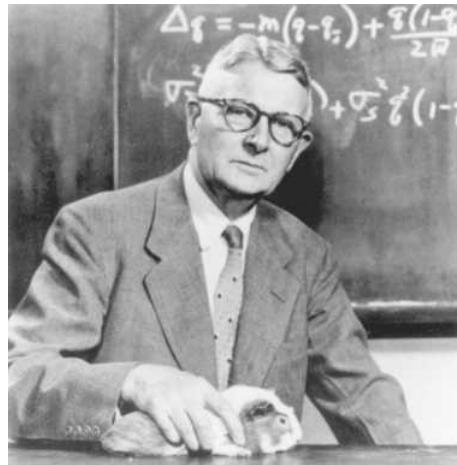
generace 2

generace 1

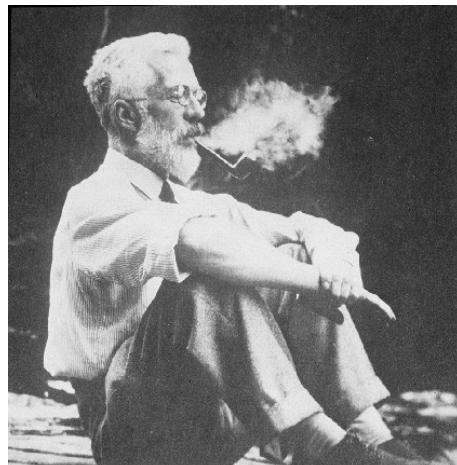


čas

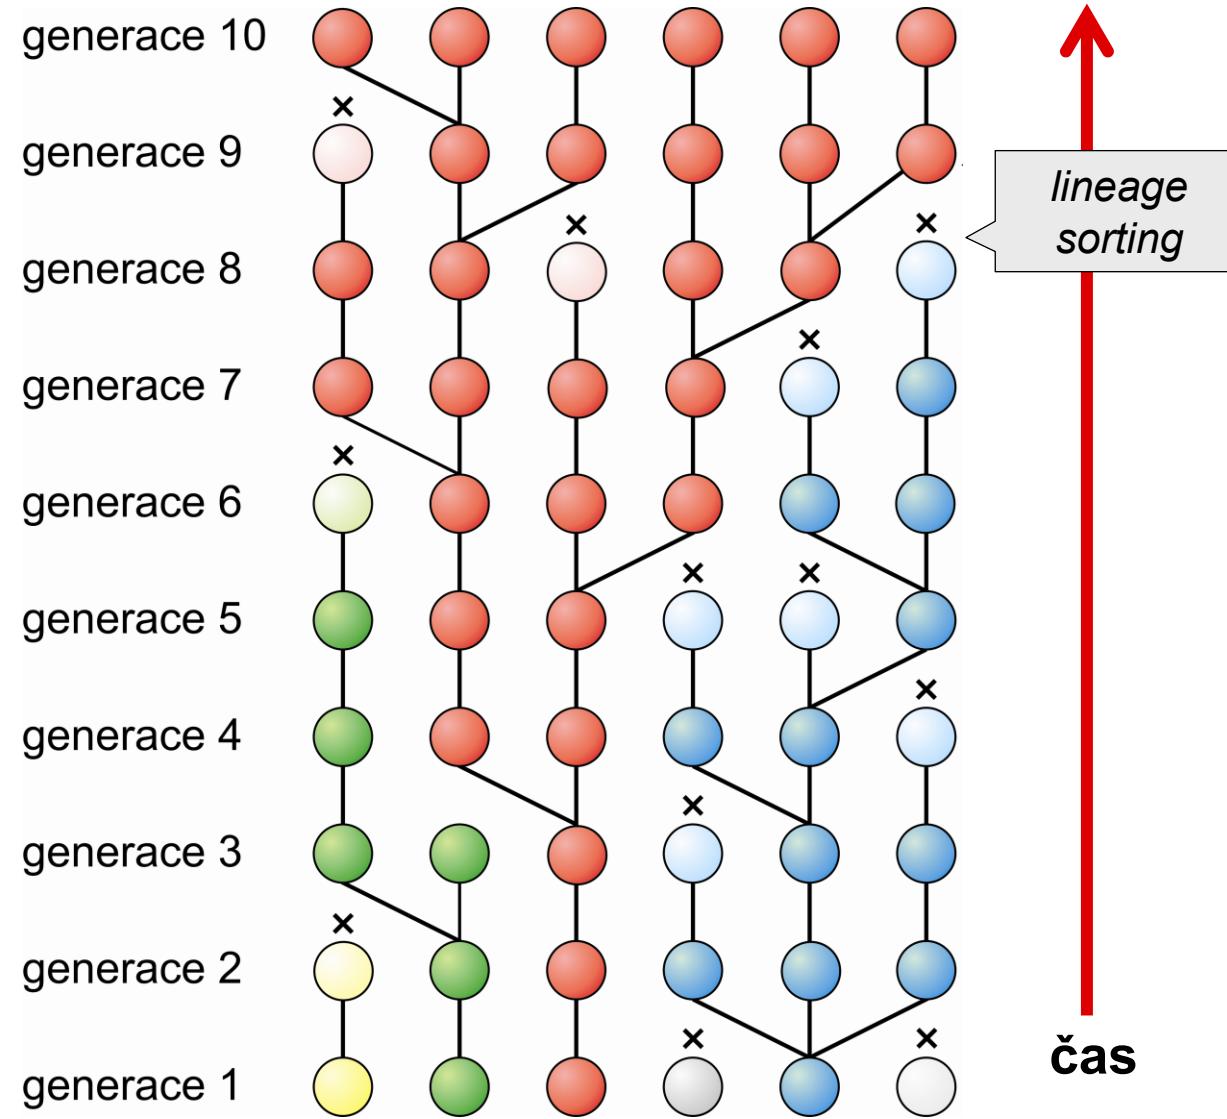
Sortování linií ve WF modelu:



Sewall Wright



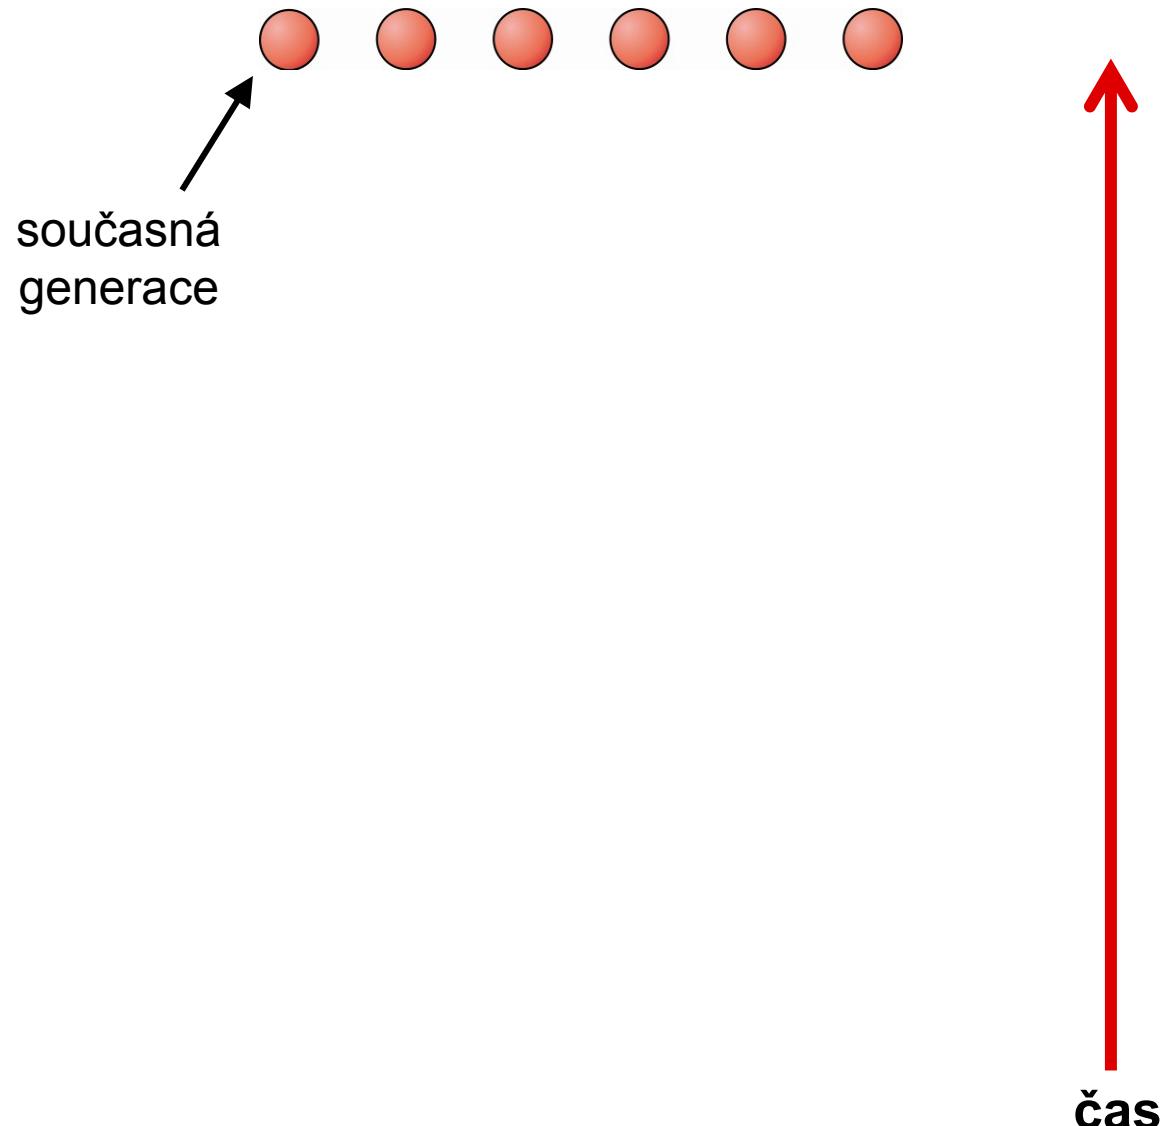
Ronald A. Fisher



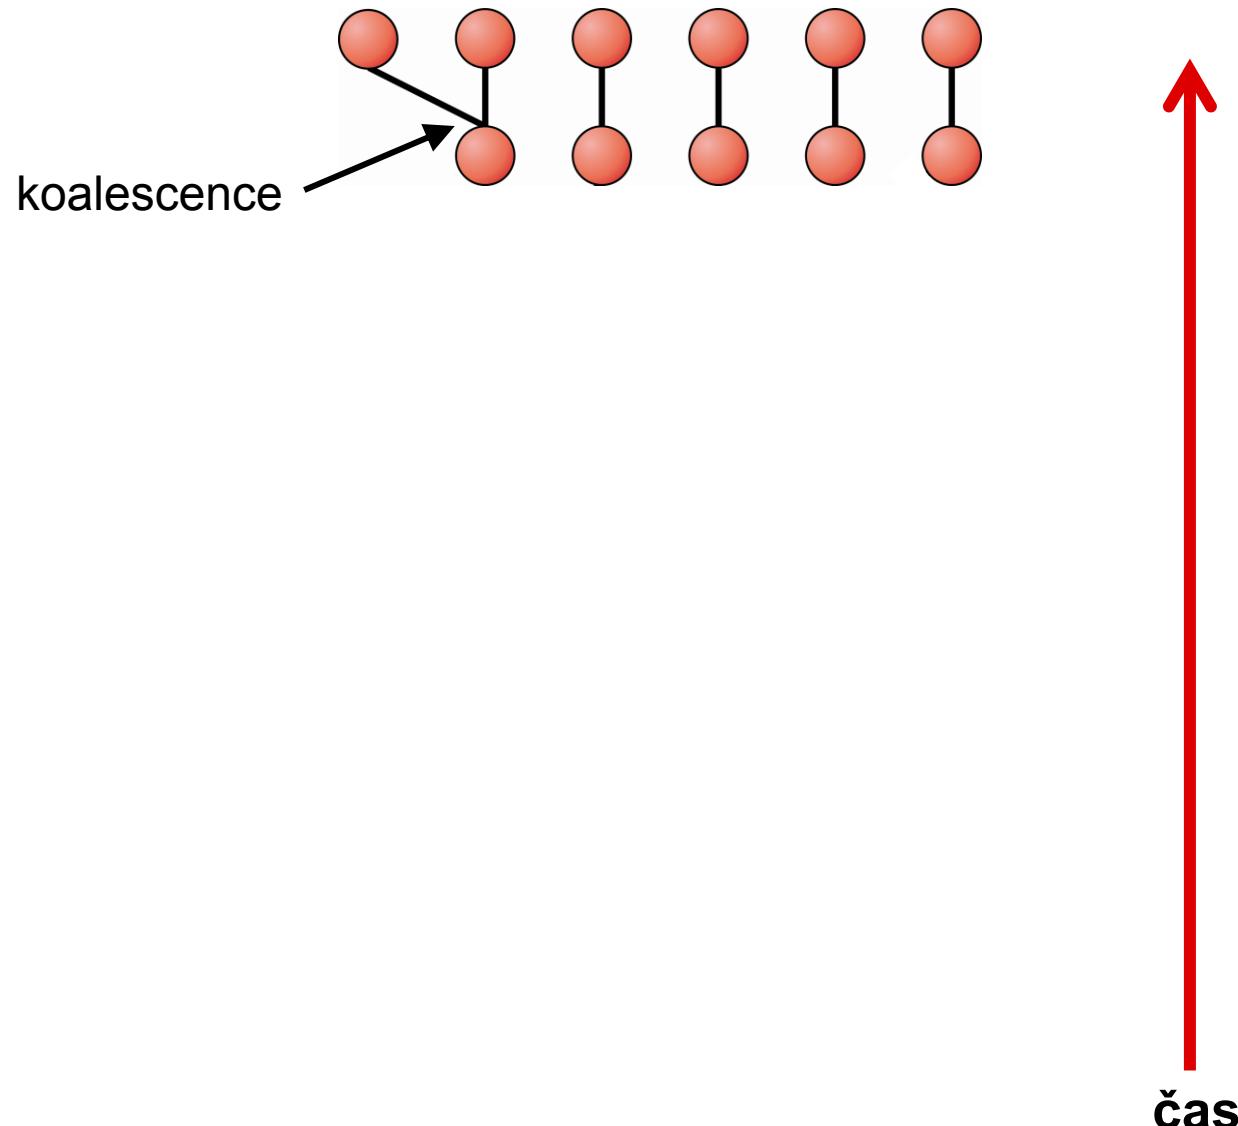
Koalescence:



