

# Génétique des populations et évolution moléculaire

Groupe de travail, 23 mars 2005

Laboratoire de Biodiversité-Hydrobiologie

## I - Introduction : la loi de Hardy-Weinberg

BUT : étude de l'évolution du patrimoine génétique d'une population

On considère un gène avec 2 allèles  $A_1$  et  $A_2$

↪ fréquence des génotypes  $A_1A_1$  ( $p_1$ ),  $A_1A_2$  ( $2q$ ) et  $A_2A_2$  ( $p_2$ )

Fréquence des génotypes aux générations suivantes ?

génération 1 :

$$A_1A_1 \left( (p_1 + q)^2 \right)$$

$$A_1A_2 \left( 2(p_1 + q)(q + p_2) \right)$$

$$A_2A_2 \left( (q + p_2)^2 \right)$$

génération 2 :

$$A_1A_1 \left( (p_1 + q)^2 \right)$$

$$A_1A_2 \left( 2(p_1 + q)(q + p_2) \right)$$

$$A_2A_2 \left( (q + p_2)^2 \right)$$

Loi de Hardy-Weinberg

Stabilité de la répartition des génotypes dès la 2<sup>ème</sup> génération

$$\rightsquigarrow \mathbf{A}_1\mathbf{A}_1 \left( \alpha^2 \right), \mathbf{A}_1\mathbf{A}_2 \left( 2\alpha(1 - \alpha) \right) \text{ et } \mathbf{A}_2\mathbf{A}_2 \left( (1 - \alpha)^2 \right)$$

*Remarque* : fortes hypothèses sur la population

- panmixie
- population de grande taille
- population isolée (ni migrations, ni mutations)

## II - Modèle de Wright-Fisher

### 1 - Hypothèses

- On suppose :
- population diploïde de **taille constante**  $N$
  - fécondations au hasard et indépendantes
  - population **isolée** (pas de migrations)
  - **ni mutation, ni sélection**

On note  $X_t$  le nombre d'**allèles  $A_1$**  portés par la **génération  $t$** ,  $t \in \mathbb{N}$ .

$\rightsquigarrow$  génération initiale :  $N$  individus et  $X_0$  allèles  $A_1$

$\rightsquigarrow$  génération  $t$  :  $N$  individus et  $X_t$  allèles  $A_1$

  $X_t$  est une **variable aléatoire** !

On connaît l'ensemble des valeurs possibles pour  $X_t$  ( $0, 1, 2 \dots$  ou  $2N$ ), ainsi que les fréquences respectives.

Mais la valeur prise va dépendre de l'expérience.

## 2 - Loi de $X_t$

BUT : calculer la loi de  $X_{t+1}$  connaissant  $X_t$

↪ Effectif des génotypes à la génération t :

$$\mathbf{A}_1\mathbf{A}_1 (n_1), \mathbf{A}_1\mathbf{A}_2 (2m) \text{ et } \mathbf{A}_2\mathbf{A}_2 (n_2) \implies X_t = 2n_1 + 2m$$

↪ Fréquence des génotypes à la génération t :

$$\mathbf{A}_1\mathbf{A}_1 \left(\frac{n_1}{N}\right), \mathbf{A}_1\mathbf{A}_2 \left(\frac{2m}{N}\right) \text{ et } \mathbf{A}_2\mathbf{A}_2 \left(\frac{n_2}{N}\right)$$

↪ Fréquence des génotypes à la génération suivante ?

Soit  $Z_k$  = nb d'allèles  $\mathbf{A}_1$  du  $k^{\text{ème}}$  individu de la génération  $t + 1$

$$\begin{aligned} \mathbf{A}_1\mathbf{A}_1 : \quad \mathbb{P}(Z_k = 2) &= \left(\frac{n_1}{N} + \frac{m}{N}\right)^2 = \left(\frac{X_t}{2N}\right)^2 \\ \mathbf{A}_1\mathbf{A}_2 : \quad \mathbb{P}(Z_k = 1) &= 2 \left(\frac{n_1}{N} + \frac{m}{N}\right) \left(\frac{m}{N} + \frac{n_2}{N}\right) = 2 \frac{X_t}{2N} \left(1 - \frac{X_t}{2N}\right) \\ \mathbf{A}_2\mathbf{A}_2 : \quad \mathbb{P}(Z_k = 0) &= \left(\frac{m}{N} + \frac{n_2}{N}\right)^2 = \left(1 - \frac{X_t}{2N}\right)^2 \end{aligned}$$

Rappelons que  $X_t$  est connu. On pose  $X_t = i$ .

$$\begin{aligned}\text{Comme } \mathbb{P}(Z_k = 2 | X_t = i) &= \left(\frac{i}{2N}\right)^2 \\ \mathbb{P}(Z_k = 1 | X_t = i) &= 2 \frac{i}{2N} \left(1 - \frac{i}{2N}\right) \\ \mathbb{P}(Z_k = 0 | X_t = i) &= \left(1 - \frac{i}{2N}\right)^2\end{aligned}$$

alors la loi de  $Z_k$  sachant  $X_t = i$  est une loi binomiale  $\mathcal{B}\left(2, \frac{i}{2N}\right)$

On répète une expérience aléatoire plusieurs fois (on examine chaque chromosome du  $k^{\text{ème}}$  individu) et on compte le nombre de fois où un critère particulier  $c$  apparaît ( $c =$  allèle  $\mathbf{A}_1$ ).

Les résultats doivent être indépendants

(le fait que le  $2^{\text{ème}}$  chromosome porte ou non  $\mathbf{A}_1$  ne dépend pas de l'état du  $1^{\text{er}}$ ).

On obtient une loi binomiale  $\mathcal{B}$ (nb de répétitions de l'expériences, probabilité que  $c$  apparaisse).

