








# 1. L'ADN et l'information génétique




1

## I'ADN

l'information génétique est contenue dans l'ADN




## comment fait-on une protéine ?



le « rôle » de l'ADN est de contenir, conserver et transmettre l'information nécessaire à la synthèse des protéines.

## traduction

l'information génétique est organisée par triplets (codons)



4

## le code génétique


		Second Letter					
		U	C	A	G		
1st letter	U	UUU   Phe UUC UUA   Leu UUG	UCU   Ser UCC UCA UCG	UAU   Tyr UAC UAA   Stop UAG   Stop	UGU   Cys UGC UGA   Stop UGG   Trp	U C A G	3rd letter
	C	CUU   Leu CUC CUA CUG	CCU   Pro CCC CCA CCG	CAU   His CAC CAA   Gln CAG	CGU   Arg CGC CGA CGG	U C A G	
	A	AUU   Ile AUC AUA AUG   Met	ACU   Thr ACC ACA ACG	AAU   Asn AAC AAA   Lys AAG	AGU   Ser AGC AGA   Arg AGG	U C A G	
	G	GUU   Val GUC GUA GUG	GCU   Ala GCC GCA GCG	GAU   Asp GAC GAA   Glu GAG	GGU   Gly GGC GGA GGG	U C A G	

le code génétique est dégénéré :  $4^3 = 64 > 20$  !

5

## le gène


unité de l'information génétique



6

## le gène

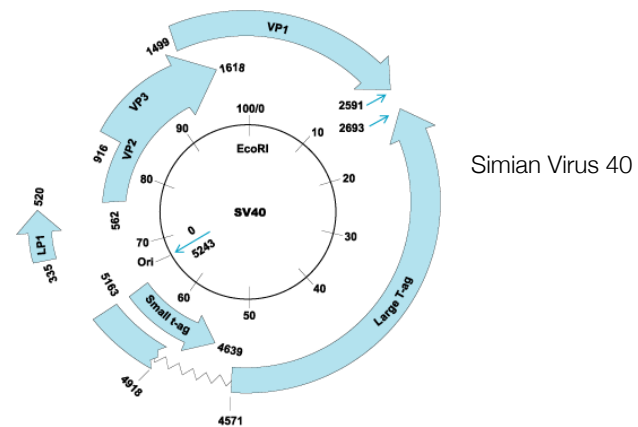
unité de l'information génétique



7

## le génome

organisation de l'information génétique




Simian Virus 40

8

## le génome

organisation de l'information génétique




9

## le génome

organisation de l'information génétique

chez l'homme :


- 3 milliards de pbs
- ~20000 gènes
- < 2 % d'ADN codant !



10

## le génome

quantité d'ADN codant en fonction de la taille du génome



11

## ADN codant et non codant

en résumé :




pourquoi autant d'ADN non codant ?  
peut-on en comprendre le rôle ?

12




### 3. fonction de corrélation et densité spectrale de puissance (DSP)




17

### fonction de corrélation



$\xi(t)$  signal aléatoire fonction du temps t, stationnaire :

ici sinus + bruit



$\varphi_{\xi\xi}(\tau)$  fonction de corrélation de  $\xi(t)$  :

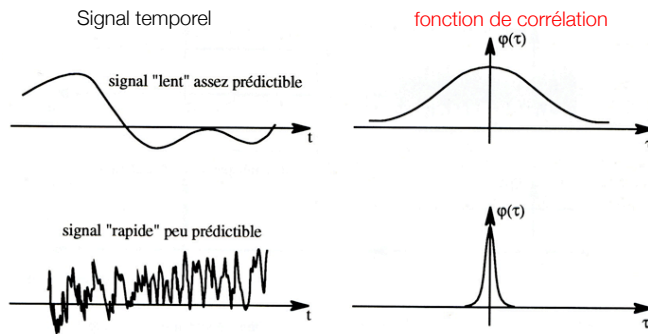
$$\varphi_{\xi\xi}(\tau) = \left\langle (\xi(t) - \langle \xi \rangle) \cdot (\xi(t + \tau) - \langle \xi \rangle) \right\rangle_{ensemble}$$

périodicité « cachée »  
→ oscillations dans la corrélation

18

### fonction de corrélation


mesure de la persistance (mémoire) d'un signal :