John F.C. Kingman

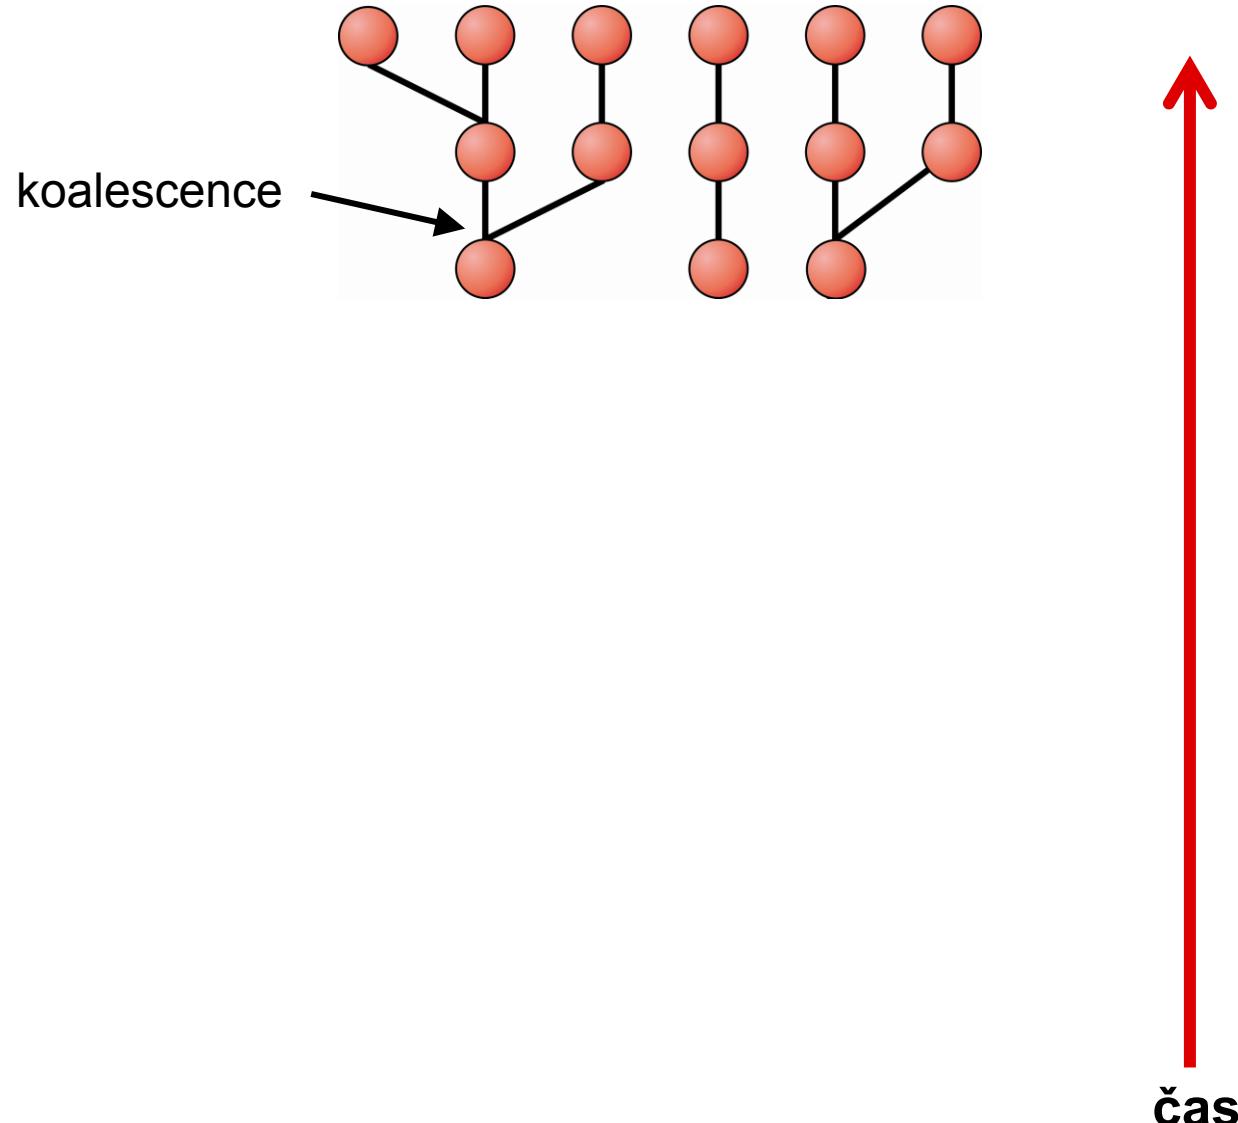


Koalescence:



John F.C. Kingman

Koalescence:



John F.C. Kingman

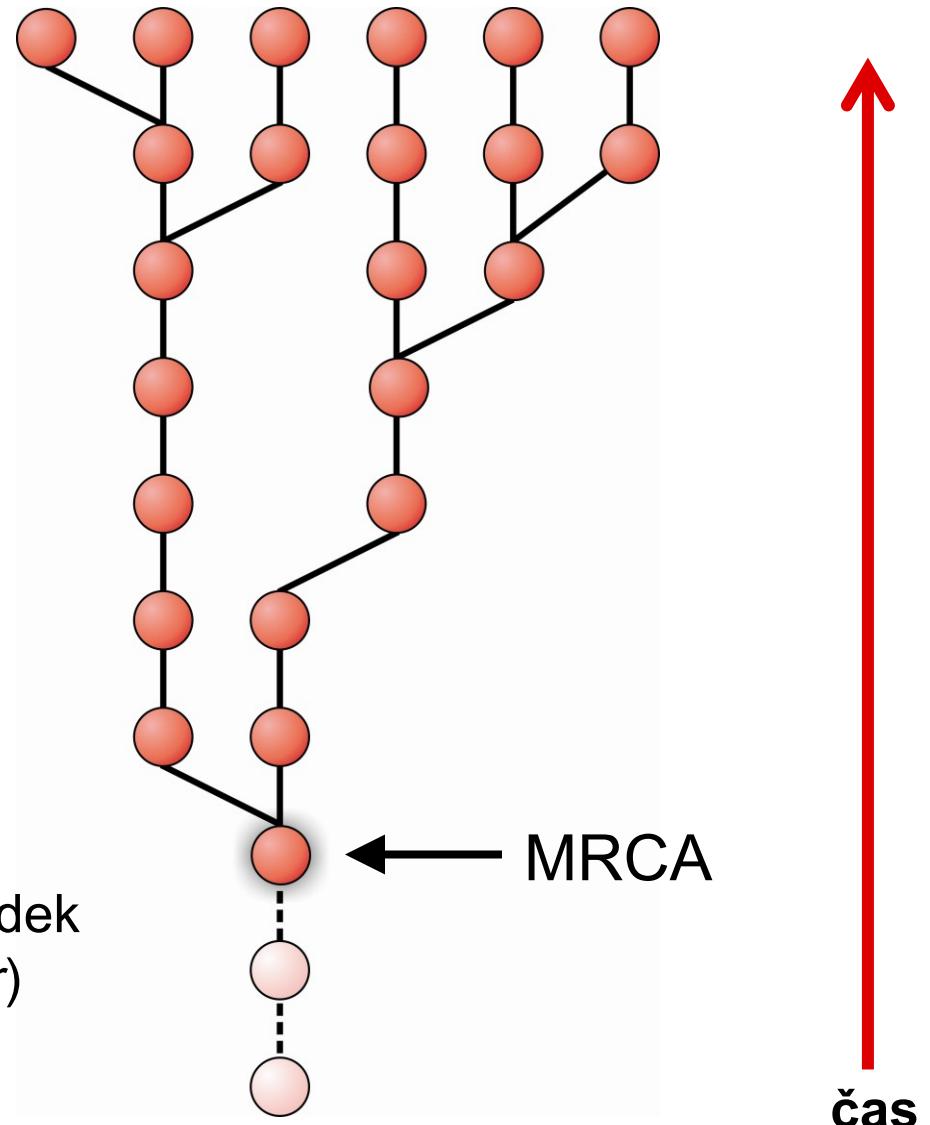
čas

Koalescence:



John F.C. Kingman

MRCA = nejbližší společný předek
(most recent common ancestor)

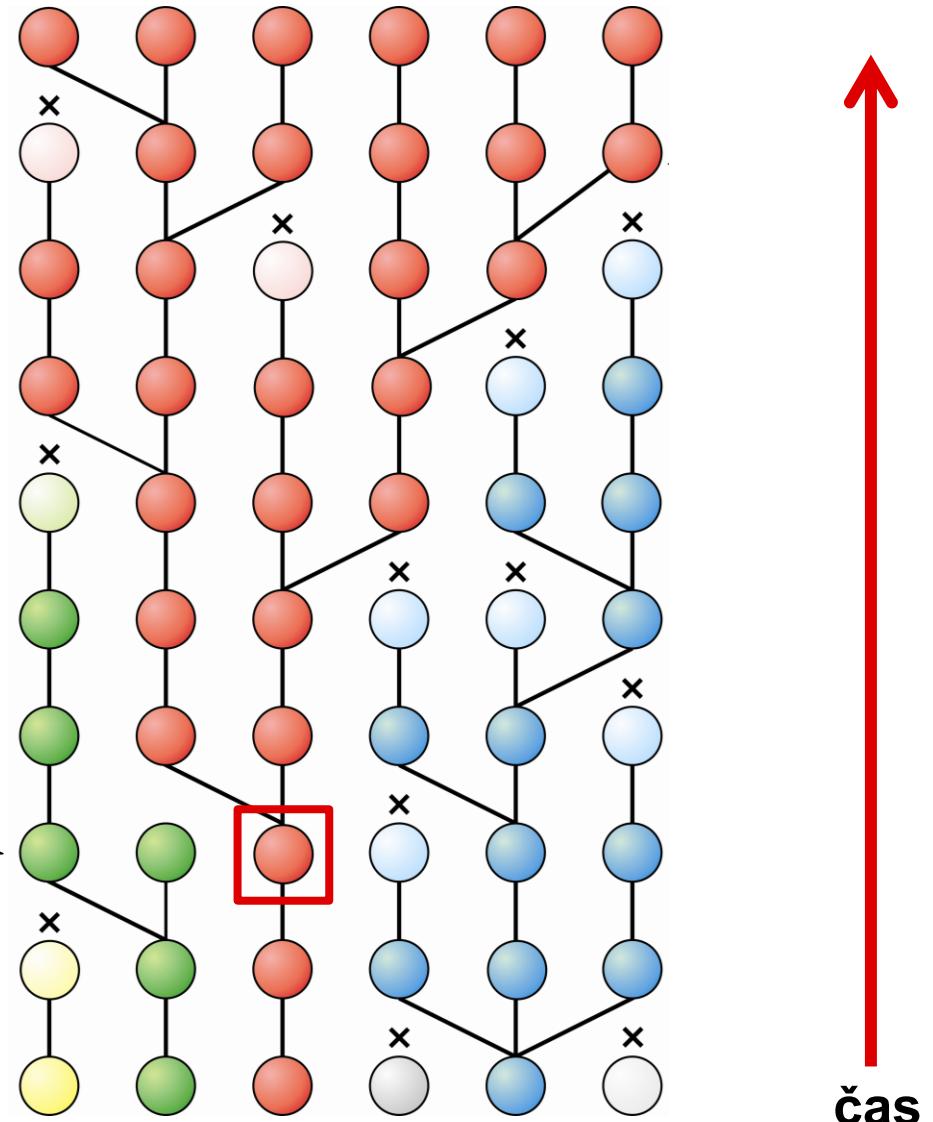


Koalescence:



John F.C. Kingman

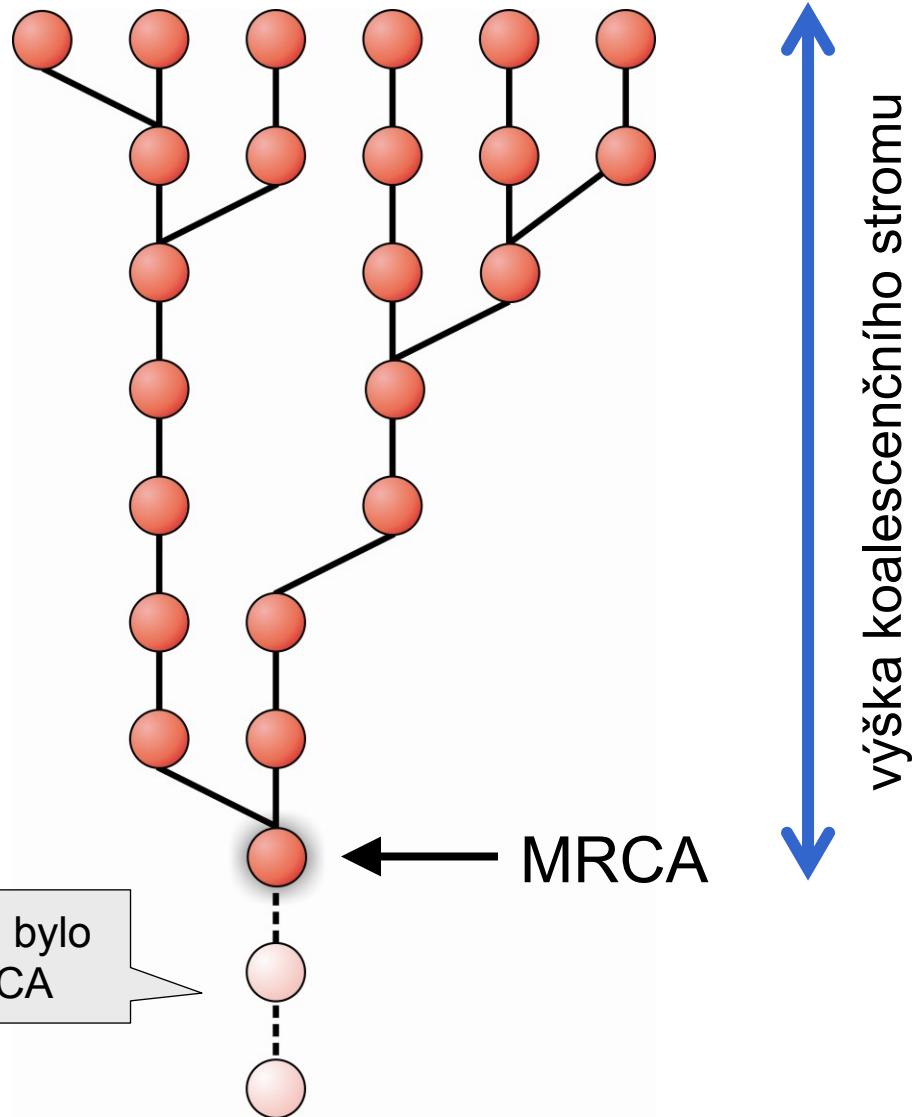
nevíme, kolik kopií
bylo v generaci
MRCA



Koalescence:



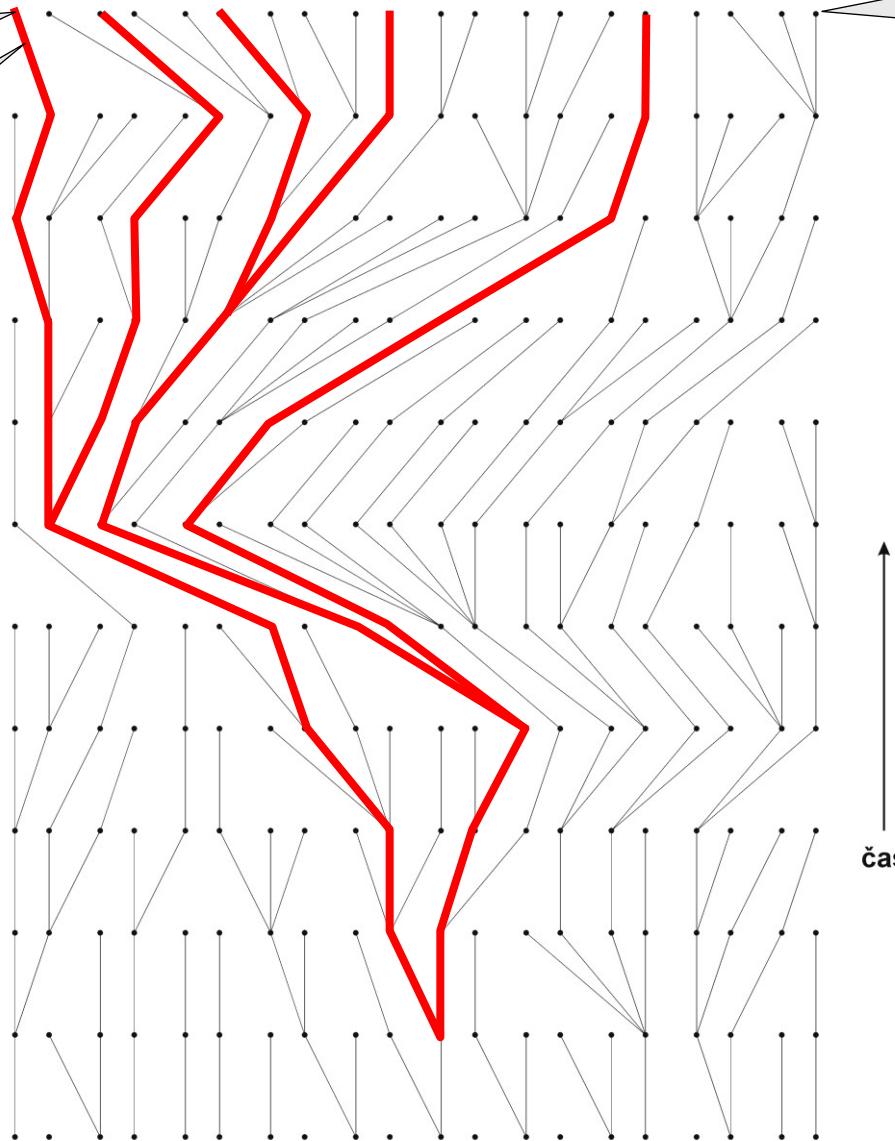
John F.C. Kingman

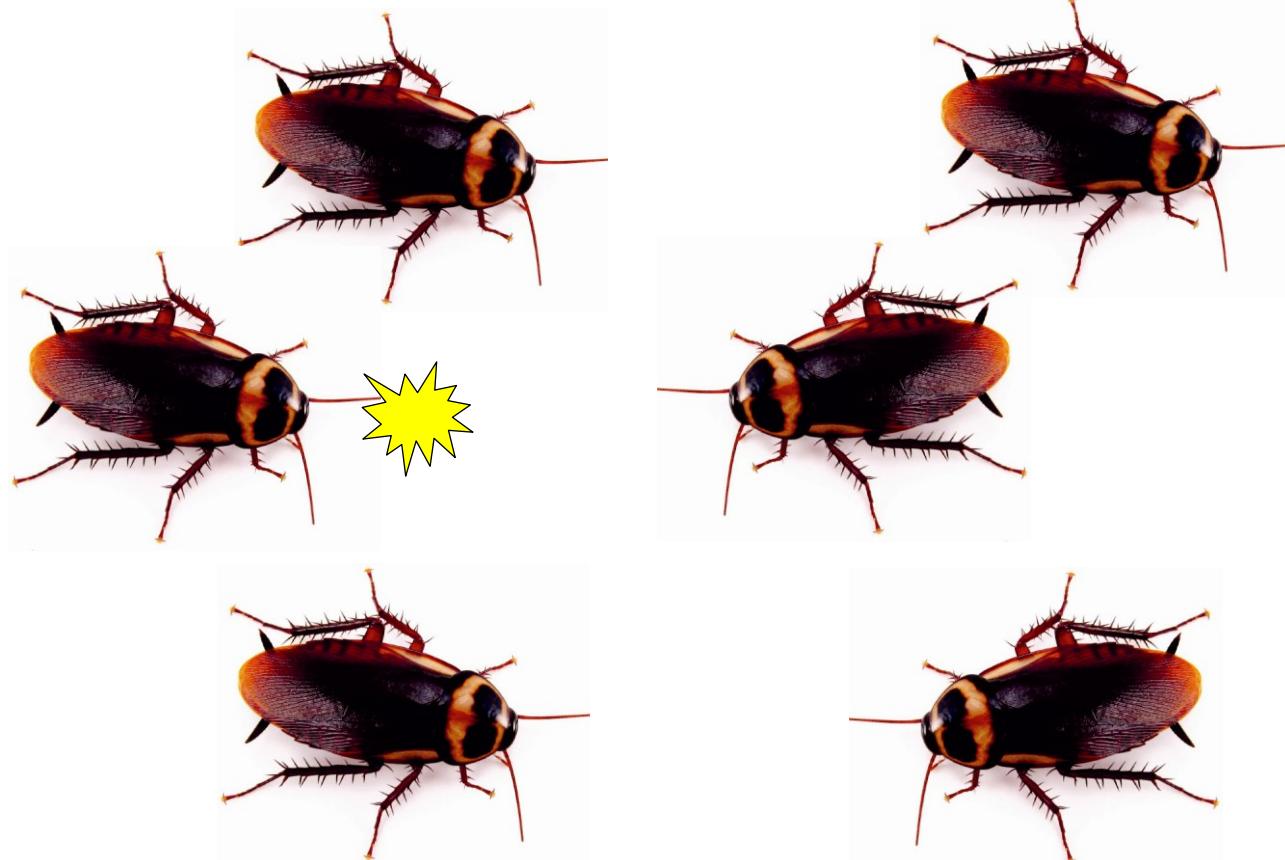


$n = 5$ kopií
ve vzorku

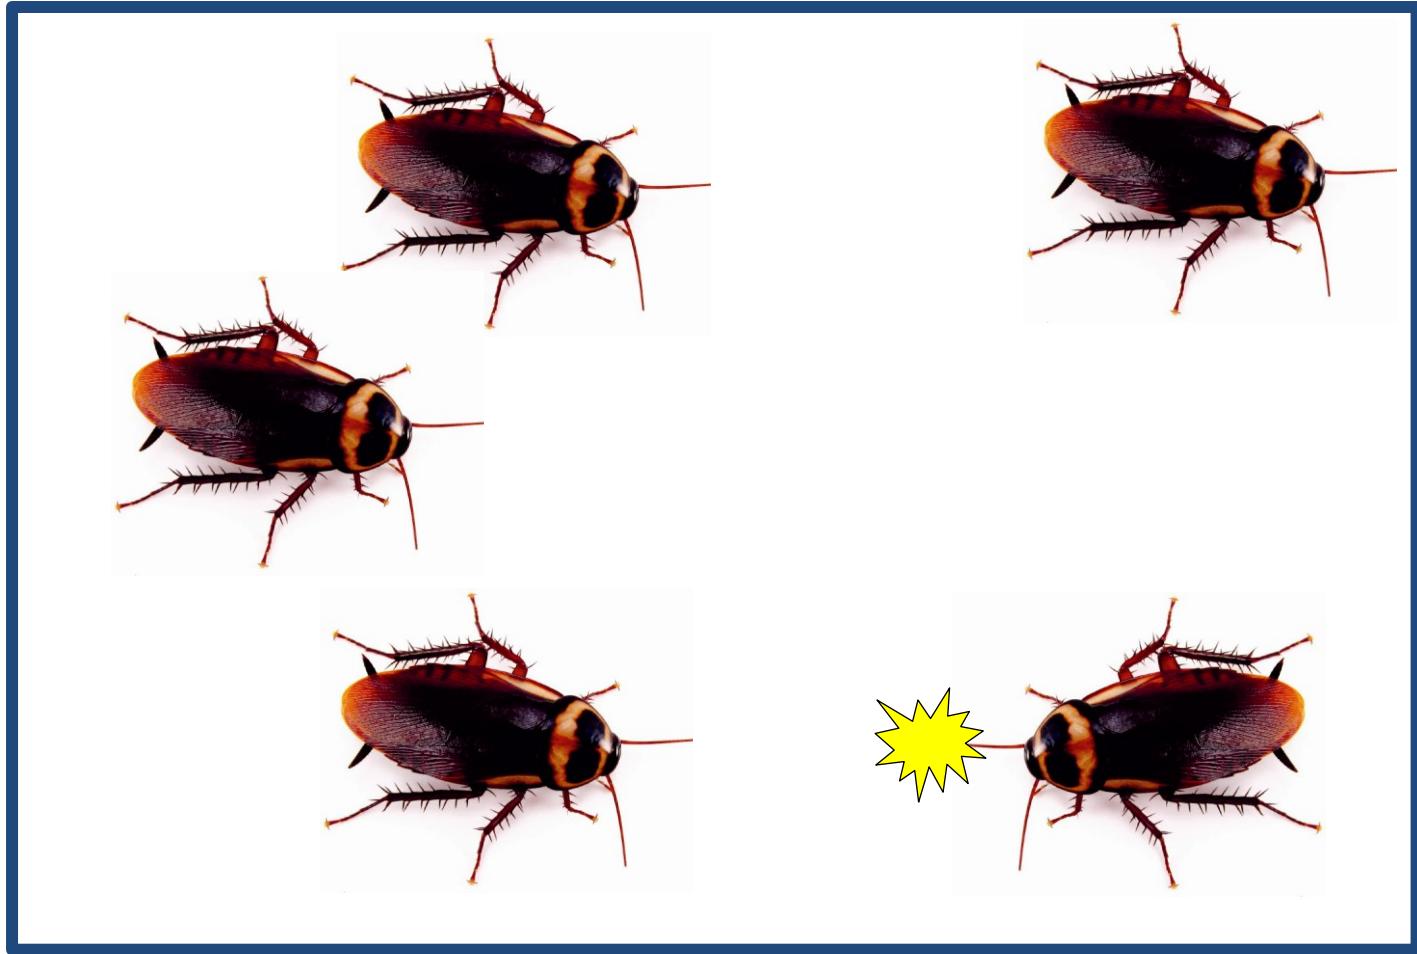
$N = 20$ kopií
v populaci

většinou
 $n \ll N$





Pravděpodobnost setkání 2 švábů je $n(n - 1)/4N$, kde
 n = počet švábů v krabici, N = velikost krabice



při koalescenci se počet švábů (kopií) sníží o 1 ...



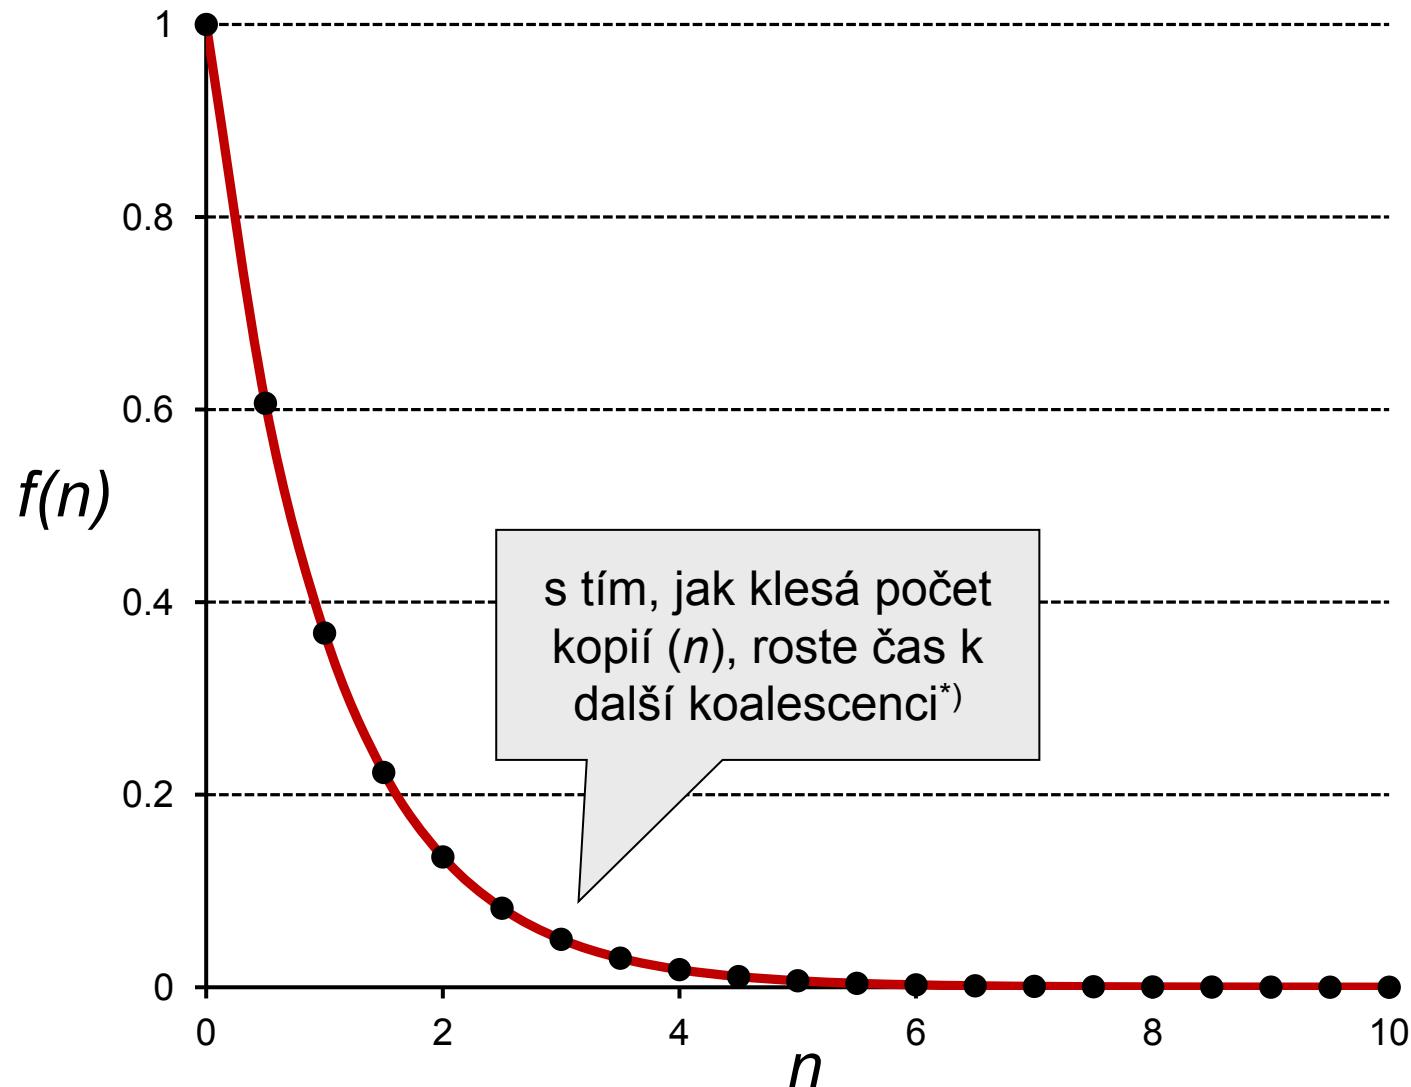
s tím, jak klesá počet
švábů (n), roste čas k
dalšímu kontaktu
(koalescenci)

při koalescenci se počet švábů (kopií) sníží o 1 ...



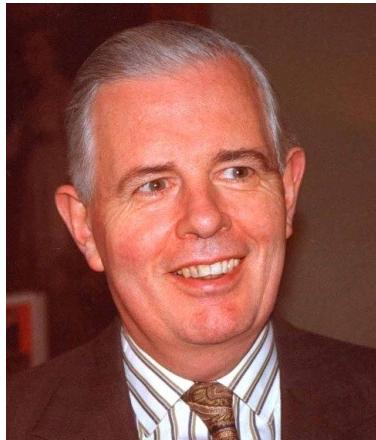
... až nakonec zůstane jen 1 šváb (kopie) = MRCA

rozdělení času mezi koalescencemi je přibližně exponenciální:

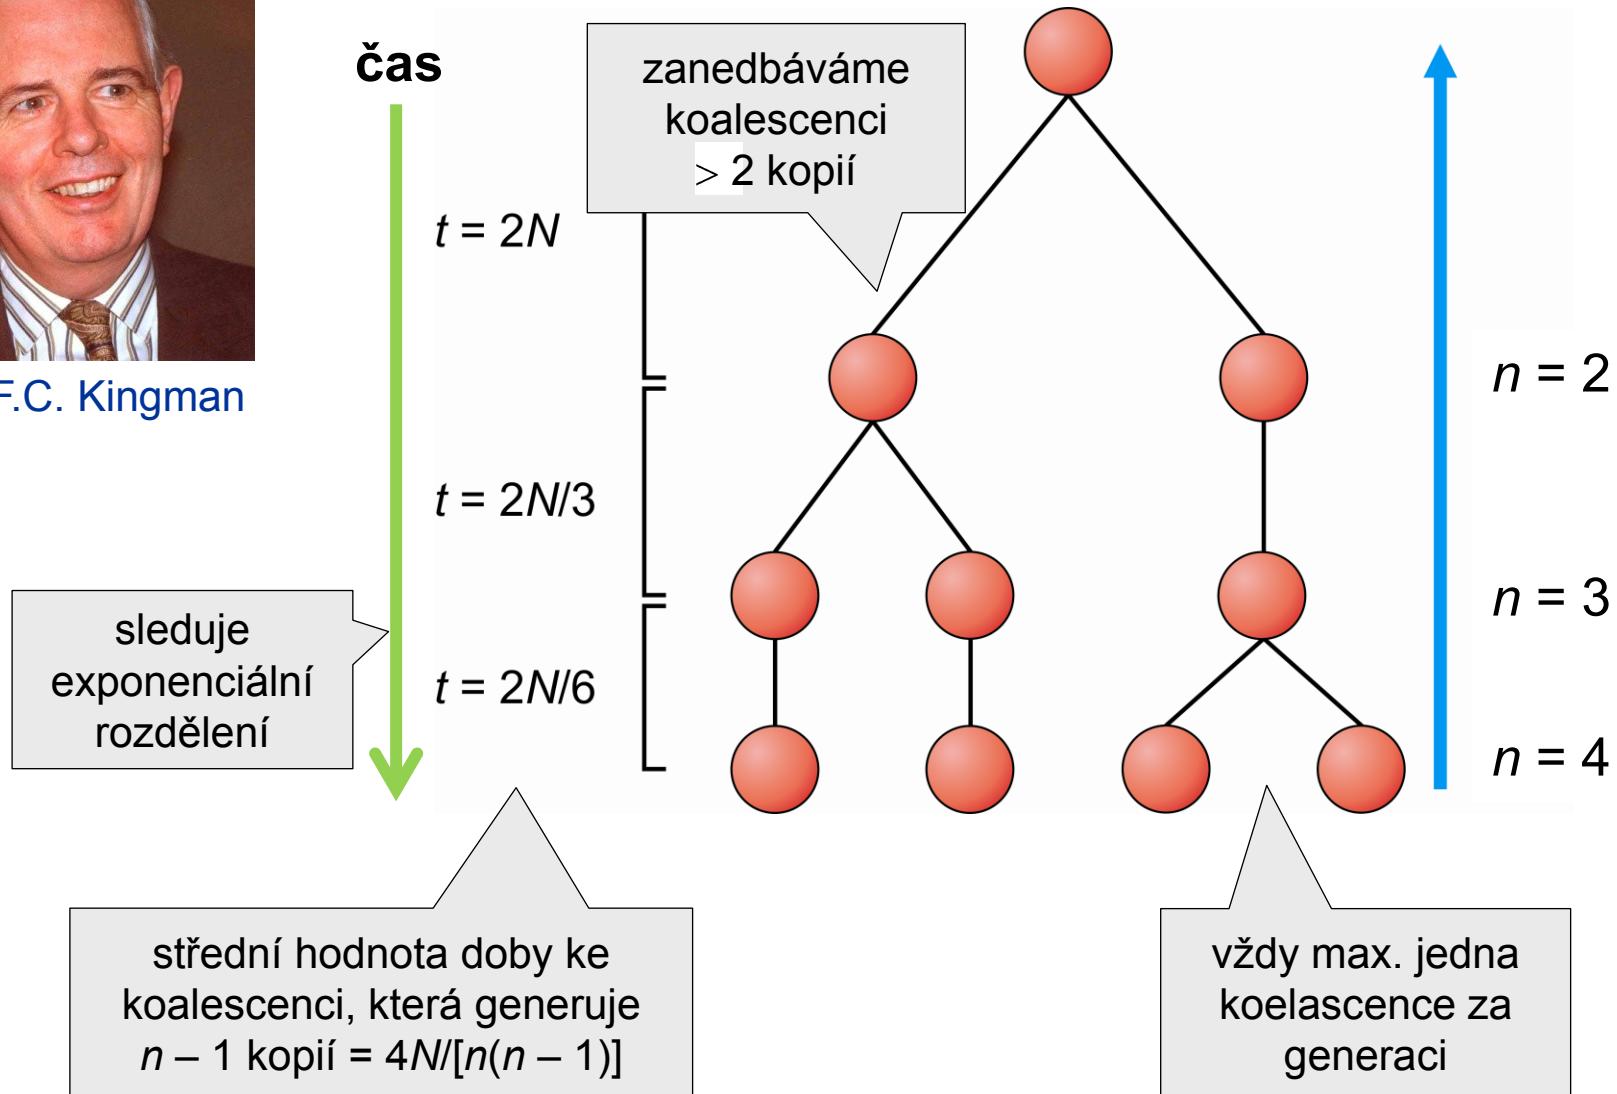


^{*)} viz počet švábů v krabici

Kingmanova koalescence:



John F.C. Kingman



pravděpodobnost, že dvě kopie splynou v následující generaci =

= identita původem = $1/(2N_{eF}) = 1/(2N)^*$

obecně $1/(xN)$, kde x = ploidie

pravděpodobnost, že v té době nedojde ke koalescenci = $1 - [1/(2N)]$

\Rightarrow pravděpodobnost koalescence před t generacemi =

$Pr_{[\text{žádné koalescence pro prvních } (t-1) \text{ generací}]} \times Pr_{[\text{koalescence v gen. } t]}$

pro diploidní ge

$$Pr = \left(1 - \frac{1}{2N}\right)^{t-1} \left(\frac{1}{2N}\right)$$

průměrná doba ke koalescenci 2 kopií =

$$= \sum_{t=1}^{\infty} t \left(1 - \frac{1}{2N}\right)^{t-1} \left(\frac{1}{2N}\right) = 2N$$

*) v ideální populaci, diploidní lokus

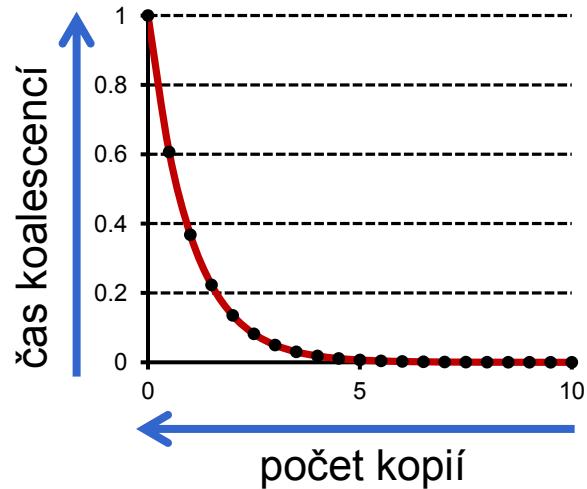
čas od jedné koalescence ke druhé se řídí geometrickým rozdělením,
které se dá approximovat exponenciálním

⇒ střední hodnota času do příští koalescence:

$$E[T(2)] = \frac{2N}{\binom{n}{2}} = \frac{2N}{\frac{n(n-1)}{2}} = \frac{4N}{n(n-1)}$$

$$\binom{n}{2} = \frac{n!}{(n-2)!2!} = \frac{n(n-1)}{2}$$

s každou koalescencí se počet kopií sníží o 1, tj.



$$E[T(n)] = \frac{4N}{n(n-1)} + \frac{4N}{(n-1)(n-2)} + \frac{4N}{(n-2)(n-3)} + \dots + \frac{4N}{2}$$

⇒ proces koalescence se postupně zpomaluje

doba koalescence MRCA všech n kopií = $4N \left(1 - \frac{1}{n}\right)$

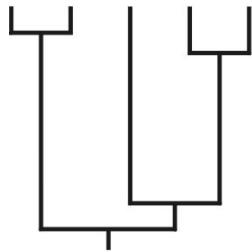
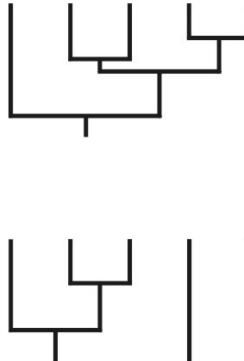
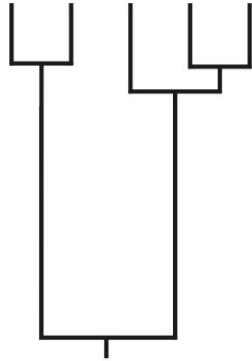
pro $n = 2 \rightarrow t = 2N$
pro velká $n \rightarrow t \approx 4N$

splynutí posledních k kopií zabere

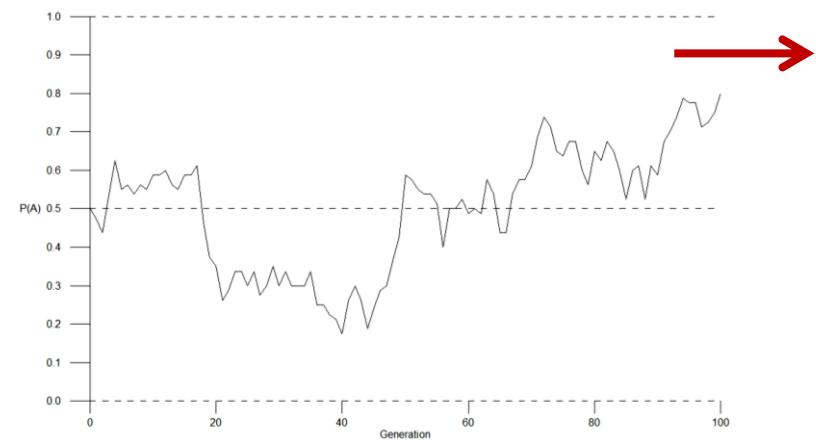
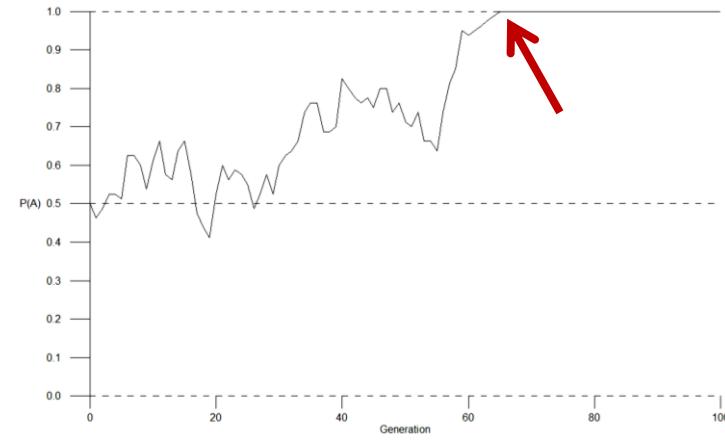
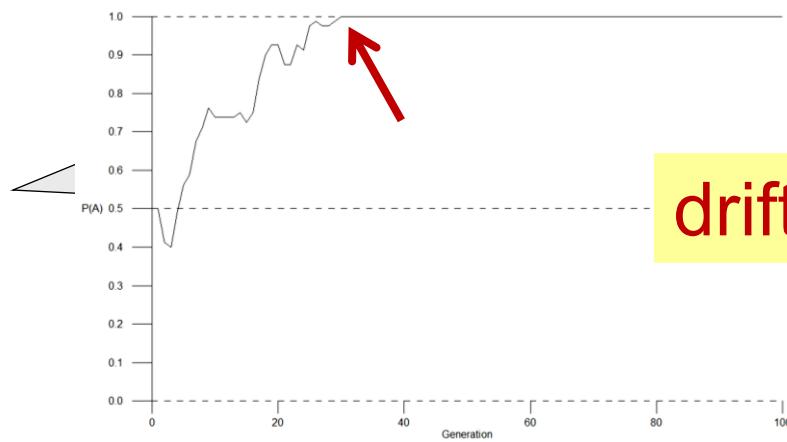
$$\left(1 - \frac{1}{k}\right) \left(1 - \frac{1}{n}\right) \text{ generací}$$

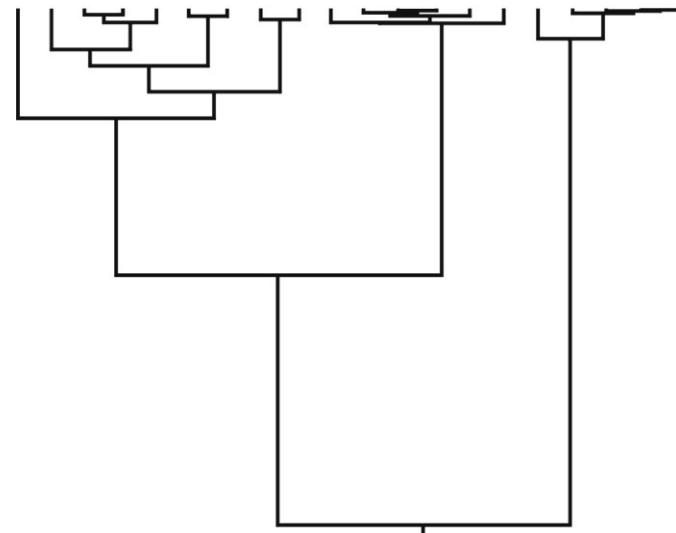
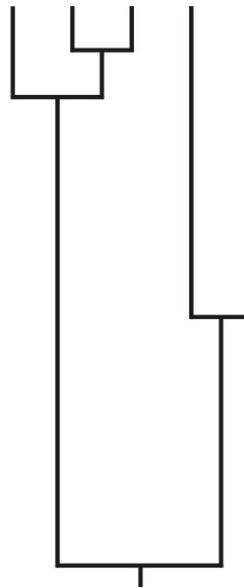
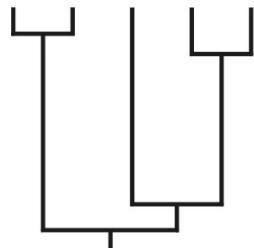
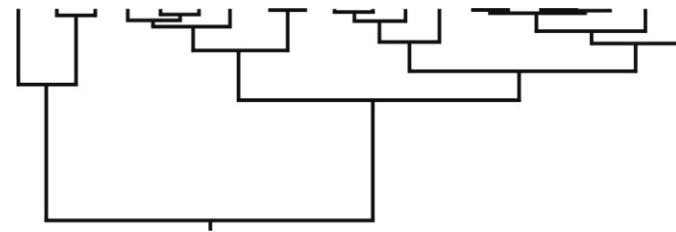
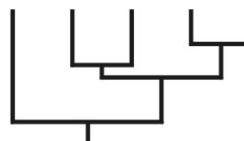
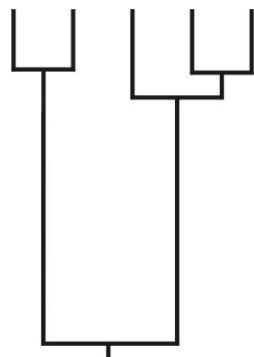
⇒ prvních 90 % kopií splyne během 9 % celkového času,
zbývajících 91 % času se čeká na splynutí posledních
10 % kopií!

jestliže máme 100 kopií ve vzorku, pravděpodobnost,
že přidáním 101. kopie dospějeme k hlubšímu kořenu,
je pouze 0,02% ⇒ přidání další genové kopie
pravděpodobně nepovede ke starší koalescenci



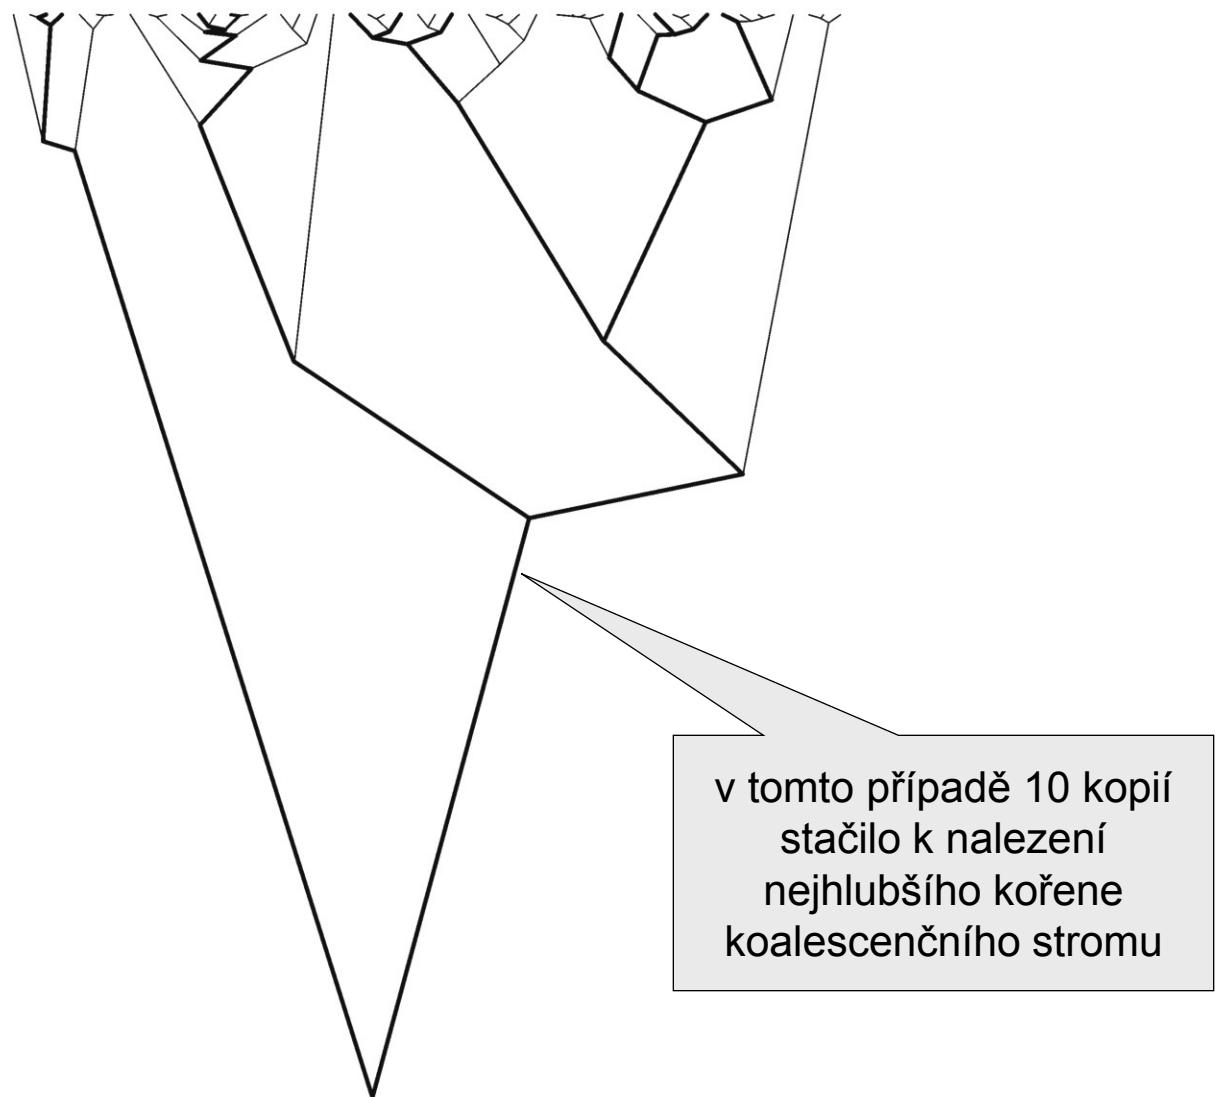
s klesajícím počtem
volných kopií se proces
zpomaluje ...





přidání dalších sekvencí
pravděpodobně nepovede
k hlubší koalescenci ...