On veut calculer  $X_{t+1} = Z_1 + Z_2 + \dots + Z_N$

$\Rightarrow$  la loi de  $X_{t+1}$  sachant  $X_t = i$  est une loi binomiale  $\mathcal{B}\left(2N, \frac{i}{2N}\right)$

(on considère les  $2N$  allèles des individus de la génération  $t+1$  et on compte le nombre de fois où l'allèle  $\mathbf{A}_1$  apparaît)

### 3 - Stabilité moyenne de la fréquence de l'allèle $A_1$

Comme  $X_{t+1}$  sachant  $X_t = i$  suit la loi binomiale  $\mathcal{B}\left(2N, \frac{i}{2N}\right)$ , alors

$$\text{a) } \mathbb{P}(X_{t+1} = j | X_t = i) = C_{2N}^j \left(\frac{i}{2N}\right)^j \left(1 - \frac{i}{2N}\right)^{2N-j}$$

$\leadsto (X_t)_t$  est une chaîne de Markov de matrice de transition

$$P = (P_{ij})_{i,j} \text{ avec } P_{ij} = C_{2N}^j \left(\frac{i}{2N}\right)^j \left(1 - \frac{i}{2N}\right)^{2N-j}$$

La valeur future de  $X_{t+1}$  ne dépend du passé que par la valeur présente de  $X_t$ .

$$\text{b) } \mathbb{E}(X_{t+1} | X_t = i) = 2N \times \frac{i}{2N} = i$$

$\leadsto$  effectif constant en moyenne; stabilité de Hardy-Weinberg?

Le nombre moyen d'apparitions du critère  $c$  au cours des expériences indépendantes est :

nombre de répétitions de l'expérience  $\times$  probabilité d'apparition de  $c$

$$\text{c) } \text{Var}(X_{t+1} | X_t = i) = 2N \times \frac{i}{2N} \times \left(1 - \frac{i}{2N}\right) = i\left(1 - \frac{i}{2N}\right)$$

## 4 - Perte définitive d'un allèle

La chaîne de Markov a 2 états absorbants : 0 et  $2N$

Tous les autres états sont transients.

⇒ **perte définitive d'un allèle.**

### a) Combien de temps avant le dérive génique ?

On note  $T$  l'instant de perte d'un allèle.

$T$  est un **temps d'arrêt.**

**L'instant d'arrêt ne dépend que du passé et du présent.**

$$\mathbb{E}(T) = -4N \left[ \left(1 - \frac{X_0}{2N}\right) \ln\left(1 - \frac{X_0}{2N}\right) + \frac{X_0}{2N} \ln\left(\frac{X_0}{2N}\right) \right]$$

## b) Quel allèle reste ?

$$\begin{aligned}\mathbb{E}(X_{t+1} | \mathcal{F}_t) &= \mathbb{E}(X_{t+1} | X_t) \text{ car } (X_t)_t \text{ est une chaîne de Markov} \\ &= \sum_{i=0}^{2N} \mathbb{E}(X_{t+1} | X_t = i) \mathbb{1}_{\{X_t=i\}} = \sum_{i=0}^{2N} i \mathbb{1}_{\{X_t=i\}} = X_t\end{aligned}$$

$\leadsto (X_t)_t$  est une **martingale**

Connaissant le comportement passé de  $(X_t)_t : X_0, X_1, \dots, X_t$ ,

la meilleure prédiction qu'on puisse faire pour la valeur future de  $X_{t+1}$  est  $X_t$ .

Par conséquent,  $\forall t \in \mathbb{N}$ ,  $\mathbb{E}(X_t) = X_0$ . **En moyenne, une martingale est constante.**

Et aussi,  $\mathbb{E}(X_T) = X_0$

avec  $\mathbb{E}(X_T) = 0 \times \mathbb{P}(X_T = 0) + 2N \mathbb{P}(X_T = 2N)$

$$\implies \mathbb{P}(\mathbf{A}_2 \text{ disparaît}) = \frac{X_0}{2N}$$

### III - Application aux mutations

#### 1 - Probabilité de fixation d'une mutation

instant initial = apparition d'une mutation

On note  $\mathbf{A}_1$  l'allèle muté et  $\mathbf{A}_2$  l'ensemble des autres allèles.

Soit  $X_t$  le nombre d'allèles  $\mathbf{A}_1$  portés par la génération  $t$ ,  $t \in \mathbb{N}$ .

*Remarque* :  $X_0 = 1$

D'après précédemment,

$$\mathbb{P}(\text{fixation de la mutation}) = \mathbb{P}(\mathbf{A}_2 \text{ disparaît}) = \frac{X_0}{2N} = \frac{1}{2N}$$

## 2 - Théorie de l'horloge moléculaire

Le taux d'apparition des mutations est constant (indépendant de  $t$  et du locus considéré).

Notons  $\mu$  le taux de mutation par locus, par génération et  $f_0$  la proportion de mutations neutres (non létales).

$\rightsquigarrow$  nombre moyen de mutations neutres par locus, par génération  
=  $2Nf_0\mu$ . On note  $\frac{\theta}{2} = 2Nf_0\mu$ .

Soit  $S_t$  = nombre de mutations neutres apparues en  $t$  générations.

Alors  $(S_t)_{t \geq 0}$  est un processus de Poisson de taux  $\frac{\theta}{2}$ .

On observe l'occurrence d'événements qui surviennent avec un taux constant ;

les nombres d'occurrences sur deux intervalles disjoints sont indépendants ;

il ne se produit pas 2 occurrences de l'événement simultanément.

Le temps d'attente entre deux occurrences successives est sans mémoire.

Remarque : pour des considérations phylogéniques, on mesure le temps en unités de générations ou de  $2N$  générations.

$\leadsto$  taux de mutation neutre =  $2Nf_0\mu \times \mathbb{P}(\text{fixation d'une mutation})$ .  
 $\implies$  **taux d'évolution**  $k_0 = f_0\mu$ .

Soit  $K$  = nombre de mutations neutres **apparues** en  $T$  générations  
susceptibles d'être fixées.

Alors  $K$  suit une **loi de Poisson**  $\mathcal{P}(k_0T)$ .

Remarque :  **$\mathbb{E}(K)$  est indépendant de la taille de la population !**

On observe l'occurrence d'événements indépendants qui surviennent avec un taux constant ;  
le temps entre deux occurrences successives est sans mémoire.

## IV - Différences entre séquences d'ADN

### 1 - Hypothèses

- On suppose :
- population diploïde de **taille constante**  $N$
  - fécondations au hasard et indépendantes
  - population **isolée** (pas de migrations)
  - **pas de sélection**

$\mathbb{P} \left( 2 \text{ chromosomes de la génération } t+1 \text{ soient issus du même chromosome de la génération } t \right) = \frac{1}{2N}$

Soit  $M$  = nombre de générations écoulées depuis l'ancêtre commun.

Alors  $M$  suit une **loi géométrique**  $\mathcal{G} \left( \frac{1}{2N} \right)$ .

On répète une expérience aléatoire plusieurs fois (on examine les générations antérieures) et on compte le nombre de fois où on répète l'expérience avant d'obtenir un succès (ancêtre commun).

$\rightsquigarrow$  **temps moyen d'attente** =  $\mathbb{E}(M) = 2N$  générations.

## 2 - Temps de coalescence

On s'intéresse au temps de coalescence de 2 chromosomes.

$T_2 =$  temps de coalescence  $= \frac{M}{2N}$  : unité de  $2N$  générations.

Comme  $\mathbb{P}(M = m) = \left(1 - \frac{1}{2N}\right)^{m-1} \left(\frac{1}{2N}\right)$ ,

alors  $\mathbb{P}(T_2 \leq x) = \sum_{m=1}^{2Nx} \mathbb{P}(M = m) = 1 - \left(1 - \frac{1}{2N}\right)^{2Nx}$

On se place dans le cadre d'une population de grande taille.

alors  $\mathbb{P}(T_2 \leq x) \simeq 1 - e^{-x}$

donc le temps de coalescence  $T_2$  suit une loi exponentielle  $\mathcal{E}(1)$ .

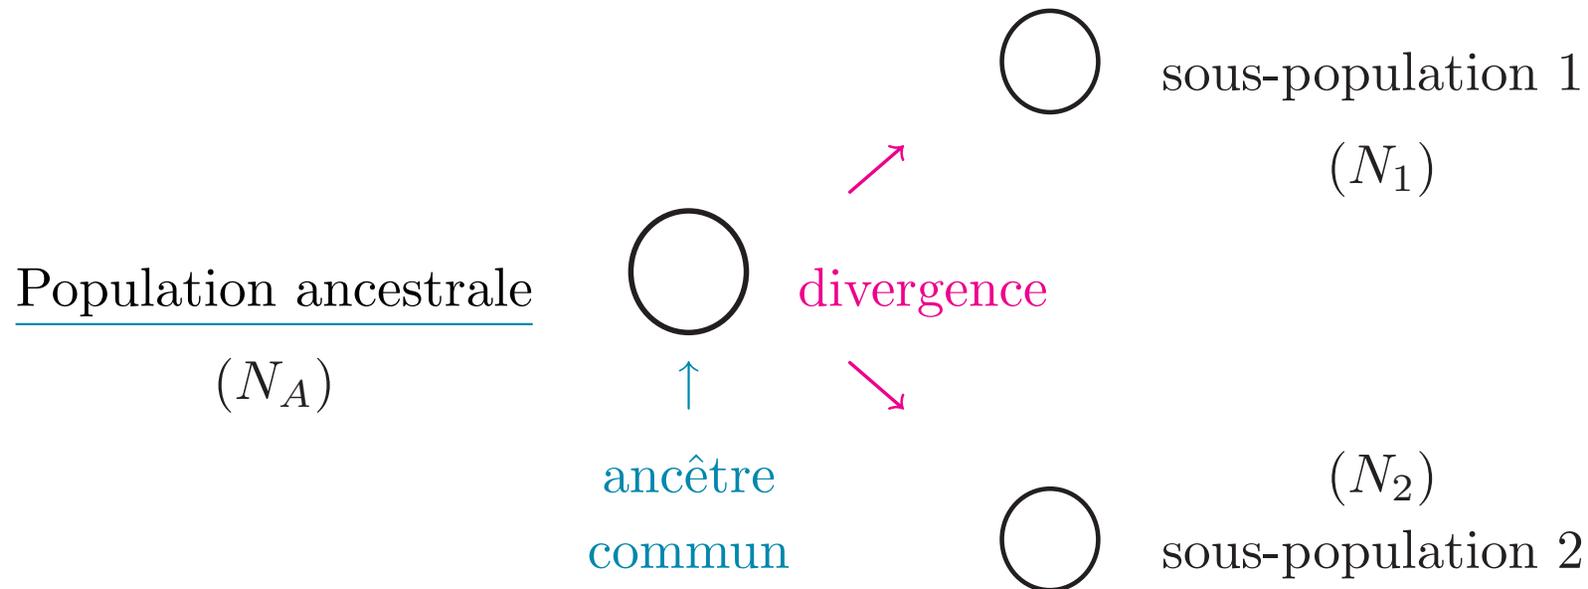
De même que la loi géométrique, la loi exponentielle est sans mémoire.

### 3 - Nombre de mutations depuis la divergence

Population ancestrale composée de  $N_A$  individus.

Il y a  $T$  générations, **divergence** en 2 sous-populations.

Considérons 1 séquence d'ADN dans chaque sous-population.



Depuis l'instant de divergence, chaque séquence a subi **indépendamment** une évolution due à des mutations.

Soit  $K_i$  = nombre de mutations neutres apparues en  $T$  générations sur la séquence  $i$ , susceptibles d'être fixées.

horloge moléculaire  $\implies K_i$  suit une loi de Poisson  $\mathcal{P}(k_0T)$ .

Remarque : Le taux d'évolution  $k_0 = f_0\mu$  ne dépend pas de l'effectif des populations  $N_1$  et  $N_2$ .