50 genových kopií, 10 náhodně vybraných:



Pokud nás zajímají „staré“ koalescence, nepotřebujeme velké vzorky

např. pouhé 2 kopie poskytují v průměru 50 % koalescenčního času pro celou populaci!

Naopak pokud nás zajímá čas do první koalescence z n na $n - 1$, odhad $N/[n/(n - 1)]$ je citlivý vůči n

např. rozptyl průměrné doby první a poslední koalescence pro 10 genů je $0,0444N$ až $3,60N$; zvýšením n na 100 genů, rozmezí bude $0,0004N - 3,96N$

zvýšením n 10× se
rozdíl zvýší 100× ...

... pro poslední
koalescenci prakticky
žádný rozdíl

Z toho plyne, že pro odhady starých evolučních genových událostí stačí malé vzorky, pro odhady recentních událostí jsou velké vzorky nezbytné

Koalescence pro různé typy ploidie:

střední hodnota času koalescence (viz výše) pro velká $n = 2xN_e$
(pro 2 kopie = $2N_e$)

autozomální lokus: $4N_e$

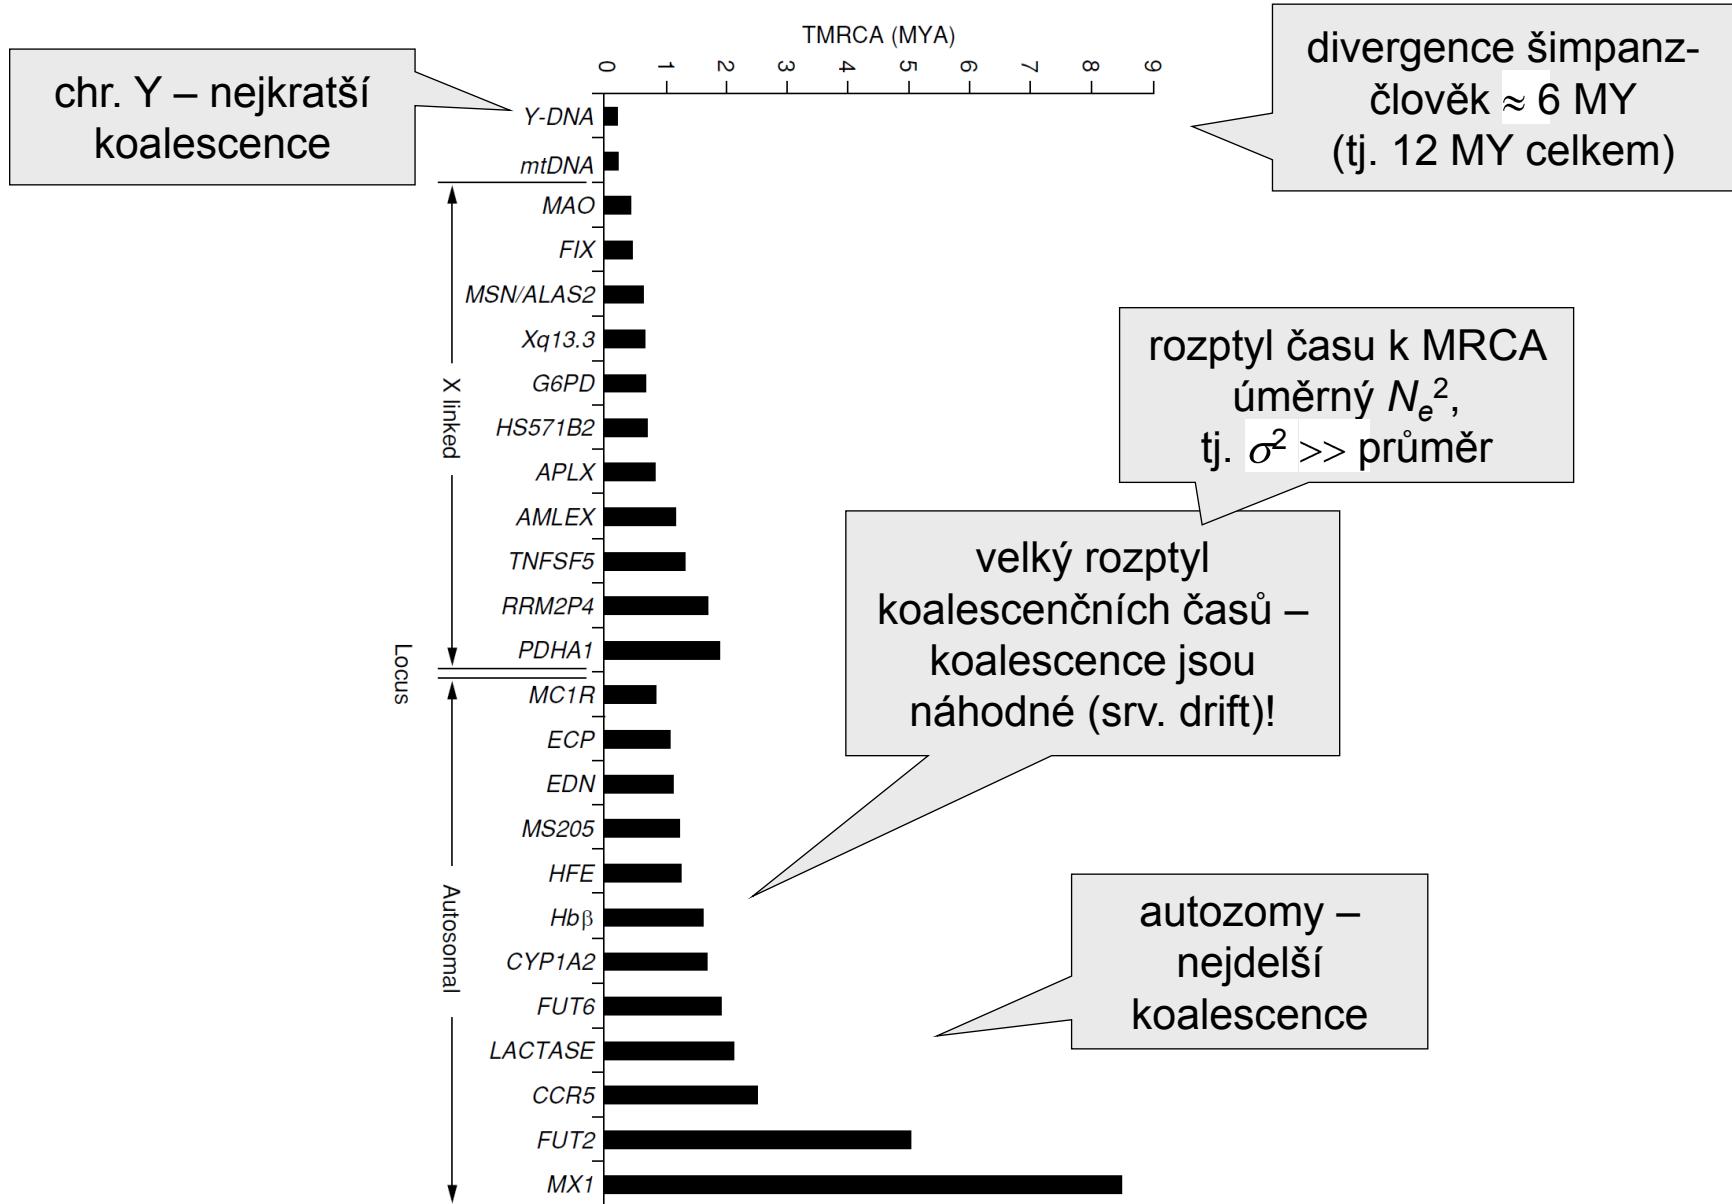
chr. X (při poměru pohlaví 1:1 → $x = 1,5$): $3N_e$

mtDNA, chr. Y (při poměru pohlaví 1:1): N_e

ALE: u savců většinou rozptyl reprodukční úspěšnosti samců > samic
⇒ N_e samců < N_e samic

Z toho plyne, že ke koalescenci Y dochází dřív než u mtDNA
a mnohem dřív než u ostatních lokusů (srv. mitochondriální
Eva × Y-Adam)

Př.: časy koalescence pro 12 autozomálních genů, 11 genů na X, mtDNA a Y u člověka (Templeton 2005):



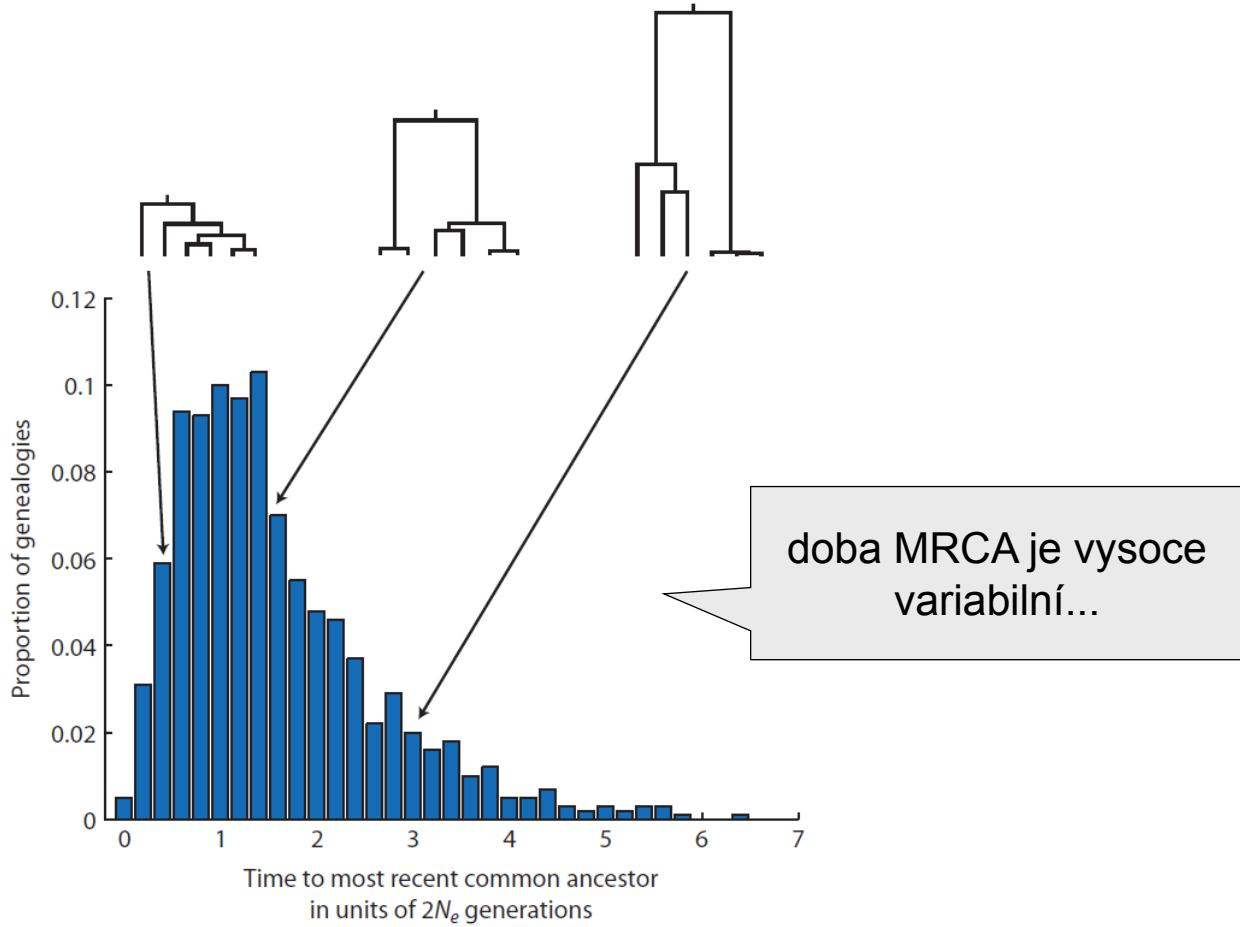
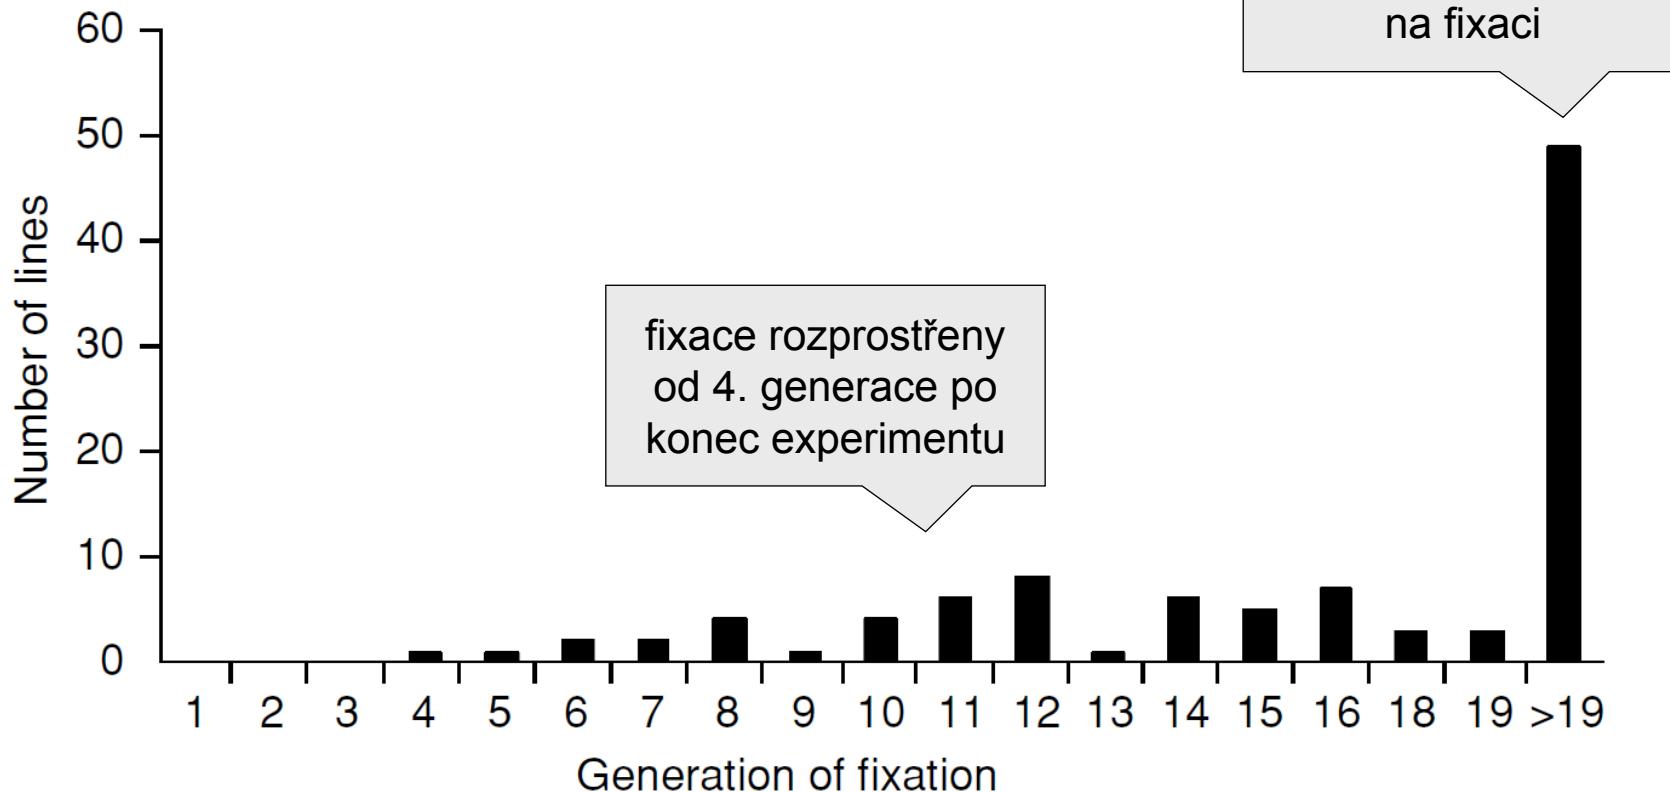


Figure 3.27 The distribution of times to a MRCA (or genealogy heights) for 1000 replicate genealogies starting with six lineages ($k = 6$). The distribution of total coalescence times has a large variance because the range of times is large and also asymmetric with a long tail of a few genealogies that take a very long time to reach the MRCA. The genealogies shown above the distribution are those for the tenth, fiftieth, and ninetieth percentile times to MRCA. In this example $N_e = 1000$.