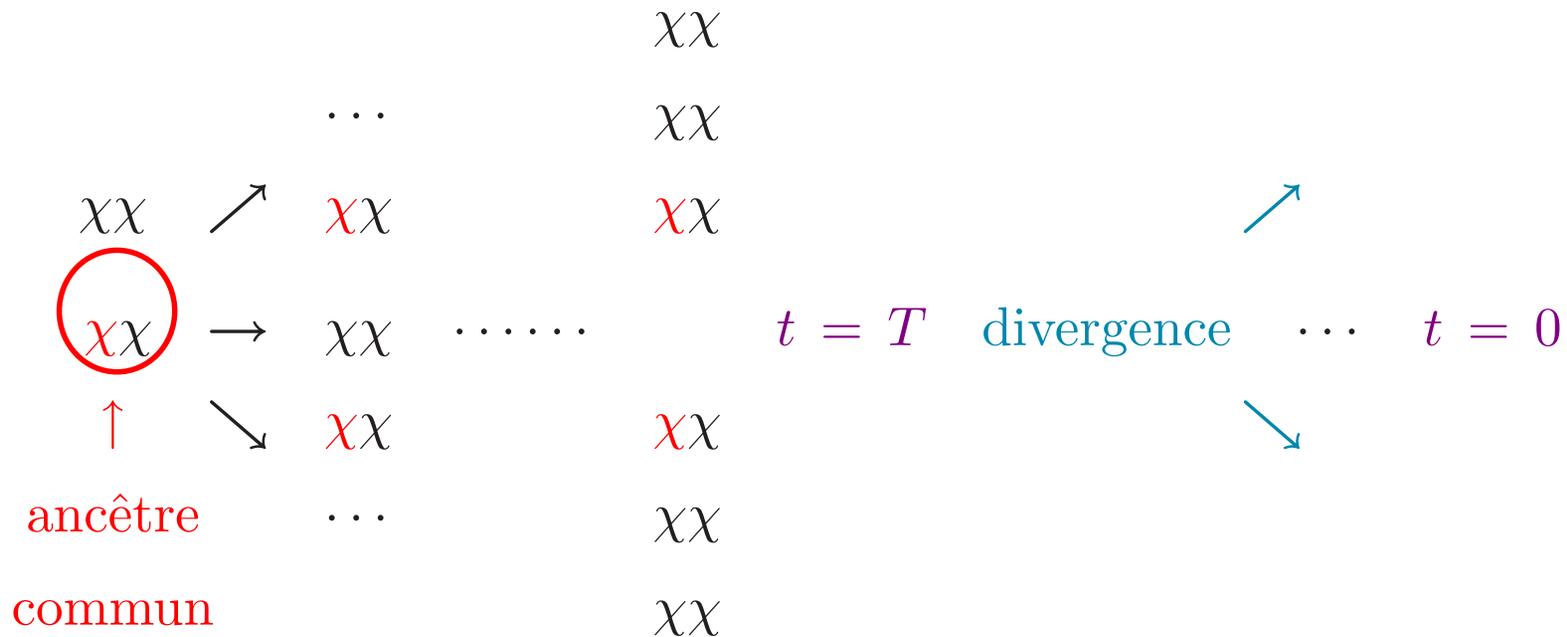
Ainsi,  $K_1 + K_2$  suit une loi de Poisson  $\mathcal{P}(2k_0T)$  ( $k_0 = f_0\mu$ ).

$$\implies \mathbb{E}(K_1 + K_2) = 2f_0\mu T \text{ et } \text{Var}(K_1 + K_2) = 2f_0\mu T.$$

## 4 - Nombre de mutations ancestrales

On note  $\chi$  le chromosome transmis par l'ancêtre commun.

Population ancestrale ( $2N_A$  chromosomes)  $\rightsquigarrow$  2 sous-populations



⚠ La mesure du temps est **rétrograde**!

Depuis l'instant de coalescence, chaque séquence a subi **indépendamment** une évolution due à des mutations.

Soit  $K_t^i$  = nombre de mutations neutres apparues en  $t$  générations sur la séquence  $i$ , **susceptibles d'être fixées**.

horloge moléculaire  $\implies (K_t^i)_{t \geq 0}$  processus de Poisson ( $f_0\mu$ )

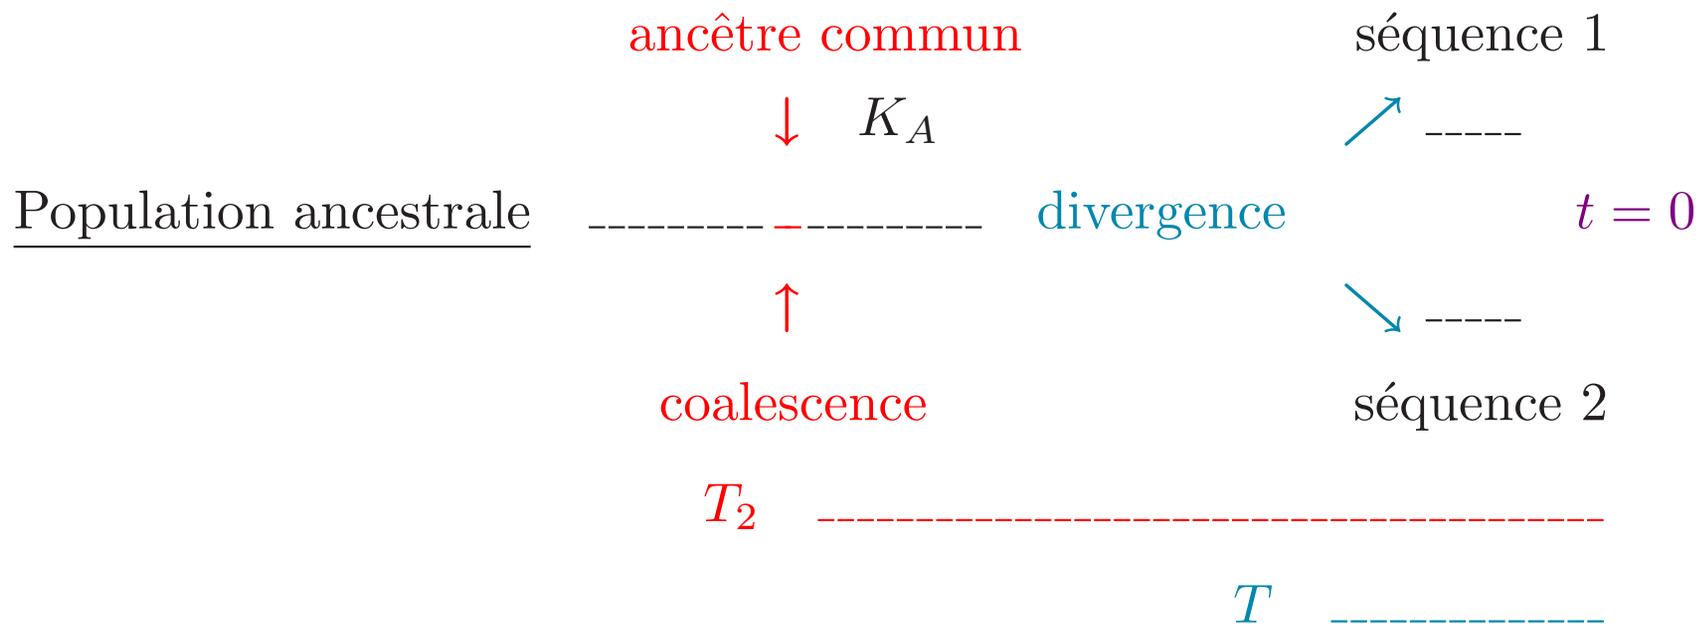
Ainsi,  $(K_t^1 + K_t^2)_{t \geq 0}$  est un **processus de Poisson**, de paramètre  $2f_0\mu$ .

$\implies t_M$  = temps d'attente entre deux mutations susceptibles d'être fixées **sur l'une ou l'autre** des séquences,

$\sim$  loi exponentielle  $\mathcal{E}(2f_0\mu)$

$\implies T_M$  = temps d'attente en unités de  $2N_A$  générations

$\sim$  loi exponentielle  $\mathcal{E}(\theta_A)$  ( $\theta_A = 4N_A f_0\mu$ )



Les séquences 1 et 2 sont issues de populations qui ont divergé.  
 L'ancêtre commun se trouve donc dans la population ancestrale.  
 D'où  $T_2 \geq T$ .

$T_2$  est sans mémoire  $\implies \mathbb{P}(T_2 \geq T + s | T_2 \geq T) = \mathbb{P}(T_2 \geq s)$ .

Le temps d'attente de la coalescence, depuis l'instant de divergence suit une loi  $\mathcal{E}(1)$ .

$T_2$  et  $T_M$  sont indépendantes, avec  $T_2 \sim \mathcal{E}(1)$  et  $T_M \sim \mathcal{E}(\theta_A)$

Le temps d'attente avant la coalescence ne dépend pas du nombre de mutations opérées sur le chromosome.

$$\text{donc } \mathbb{P}(T_M < T_2) = \frac{\theta_A}{1+\theta_A}$$

$K_A$  = nombre de mutations ancestrales  
(entre la divergence et la coalescence)

L'événement  $\{T_M < T_2\}$  est un échec répété  $k$  fois avant le premier succès  $\{T_M \geq T_2\}$ .

On répète donc l'expérience  $k+1$  fois avant d'obtenir le premier succès de probabilité  $\frac{1}{1+\theta_A}$ .

Ainsi,  $K_A+1 \sim$  loi géométrique  $\mathcal{G}\left(\frac{1}{1+\theta_A}\right)$

$$\text{Alors, } \mathbb{P}(K_A = k) = \left(\frac{\theta_A}{1+\theta_A}\right)^k \frac{1}{1+\theta_A}$$

$$\text{et } \mathbb{E}(K_A) = \theta_A, \quad \text{Var}(K_A) = \theta_A (1 + \theta_A)$$

La translation des données translate la moyenne, mais le coefficient de dispersion est identique.

Autre point de vue : file M/M/1

Temps de service =  $T_2 \sim \mathcal{E}(1)$

Processus arrivée clients (mutation susceptibles d'être fixées)

=  $(S_t)_{t \geq 0}$  processus de Poisson de paramètre  $\theta_A$ .

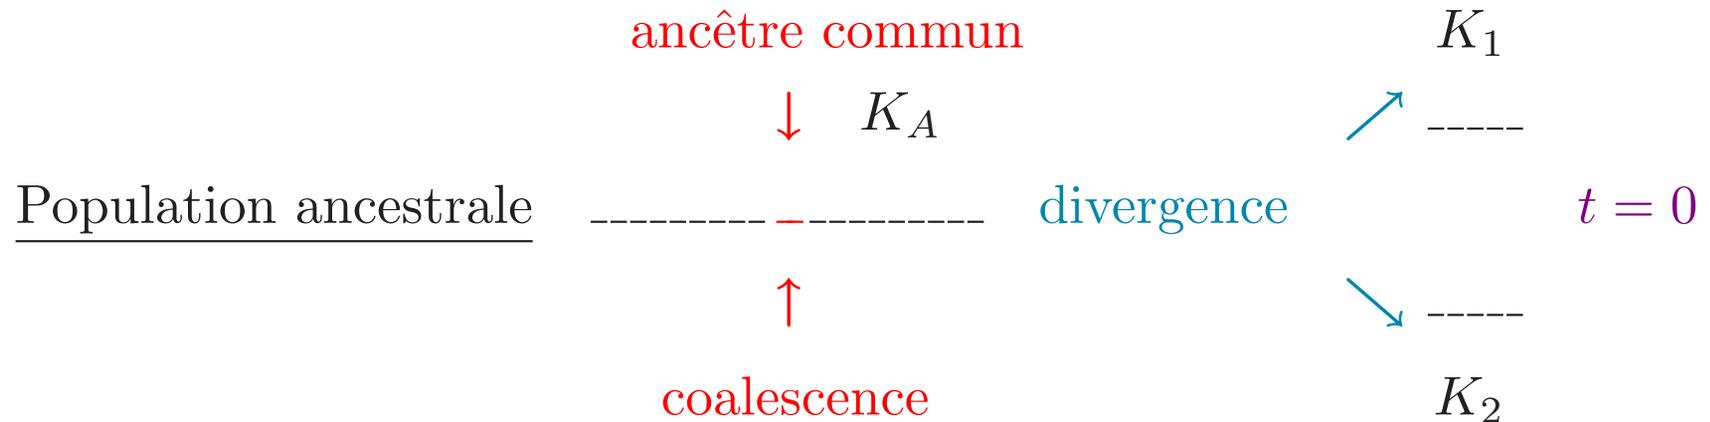
$T_2$  est indépendant du processus d'arrivée des mutations.

On compte le nombre de clients  $K_A$  qui arrivent pendant le temps de service d'un client :

$$\begin{aligned} \mathbb{P}(K_A = k) &= \int_0^\infty \mathbb{P}(S_t = k | T_2 = t) e^{-t} dt \\ &= \frac{\theta_A^{k+1}}{(k+1)!} \int_0^\infty t^{k+1} e^{-(\theta_A+1)t} dt \\ &= \left( \frac{\theta_A}{1+\theta_A} \right)^k \frac{1}{1+\theta_A} \end{aligned}$$

## 5 - Nombre de mutations totales

$K$  = nombre de mutations totales (depuis la coalescence).