Ještě jednou Buriho experiment (Buri 1956):



Přes identické podmínky velký rozptyl fixací; v přírodě jen 1 „experiment“
→ musíme očekávat velkou „chybu“ v odhadech koalescencí, která
nezávisí na velikosti vzorku ani na dalších typech chyb!

Čas a koalescence:

V základní podobě je čas koalescencí měřen v jednotkách N generací pokud existují rozdíly mezi příslušníky populace z hlediska jejich reprodukční úspěšnosti (rozptyl $0 < \sigma^2 < \infty$), ale velikost populace je pořád stejná, koalescenční proces je měřen v jednotkách N/σ^2 generací

Vyšší rozptyl reprodukční úspěšnosti vede k rychlejším koalescencím (nižší N_e)

Lineární změnou časové škály můžeme vzít v úvahu např. nediskrétní generace, oddělená pohlaví, odlišné systémy páření atd.

⇒ můžeme využít i na reálné organismy

Při aplikaci na reálné organismy ale potřebujeme nezávislé odhady N_e , σ^2 (popř. dalších parametrů)

Tyto odhady nejsou vždy k dispozici, navíc jsou zdrojem další chyby (např. divergence sekvencí, datování fosilního záznamu, odhad generační doby atd.).

Navíc odhady koalescenčních časů často ignorují evoluční nahodilost fixačního/koalescenčního procesu (viz výše) – použité metody vycházející z NT jsou založeny na mezidruhové divergenci, tzn. považují fixaci alel za náhlý proces, který tím pádem nepřispívá do celkového rozptylu odhadu.

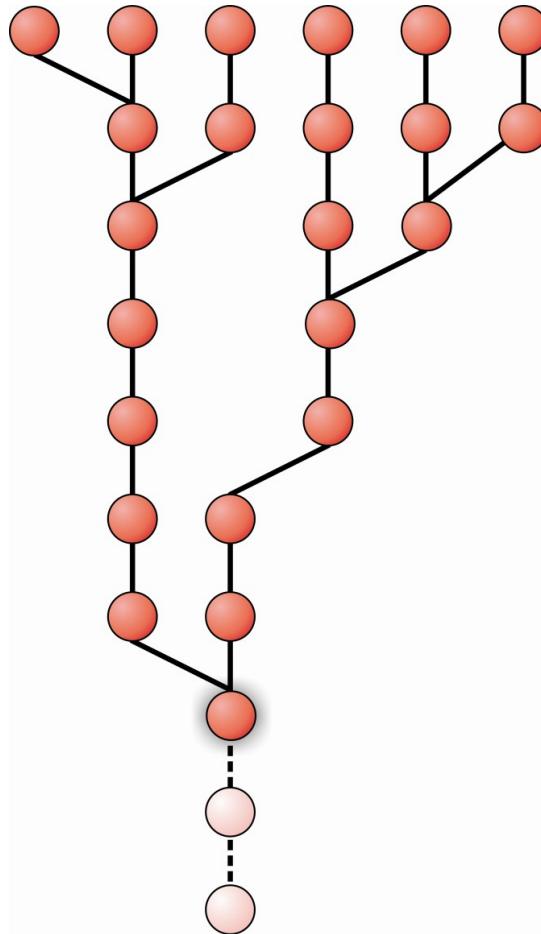
Např. odhad koalescence mtDNA člověka $\approx 290\ 000$ let \rightarrow vzhledem k rozptylu spojenému s molekulárními hodinami a koalescenčním procesem^{*)} 95% CI = 152 000 – 473 000 let (tj. $> 300\ 000$ let!)^{**)}

^{*)} ignorujeme výběrovou chybu (*sampling error*), chybu měření (*measurement error*) a ne zcela přesně známou mutační rychlosť $\mu \Rightarrow$ ve skutečnosti by byl konfidenční interval mnohem větší

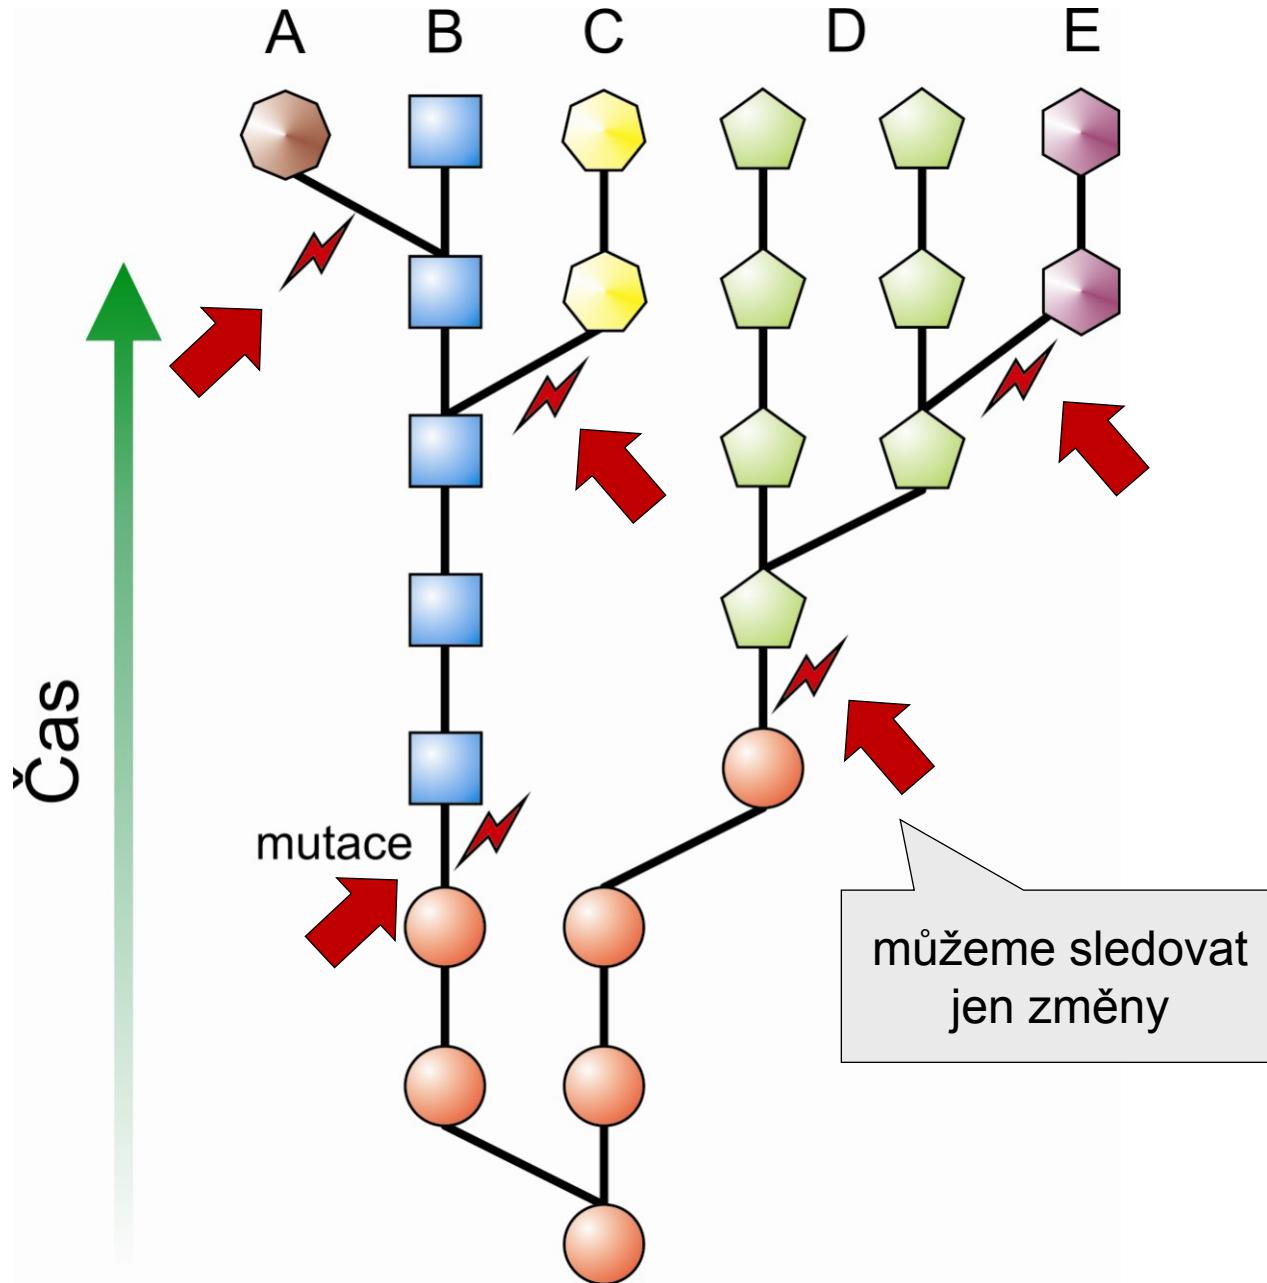
^{**) rozptyl v časech fixací/koalescencí způsobený driftem nelze odstranit jednoduše zvýšením velikosti vzorku (n), protože populace představují pouze jednu realizaci evolučního procesu (můžeme ale použít více lokusů)}

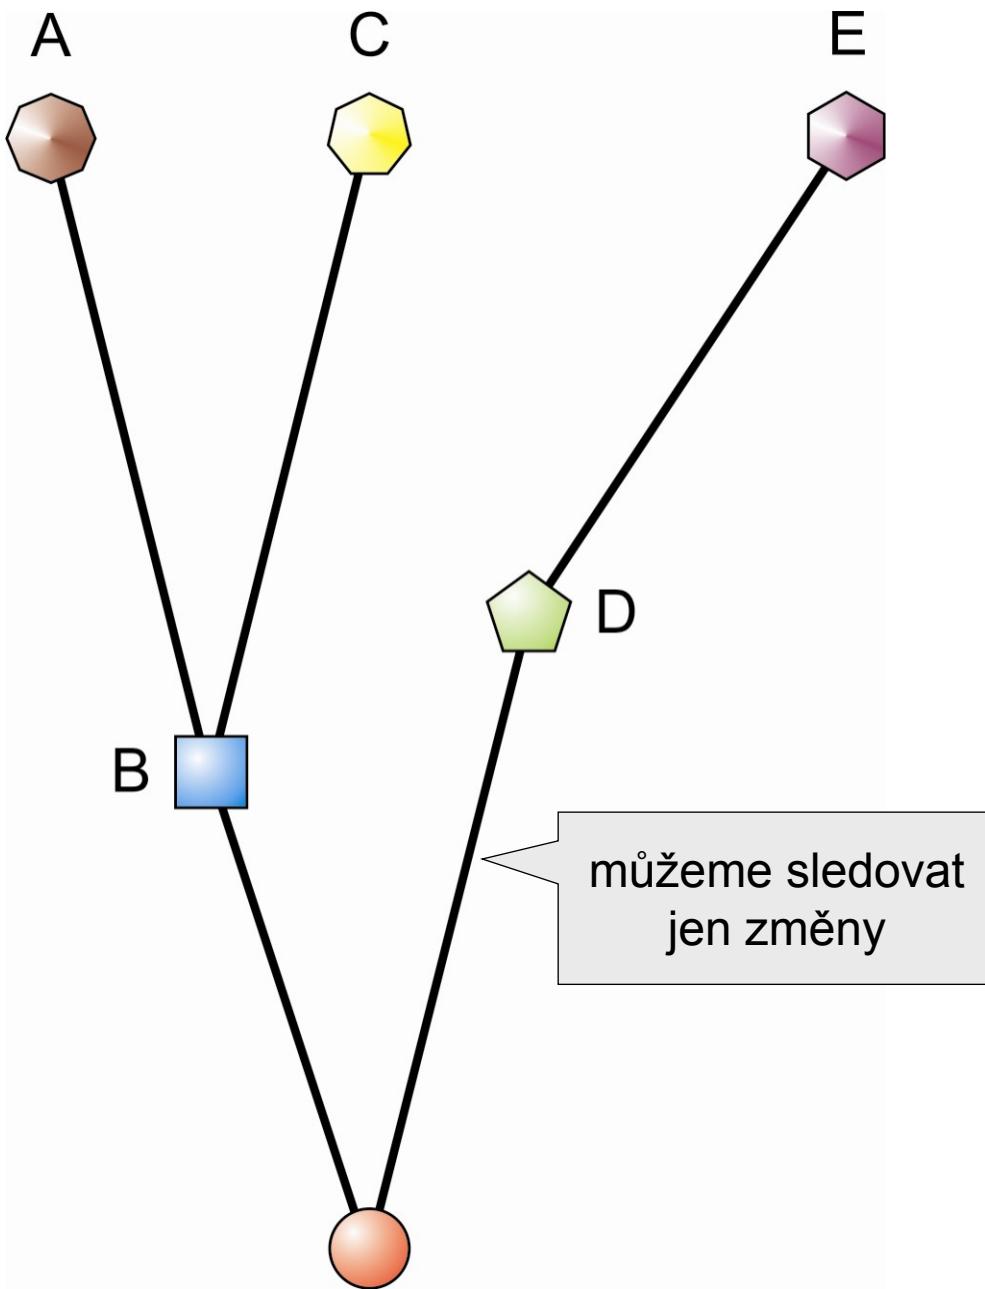
Při datování evolučních událostí pomocí vnitrodruhové molekulární variability bychom si měli být těchto skutečností vědomi!

Dosud jsme uvažovali koalescence stejných alel ...



... ve skutečnosti můžeme sledovat jen různé alely → mutace!





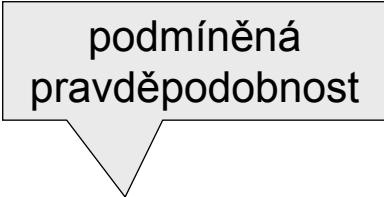
Koalescence a neutrální mutace:

Jestliže μ je velmi malé a N_e velmi velké, můžeme výskyt obou jevů během jedné generace zanedbat.