Alors,  $K = K_A + K_1 + K_2$ , somme de variables indépendantes.

$$\implies \mathbb{E}(K) = \mathbb{E}(K_A) + \mathbb{E}(K_1 + K_2) = \theta_A + 2\mu f_0 T$$

$$\text{et } \text{Var}(K) = \text{Var}(K_A) + \text{Var}(K_1 + K_2) = \theta_A(1 + \theta_A) + 2\mu f_0 T$$

Conclusion :

Malgré l'hypothèse de l'horloge moléculaire, le processus du nombre de mutations susceptibles d'être fixées depuis la coalescence n'est pas un processus de Poisson si la population ancestrale a divergé.

Si c'était le cas,  $K$  suivrait une loi de Poisson, et on aurait  $\mathbb{E}(K) = Var(K)$ .

$$\text{Or, } \frac{Var(K)}{\mathbb{E}(K)} = \frac{\theta_A^2 + \theta_A + 2\mu f_0 T}{\theta_A + 2\mu f_0 T} = \frac{\theta_A}{1 + \frac{T}{2N_A}} + 1 \neq 1,$$

avec  $\theta_A = 4N_A f_0 \mu$ .

## V - Sélection naturelle

### 1 - Hypothèses

On suppose :

- population diploïde de **taille constante**  $N$
- fécondations au hasard et indépendantes
- population **isolée** (pas de migrations)

**Coefficient de sélection**  $s$  qui mesure l'**aptitude des génotypes**.

$s$  tient compte de :

- la probabilité de survie jusqu'à l'âge adulte
- la fertilité

**Coefficient de dominance**  $h$  qui ajuste  $s$  pour les **hétérozygotes**.

Remarque  $s$  et  $h$  sont  $\geq 0$  ou  $\leq 0$  ;  
 $s$  et  $sh$  sont de l'ordre du %.

Soit  $p$  la fréquence de l'allèle  $\mathbf{A}_1$  pour les adultes de la génération 0.

On étudie la fréquence des génotypes à la génération suivante.

Pour l'exemple, on suppose  $s = -0.05$ ,  $h = 0$ ,  $p = 0.9$ ,  $N = 100$ .

Génotype	$\mathbf{A}_1\mathbf{A}_1$	$\mathbf{A}_1\mathbf{A}_2$	$\mathbf{A}_2\mathbf{A}_2$
Fréquence (nais.)	$p^2$ (81%)	$2p(1-p)$ (18%)	$(1-p)^2$ (1%)
Aptitude	$1 + 2s$ (0,9)	$1 + 2sh$ (1)	1 (1)
Nombre (adulte)	$Np^2(1 + 2s)$ (73)	$2Np(1-p)(1 + 2sh)$ (18)	$N(1-p)^2$ (1)
Fréquence (adulte)	$\frac{p^2(1+2s)}{\bar{w}}$ (79%)	$\frac{2p(1-p)(1+2sh)}{\bar{w}}$ (20%)	$\frac{(1-p)^2}{\bar{w}}$ (1%)

avec  $\bar{w} = p^2(1 + 2s) + 2p(1-p)(1 + 2sh) + (1-p)^2$

## 2 - Evolution de la fréquence de l'allèle $A_1$

$X_t$  = nombre d'allèles  $A_1$  portés par la génération adulte  $t$ ,  
(après sélection) avec  $t \in \mathbb{N}$ .

Alors  $X_{t+1}$  sachant  $X_t = i$  suit la loi binomiale  $\mathcal{B}(2N, \psi_i)$ .

$$\mathbb{P}(X_{t+1} = j | X_t = i) = C_{2N}^j \psi_i^j (1 - \psi_i)^{2N-j}$$

$$\text{avec } \psi_i = \frac{\frac{i}{2N}^2 (1 + 2s) + \frac{i}{2N} (1 - \frac{i}{2N}) (1 + 2sh)}{\frac{i}{2N}^2 (1 + 2s) + 2 \frac{i}{2N} (1 - \frac{i}{2N}) (1 + 2sh) + (1 - \frac{i}{2N})^2}$$

$\rightsquigarrow (X_t)_t$  est une chaîne de Markov de matrice de transition

$$P = (P_{ij})_{i,j} \quad \text{avec} \quad P_{ij} = C_{2N}^j \psi^j (1 - \psi)^{2N-j}$$

La chaîne de Markov a 2 états absorbants : 0 et  $2N$

$x_t$  = fréquence de l'allèle  $\mathbf{A}_1$  dans la génération adulte  $t$ ,  
(après sélection) avec  $t \in \mathbb{N}$ .

$$\text{Alors } x_{t+1} = \frac{x_t^2 (1 + 2s) + x_t(1 - x_t)(1 + 2sh)}{x_t^2 (1 + 2s) + 2x_t(1 - x_t)(1 + 2sh) + (1 - x_t)^2}$$

Les fréquences  $x_\infty = 0$  et  $1$  sont les seuls points d'équilibre.

Si  $s < 0 \implies \mathbf{A}_1$  s'éteint; si  $s > 0 \implies \mathbf{A}_2$  s'éteint.

Si  $s = 0 \implies \mathbb{P}(\text{fixation de l'allèle } \mathbf{A}_1) = \frac{x_0}{2N}$ .

### 3 - Approximation par une diffusion

Si l'**effectif** de la population est **grand**,  
on approche la chaîne de Markov par une **diffusion**.

#### a) Moyenne et variance de l'accroissement de la fréquence

Notons  $M_t$  l'**accroissement moyen** de la fréquence entre  $t$  et  $t + 1$ .

$$\begin{aligned} M_t &= \mathbb{E}\left(\frac{X_{t+1}}{2N} - \frac{X_t}{2N} \mid X_t = i\right) \\ &= \frac{1}{2N} \mathbb{E}(X_{t+1} - i \mid X_t = i) \\ &= \frac{1}{2N} \times 2N\psi_i - \frac{i}{2N} = \psi_i - \frac{i}{2N} \end{aligned}$$

$X_{t+1}$  sachant  $X_t = i$  suit la loi  $\mathcal{B}(2N, \psi_i)$ .

Et aussi  $V_t =$  variance de l'accroissement de la fréquence.

$$\begin{aligned} V_t &= \text{Var} \left( \frac{X_{t+1}}{2N} - \frac{X_t}{2N} \mid X_t = i \right) \\ &= \frac{1}{4N^2} \mathbb{E} \left( (X_{t+1} - i)^2 \mid X_t = i \right) - \frac{1}{4N^2} \left( \mathbb{E} (X_{t+1} - i \mid X_t = i) \right)^2 \\ &= \frac{1}{4N^2} \mathbb{E} (X_{t+1}^2 \mid X_t = i) + \frac{i^2}{4N^2} - \frac{i}{2N^2} \mathbb{E} (X_{t+1} \mid X_t = i) \\ &\quad - \left( \psi_i - \frac{i}{2N} \right)^2 \\ &= \frac{\psi_i(1 - \psi_i)}{2N} \end{aligned}$$

Remarque :  $M_t$  et  $V_t$  ne dépendent pas de la génération  $t$  considérée, mais seulement de  $i$  et de  $N$ .

## b) Calcul sur des exemples

On note  $x = \frac{i}{2N}$ ,  $x \in [0, 1]$ .

Cas d'une population de **très grande taille**.

On cherche un **équivalent** lorsque  $x \rightarrow 0$ ; on les note  $M_{\delta x}$  et  $V_{\delta x}$ .

Rappel :  $M_t = \psi_i - x$  et  $V_t = \frac{\psi_i(1-\psi_i)}{2N}$ .

• ni mutation, ni sélection :  $\psi_i = x \implies M_{\delta x} = 0$  et  $V_{\delta x} = \frac{x(1-x)}{2N}$

• sélection, dominance :  $\psi_i = \frac{x^2(1+2s) + x(1-x)(1+2sh)}{x^2(1+2s) + 2x(1-x)(1+2sh) + (1-x)^2}$

$\implies M_{\delta x} \approx 2sx(1-x)((1-2h)x + h)$  et  $V_{\delta x} \approx \frac{x(1-x)}{2N}$

• mutation réciproque  $\mathbf{A}_1 \xrightarrow{\mu} \mathbf{A}_2$  et  $\mathbf{A}_2 \xrightarrow{\nu} \mathbf{A}_1$  :

$$\psi_i = (1-x)\nu + x(1-\mu)$$

$\implies M_{\delta x} = (1-x)\nu - x\mu$  et  $V_{\delta x} \approx \frac{x(1-x)}{2N}$

### c) Introduction d'une EDS

Exemple : évolution dynamique d'une population isolée.

$\chi_t$  = effectif de la population à l'instant  $t$ .

- $$\chi_t = \chi_0 + \int_0^t \rho \chi_r \left(1 - \frac{\chi_r}{k}\right) dr.$$

$\rightsquigarrow \chi_t = \chi_0 + \int_0^t m(\chi_r) dr$ , avec  $m(x) = \rho x \left(1 - \frac{x}{k}\right)$ .

- Modélisation de l'aléa par le **mouvement brownien**  $(W_t)_{t \geq 0}$ .

EDS : 
$$\chi_t = \chi_0 + \int_0^t m(\chi_r) dr + \int_0^t \sigma(\chi_r) dW_r$$

Remarque :  $\chi_t$  est une **variable aléatoire** !

## Equation Différentielle Stochastique (EDS)

$$\chi_t = \chi_0 + \int_0^t m(\chi_r) dr + \int_0^t \sigma(\chi_r) dW_r$$

D'après le **calcul stochastique**,

$$m(x) = \lim_{\epsilon \rightarrow 0} \frac{1}{\epsilon} \mathbb{E}(\chi_{r+\epsilon} - \chi_r \mid \chi_r = x) = \text{accroissement infinitésimal}$$

$$\sigma^2(x) = \lim_{\epsilon \rightarrow 0} \frac{1}{\epsilon} \mathbb{E}\left( (\chi_{r+\epsilon} - \chi_r)^2 \mid \chi_r = x \right)$$

**On mesure le temps par échelle de  $2N$  générations.**

Ici,  $\chi_r = \frac{X_{E(2Nr)}}{2N}$  la fréquence à la génération  $E(2Nr)$ , et  $\epsilon = \frac{1}{2N}$ .

donc  $m(x) = \lim_{N \rightarrow +\infty} 2N M_{\delta x}$  et  $\sigma^2(x) = \lim_{N \rightarrow +\infty} 2N (V_{\delta x} + M_{\delta x}^2)$

Rappel :  $m(x) = \lim_{N \rightarrow +\infty} 2NM_{\delta x}$  et  $\sigma^2(x) = \lim_{N \rightarrow +\infty} 2N(V_{\delta x} + M_{\delta x}^2)$

- ni mutation, ni sélection :  $M_{\delta x} = 0$  et  $V_{\delta x} = \frac{x(1-x)}{2N}$

$$\implies \chi_t = \chi_0 + \int_0^t \sqrt{\chi_r(1-\chi_r)} dW_r$$

- sélection, dominance :  $M_{\delta x} \approx 2sx(1-x)((1-2h)x+h)$

pour  $h = \frac{1}{2}$ , on a  $M_{\delta x} \approx sx(1-x)$  et  $V_{\delta x} \approx \frac{x(1-x)}{2N}$

$$\implies \chi_t = \chi_0 + \int_0^t \alpha \chi_r (1 - \chi_r) dr + \int_0^t \sqrt{\chi_r(1-\chi_r)} dW_r$$

Le coefficient de sélection  $s$  est de l'ordre de  $\frac{1}{N}$ .

On pose  $\alpha = 2sN$ ;  $s$  et  $s^2N$  sont négligeables.

- mutation réciproque  $\mathbf{A}_1 \xrightarrow{\mu} \mathbf{A}_2$  et  $\mathbf{A}_2 \xrightarrow{\nu} \mathbf{A}_1$  :

---


$$M_{\delta x} = \nu(1-x) - \mu x \quad \text{et} \quad V_{\delta x} \approx \frac{x(1-x)}{2N}$$

$$\Rightarrow \chi_t = \chi_0 + \int_0^t (\gamma_1(1-\chi_r) - \gamma_2\chi_r) dr + \int_0^t \sqrt{\chi_r(1-\chi_r)} dW_r$$

Les coefficients de mutation  $\mu$  et  $\nu$  sont de l'ordre de  $\frac{1}{N}$ .

On pose  $\gamma_1 = \nu N$  et  $\gamma_2 = \nu N$  ;

$2N \mu^2$ ,  $2N \nu^2$  et  $2N \mu \nu$  sont négligeables.