Pokud jdeme zpět v čase, dokud 2 kopie bud' nesplynou, nebo jedna z nich nezmutuje, pak pravděpodobnost, že k mutaci došlo dřív než ke koalescenci, je

$$\Pr_{[\text{mutace před koal.} | \text{mutace, nebo koal.}]} \approx \frac{\theta}{\theta + 1}$$

podmíněná
pravděpodobnost



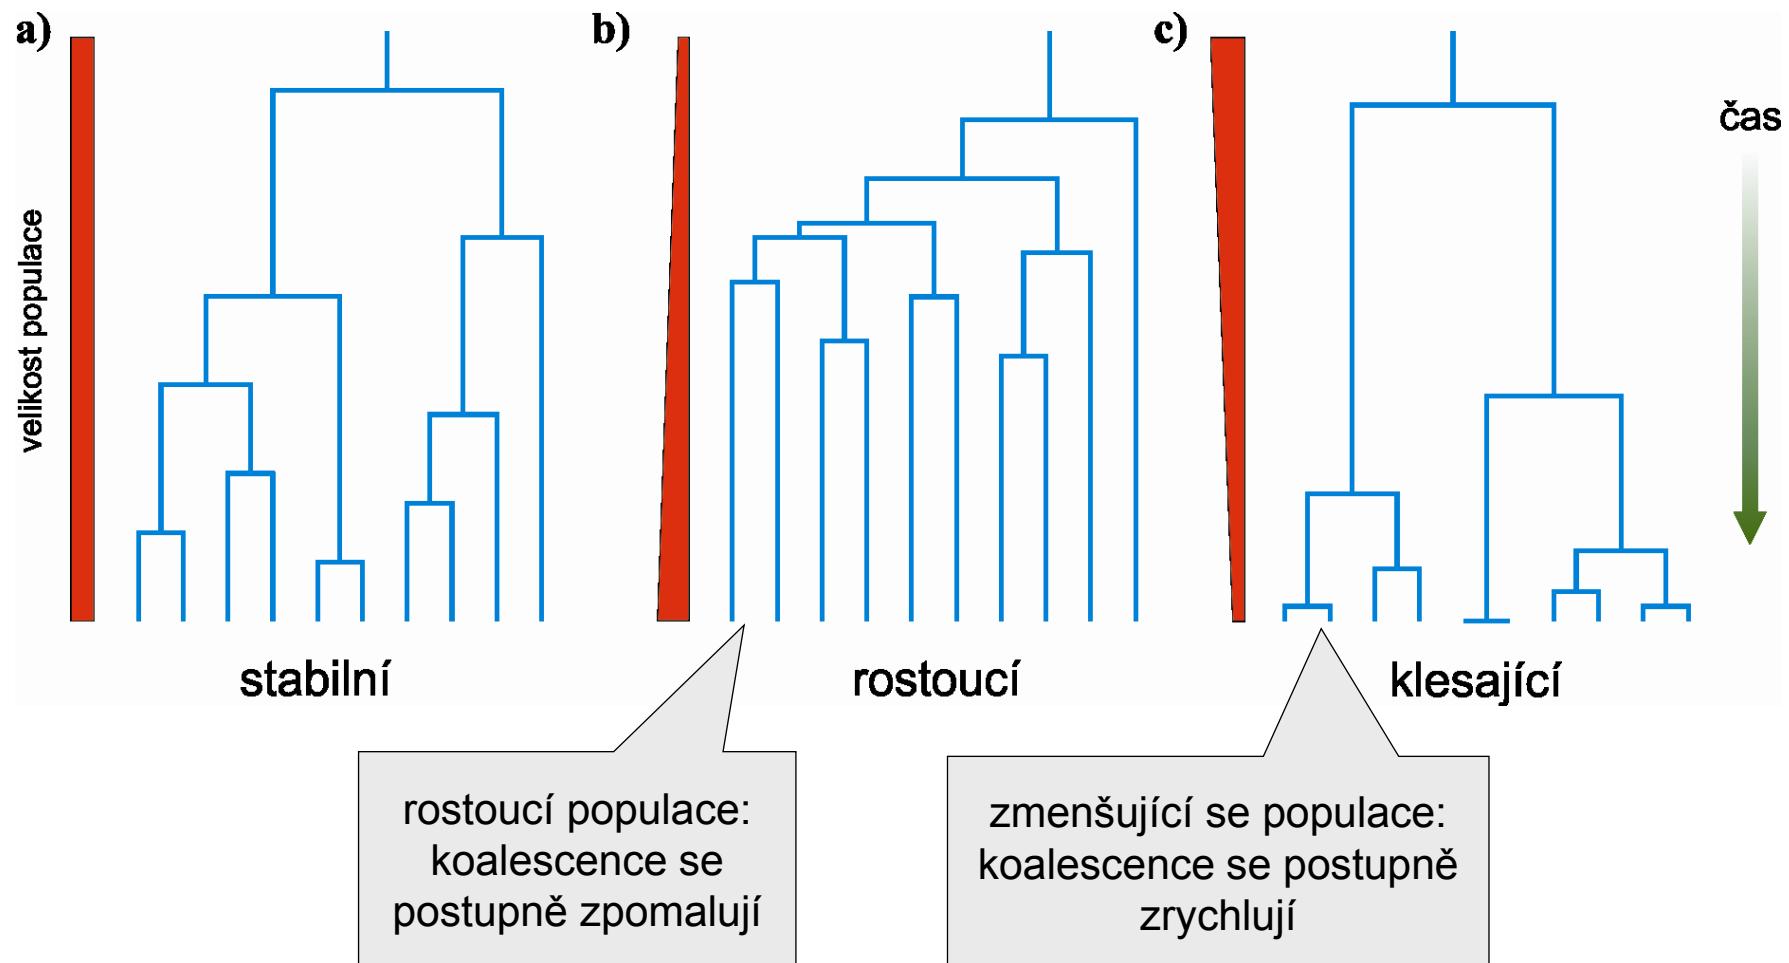
kde $\theta = 4N_e\mu$

$$\frac{\theta}{\theta + 1}$$

≈ očekávaná heterozygotnost při náhodném oplození –
jestliže dojde k mutaci před koalescencí, pak obě kopie
musí reprezentovat odlišné alely (*infinite-alleles model*)

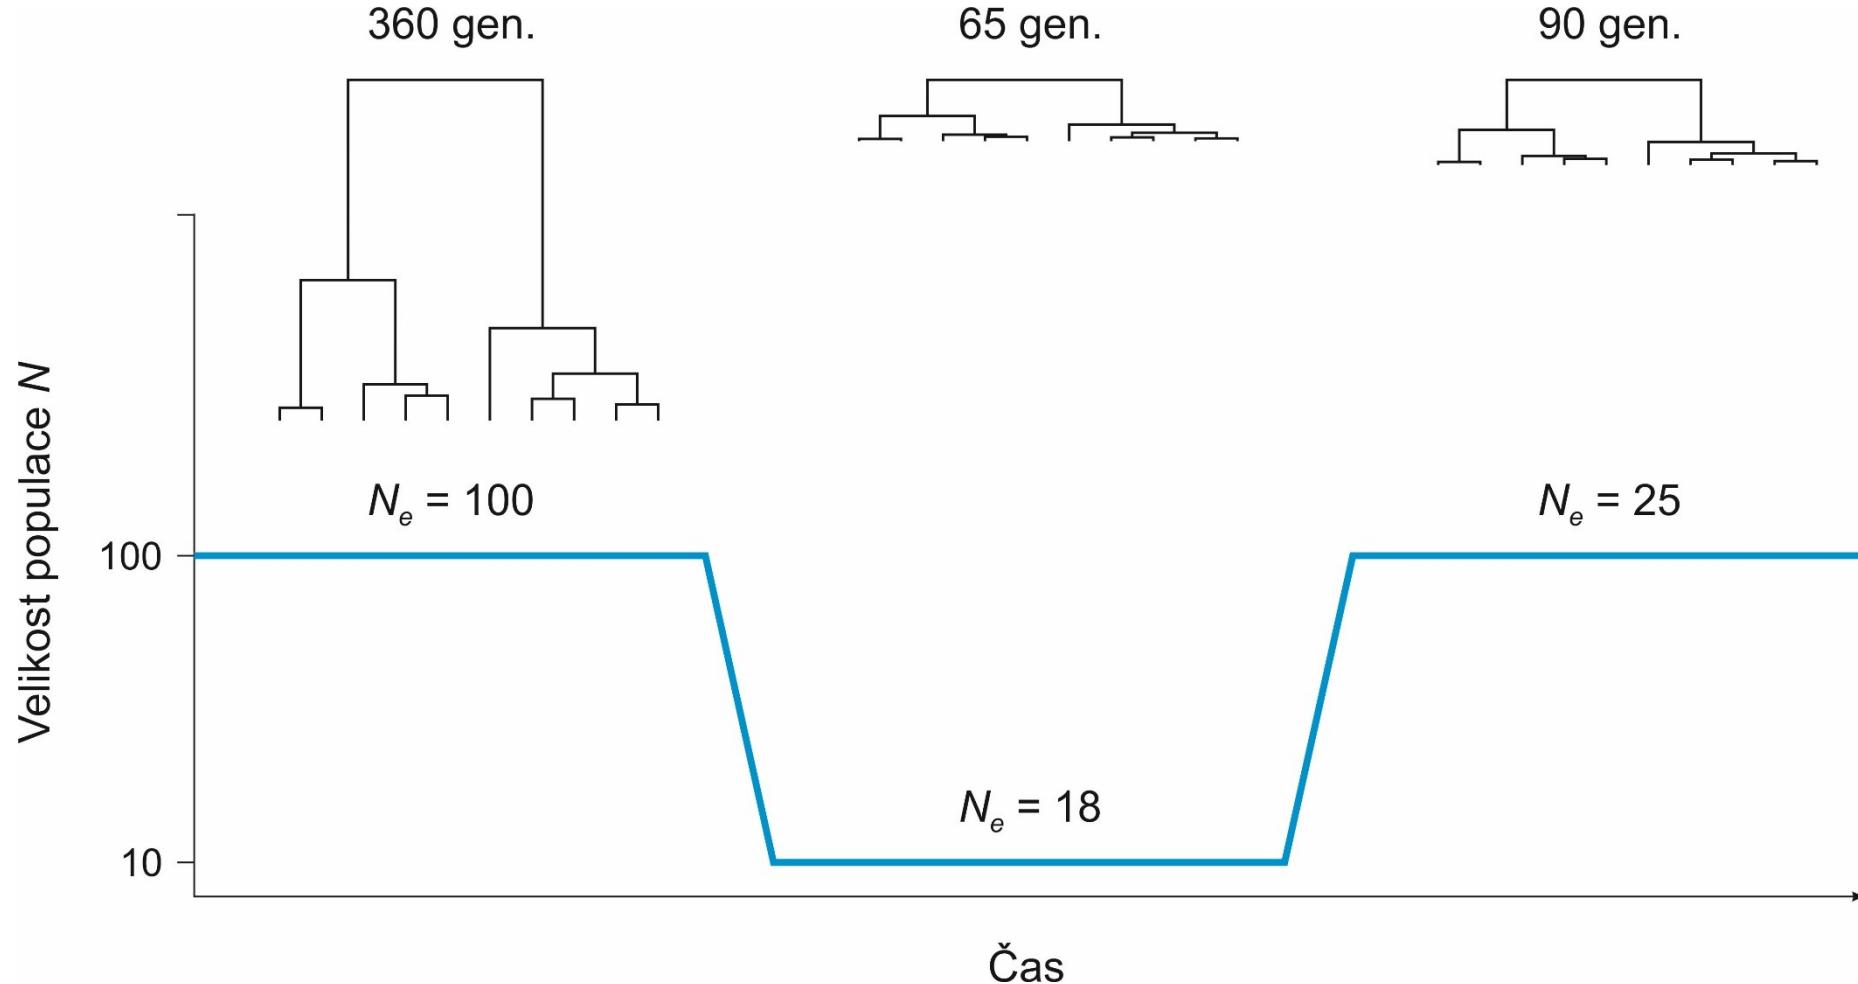
⇒ Při pohybu v čase dopředu i zpět je dopad rovnováhy driftu a mutace na genetickou variabilitu stejný.

Vliv změn velikosti populace na tvar koalescenčního stromu:

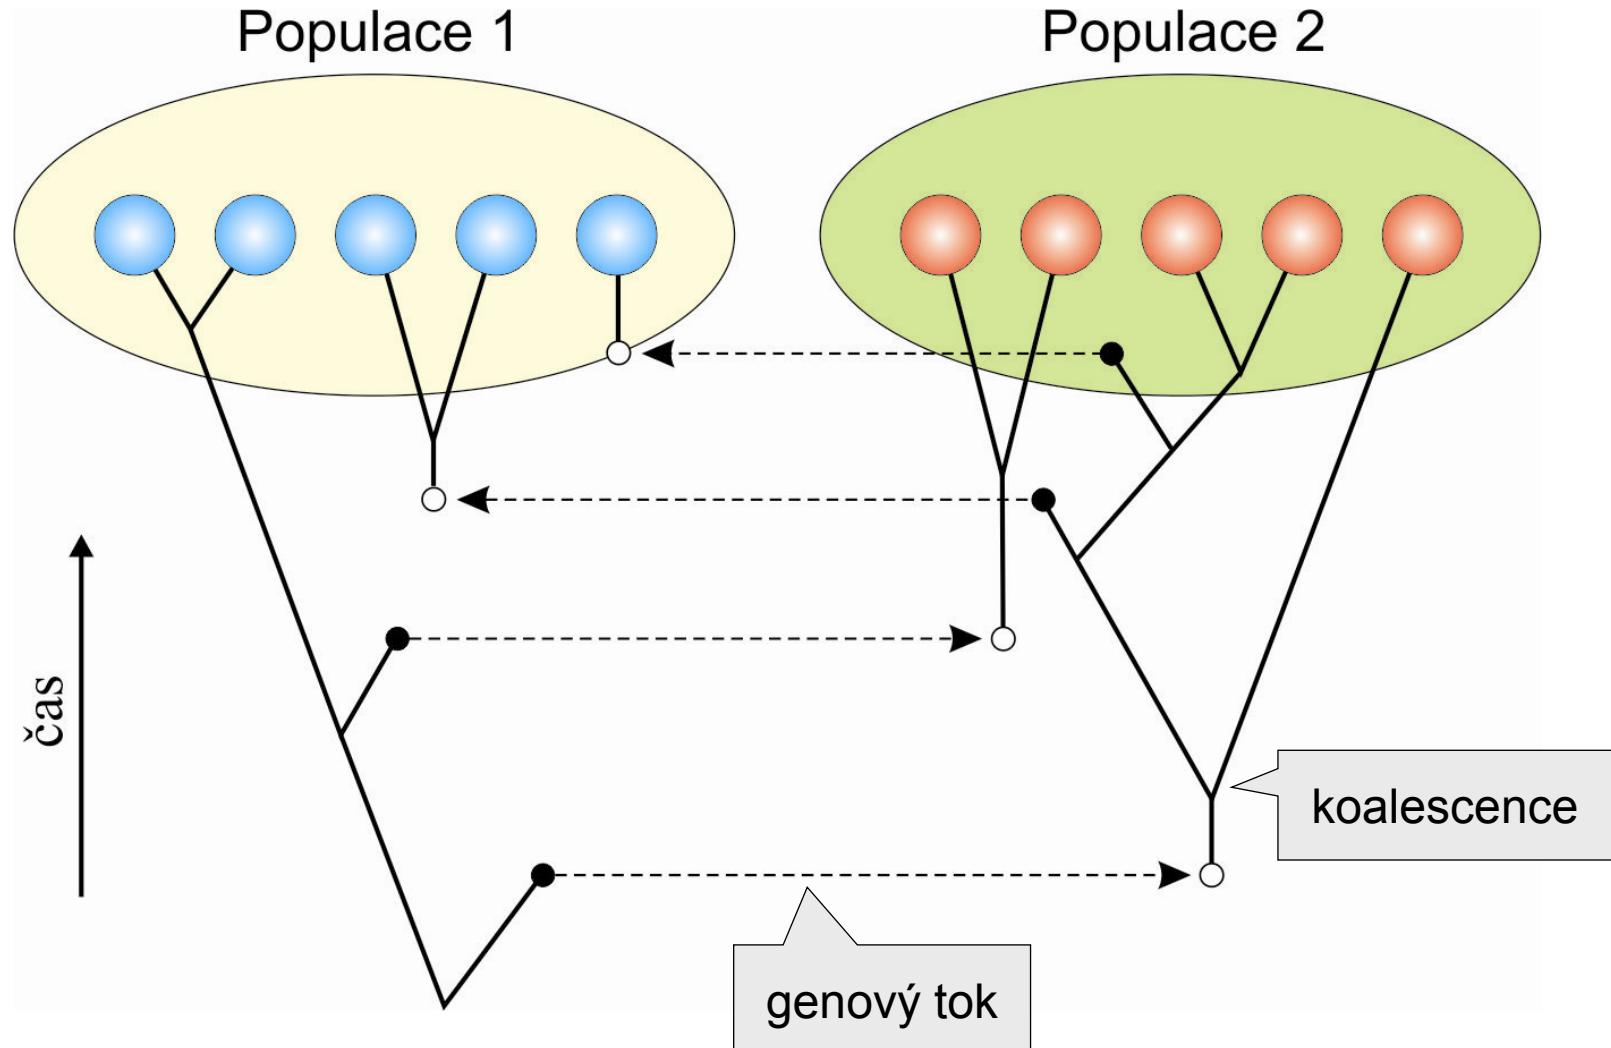


Vliv bottlenecku na koalescenci:

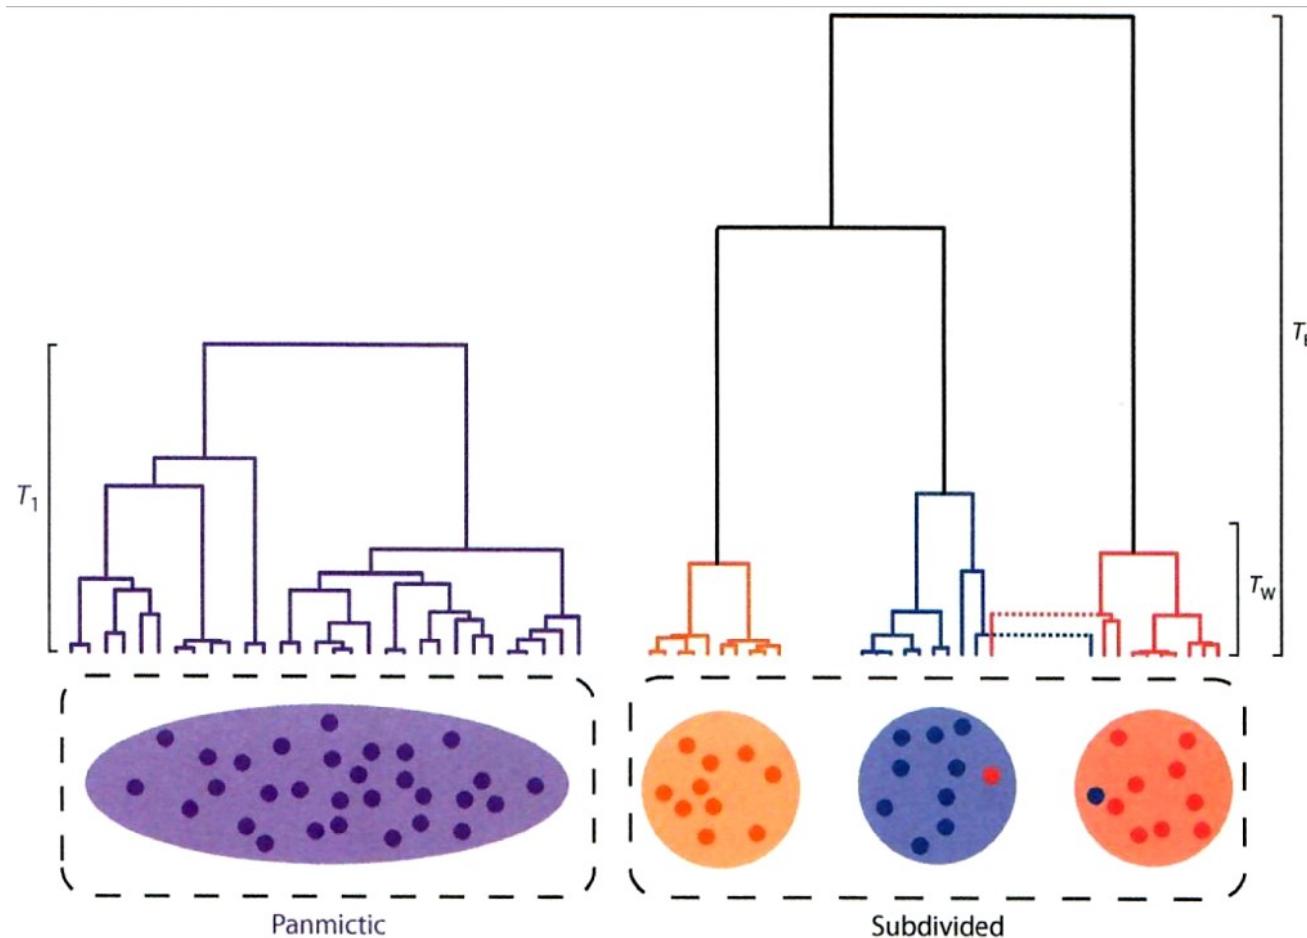
$n = 10$



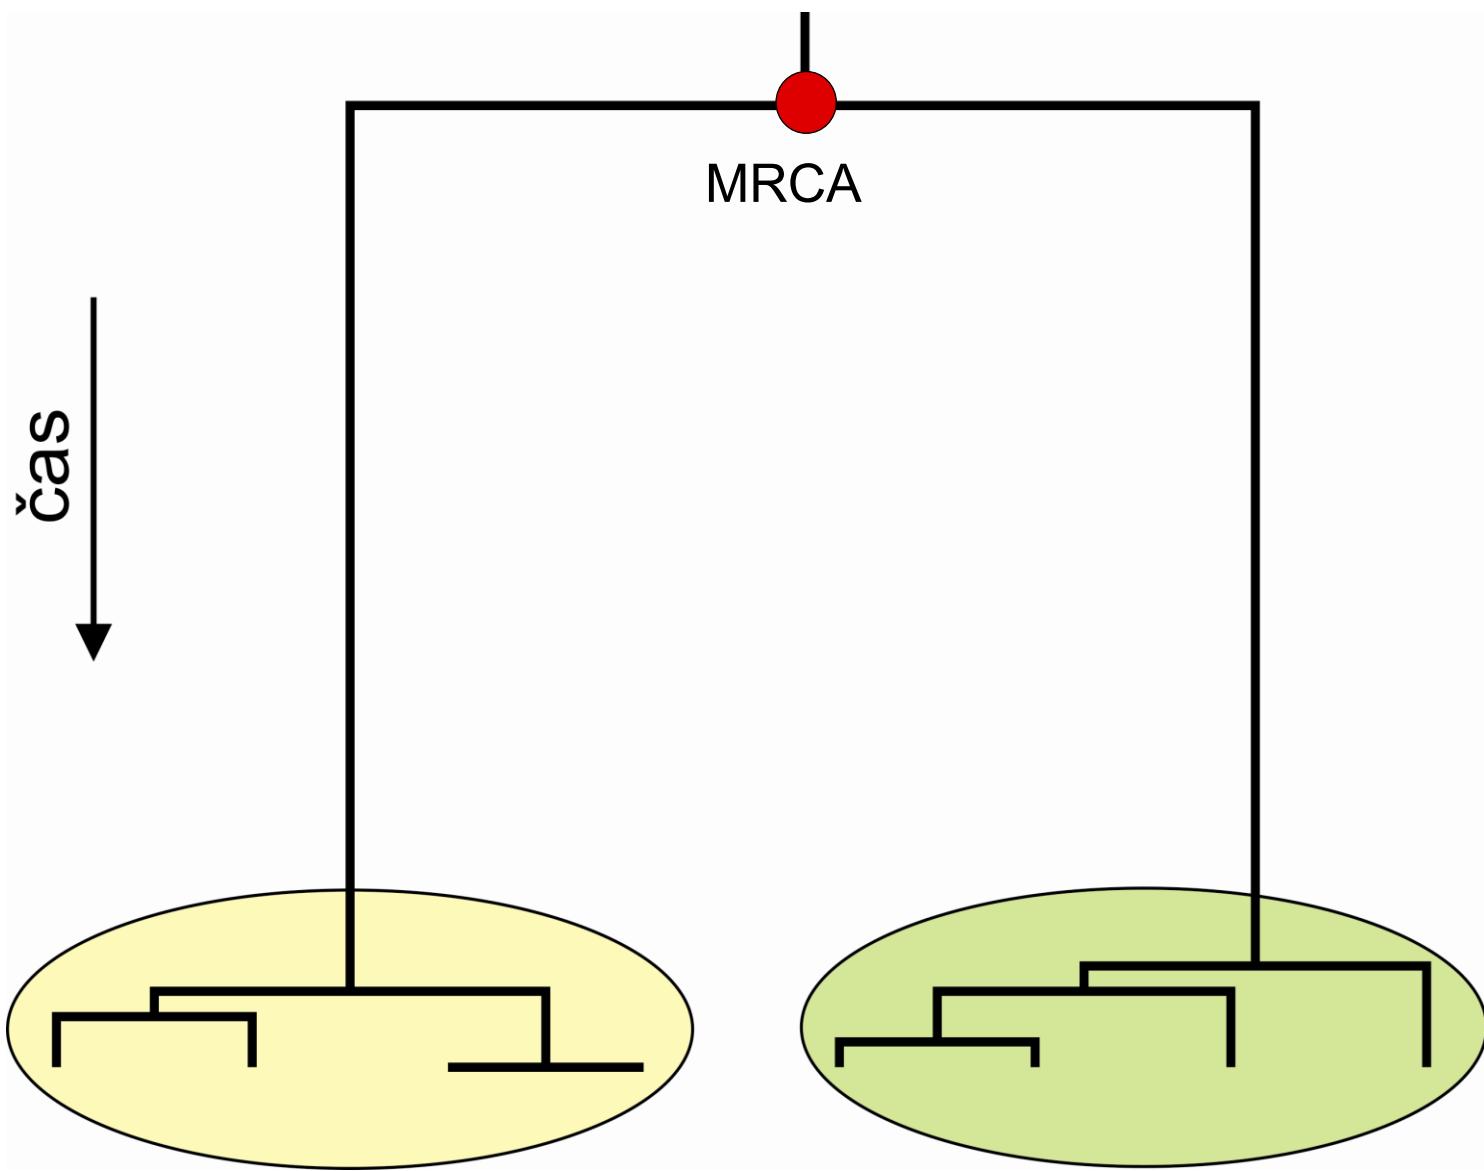
Koalescence a tok genů:



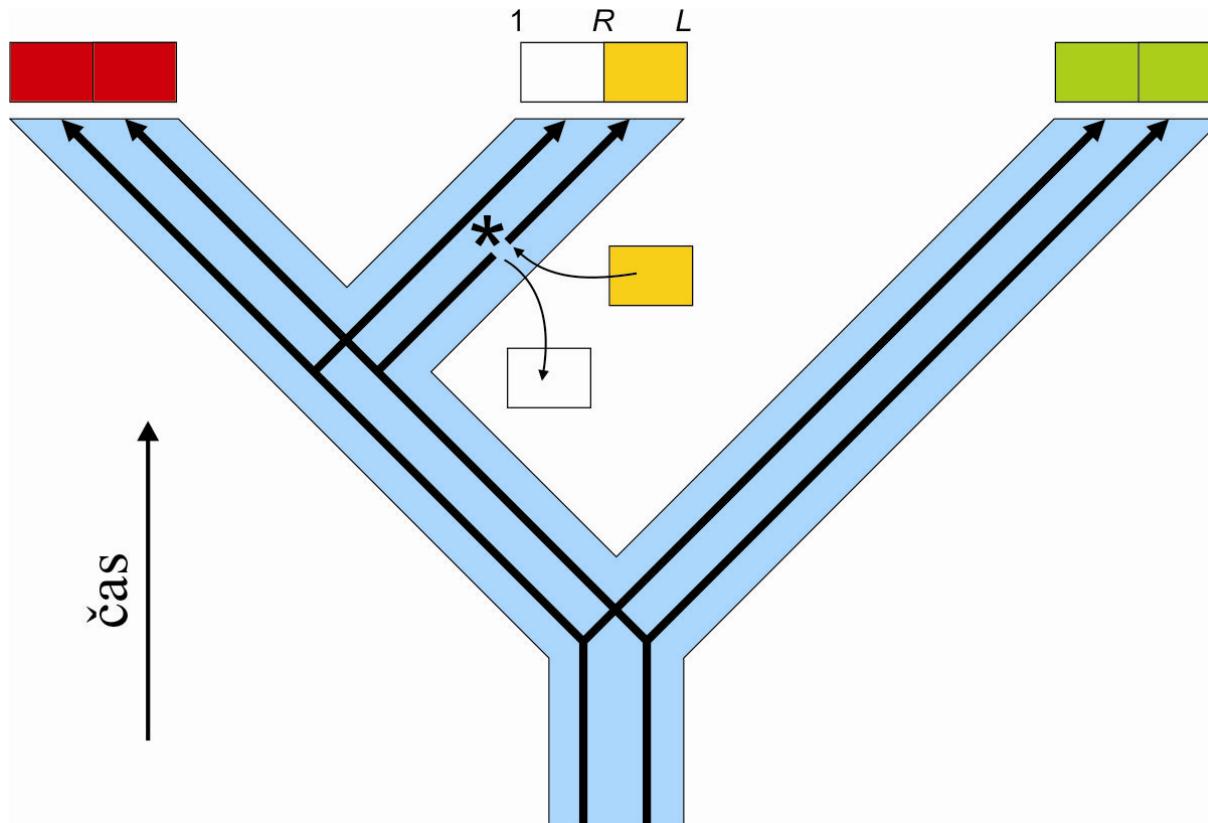
Slabá migrace vede k většině koalescencí uvnitř lokálních populací,....



.... zároveň ale k prodloužení času k MRCA a zvýšení jeho rozptylu.

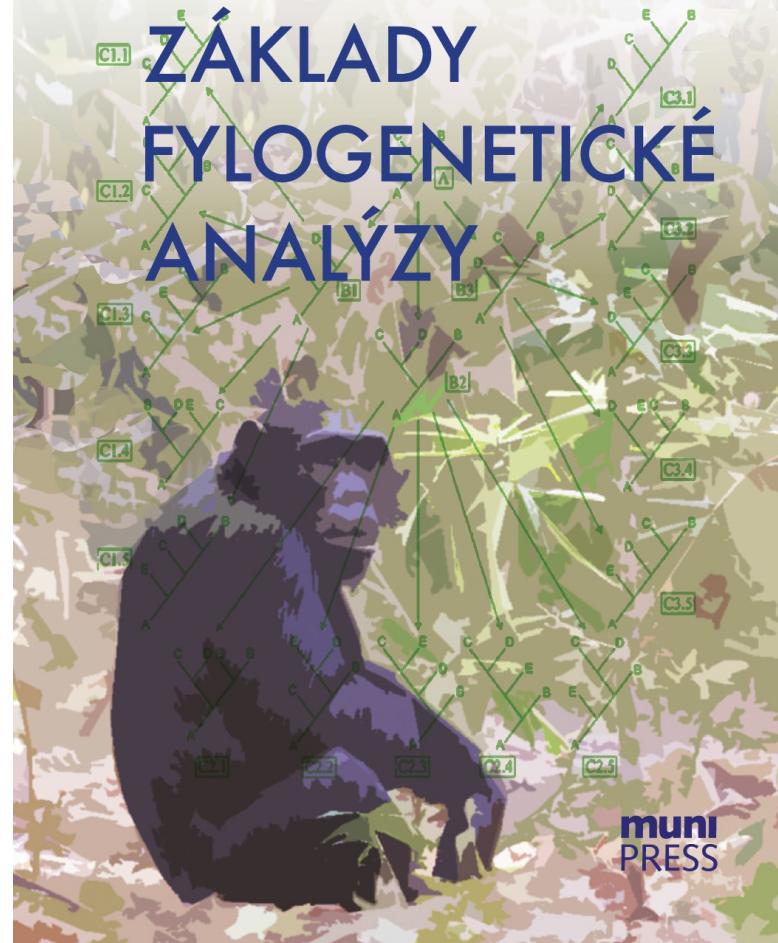


Koalescence a rekombinace:



více podrobností viz

Miloš Macholán



vliv selekce na koalescenci viz Selekce