## 4 - Lien avec les EDP

### a) Formule de Feynman-Kac

Rappel :  $\chi_r = \frac{X_{E(2Nr)}}{2N}$  la fréquence à la génération  $E(2Nr)$

$$\chi_t = \chi_0 + \int_0^t m(\chi_r) dr + \int_0^t \sigma(\chi_r) dW_r, \quad (0 \leq \chi_t \leq 1).$$

On note  $\tau_x = \inf \{t \geq 0 \mid \chi_t = 0 \text{ ou } 1 \text{ sachant que } \chi_0 = x\}$

•  $\chi_{\tau_x} = 0 \text{ ou } 1 \implies \mathbb{E}(\chi_{\tau_x}) = \mathbb{P}(\chi_{\tau_x} = 1)$ , noté  $u(x)$

est solution de 
$$\begin{cases} m(x) u'(x) + \frac{1}{2} \sigma^2(x) u''(x) = 0, \\ u(0) = 0 \text{ et } u(1) = 1 \end{cases}$$

•  $\mathbb{E}(\tau_x)$ , noté  $v(x)$  est solution de

$$\begin{cases} m(x) v'(x) + \frac{1}{2} \sigma^2(x) v''(x) = -1 \\ v(0) = 0 \text{ et } v(1) = 0 \end{cases}$$

## b) Probabilité de fixation

$\rightsquigarrow \mathbb{P}(\chi_s \text{ atteint la valeur 1 avant la valeur 0} \mid \chi_0 = x) = u(x)$

$$\text{solution de } \begin{cases} m(x) u'(x) + \frac{1}{2} \sigma^2(x) u''(x) = 0, & \text{si } 0 < x < 1 \\ u(0) = 0 \text{ et } u(1) = 1 \end{cases}$$

$$\implies u(x) = \frac{\int_0^x e^{-2 \int \frac{m(z)}{\sigma^2(z)} dz} dx}{\int_0^1 e^{-2 \int \frac{m(z)}{\sigma^2(z)} dz} dx}$$

• ni mutation, ni sélection :  $m(x) = 0$  et  $\sigma^2(x) = x(1-x) \implies u(x) = x$

$\rightsquigarrow \mathbb{P}(\text{fixation allèle } \mathbf{A}_1 \mid X_0 = x) = x$  et  $\mathbb{P}(\text{fixation mutation}) = \frac{1}{2N}$

• sélection, dominance ( $h = \frac{1}{2}$ ) :  $m(x) \approx \alpha x(1-x)$  et  $\sigma^2(x) \approx x(1-x)$

$$\implies u(x) = \frac{1 - e^{-2\alpha x}}{1 - e^{-2\alpha}}, \quad \text{avec } \alpha = 2Ns.$$

$\rightsquigarrow \mathbb{P}(\text{fixation mutation}) = \frac{1 - e^{-2s}}{1 - e^{-4Ns}} \approx \frac{2s}{1 - e^{-4Ns}}$

Importance de la sélection :  $N = 10^5$ ,  $x_1 = \frac{1}{2}$  et  $x_2 = \frac{1}{2N}$  .

Génotype     $\mathbf{A_1A_1}$      $\mathbf{A_1A_2}$      $\mathbf{A_2A_2}$

Aptitude     $1 + 2s$      $1 + 2sh$      $1$

Absence de sélection ( $s = 0$ )    Sélection faible ( $s = 10^{-5}$ )

$$u\left(\frac{1}{2}\right) = 0,5$$

$$u\left(\frac{1}{2}\right) = \frac{1-e^{-2}}{1-e^{-4}} \simeq 0,88$$

$$u\left(\frac{1}{2N}\right) = 5 \times 10^{-6}$$

$$u\left(\frac{1}{2N}\right) \simeq 2 \times 10^{-5}$$

Ainsi, même si  $s$  est faible, l'influence sur la probabilité de fixation d'un allèle ou d'une mutation est grande (car à l'échelle de **nombreuses générations**).

### c) Temps de fixation

$\rightsquigarrow \mathbb{E}(\text{ temps d'atteinte d'une des valeurs 0 ou 1 } \mid \chi_0 = x) = v(x)$

solution de 
$$\begin{cases} m(x) v'(x) + \frac{1}{2} \sigma^2(x) v''(x) = -1, & \text{si } 0 < x < 1 \\ v(0) = 0 \text{ et } v(1) = 0 \end{cases}$$

• ni mutation, ni sélection :  $m(x) = 0$  et  $\sigma^2(x) = x(1-x)$

$$\implies v(x) = -2 (x \ln x + (1-x) \ln(1-x)) \geq 0 \text{ car } 0 < x < 1.$$

$\rightsquigarrow \mathbb{E}(\text{ temps de fixation d'un des allèles } \mathbf{A}_1 \text{ ou } \mathbf{A}_2 \mid X_0 = x)$

$$= -4N (x \ln x + (1-x) \ln(1-x)) \text{ g\u00e9n\u00e9rations.}$$

Si  $x = \frac{1}{2}$ , on obtient le temps maximal d'attente :

temps moyen de fixation d'un des all\u00e8les  $\simeq 2,8N$  g\u00e9n\u00e9rations.

### d) Evolution de la fréquence en fonction du temps

Notons  $\phi(t, x) = \mathbb{P}\left(\frac{X_t}{2N} \leq x \mid \frac{X_0}{2N} = p\right)$

$\phi$  est solution de l'équation de Kolmogorov backward

$$\frac{\partial \phi}{\partial t}(t, x) - \mu(x) \frac{\partial \phi}{\partial x}(t, x) - \frac{1}{2} \sigma^2(x) \frac{\partial^2 \phi}{\partial x^2}(t, x) = 0$$

## e) Conclusion sur la sélection

théorie de l'horloge moléculaire

↷ détection de mutations sélectionnées

$K$  = nombre de mutations neutres sélectionnées apparues en  $t$  générations et susceptibles d'être fixées.

$$\text{Alors, } \mathbb{E}(K) = 2N\mu f_0 t \frac{2s}{1 - e^{-2Ns}}$$

On a supposé  $s = \text{cste}$ ,

on peut supposer que  $s$  suit une loi de densité  $f$  donnée (exponentielle, normale...)

$$\text{Dans ce cas, } \mathbb{E}(K) = 2N\mu f_0 t \int_{-\infty}^{+\infty} \frac{2s}{1 - e^{-2Ns}} f(s) ds.$$