19


### (bruit blanc)

Signal « sans mémoire » : chaque valeur est indépendante de la précédente



- $b(t)$  signal stationnaire,
- $\langle b(t) \rangle = 0$  (centré),
- $\varphi_{bb}(\tau) = \gamma \delta(\tau)$  fonction de corrélation

d'où  $\sigma_b^2 = \varphi_{bb}(\tau) = +\infty$



20

## moyennes temporelles

fonction de corrélation de  $\xi(t)$


$$\varphi_{\xi\xi}(\tau) = \left\langle (\xi(t) - \langle \xi \rangle) \cdot (\xi(t + \tau) - \langle \xi \rangle) \right\rangle_{\text{ensemble}} ?$$

si « ergodique » :

on peut remplacer la moyenne d'ensemble par une moyenne sur le temps :

$$\varphi_{\xi\xi}(\tau) = \left\langle (\xi(t_0 + t) - \langle \xi \rangle) \cdot (\xi(t_0 + t + \tau) - \langle \xi \rangle) \right\rangle_{t_0}$$

chaque  $t_0$  initial considéré comme une nouvelle réalisation



## densité spectrale de puissance (DSP)

Densité spectrale de puissance

$$S_{\xi\xi}(f) \stackrel{\text{def}}{=} TF[\varphi_{\xi\xi}(\tau)]$$

Théorème de Wiener-Khintchine :

$$S_{\xi\xi}(f) = \lim_{T \rightarrow \infty} \frac{1}{T} \left| TF[\xi^T(t)] \right|^2$$


où  $\xi^T(t) = \xi(t)$  limitée à l'intervalle  $[0, T]$

Estimateur de la DSP d'un signal réel :


$$S_{\xi\xi}(f) \cong \left\langle \frac{1}{T} \left| TF[\xi^T(t)] \right|^2 \right\rangle_{\text{ensemble}} \quad 22$$

## Fonction de corrélation et DSP

1. périodicité « cachée » =  $T \Rightarrow$  pic à la fréquence  $\propto 1/T$

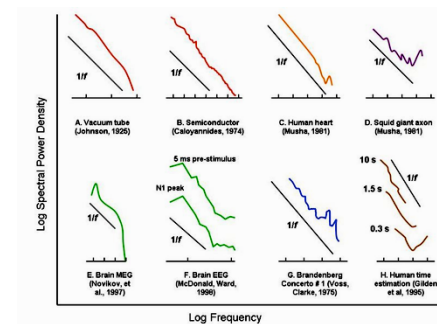


2. échelle de « mémoire » =  $a \Rightarrow \int_0^{\infty} \varphi_{\xi\xi}(\tau) d\tau \approx a$



23

## 4. corrélation à longue portée dans l'ADN



[http://www.scholarpedia.org/article/1/f\\_noise](http://www.scholarpedia.org/article/1/f_noise)

24


## corrélation à longue portée

si l'échelle de mémoire est infinie ( $\varphi_{xx}(\tau)$  n'est pas intégrable)  
on parle de **corrélation à longue portée**.

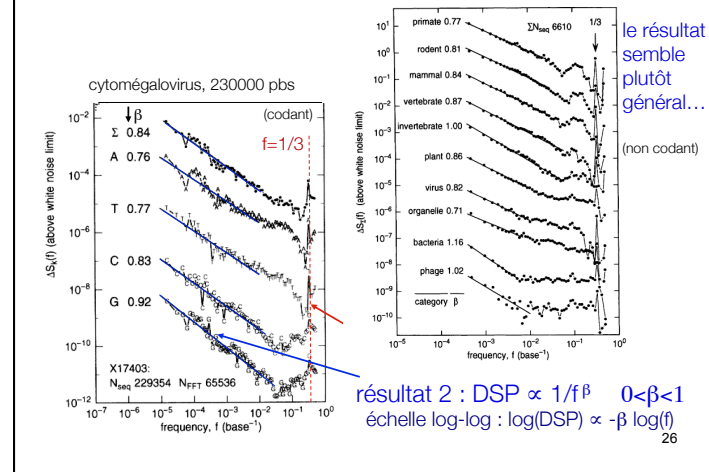
Typiquement, loi de puissance :

$$\lim_{\tau \rightarrow \infty} \varphi_{xx}(\tau) \propto \frac{1}{\tau^\alpha} \quad \Leftrightarrow \quad \lim_{f \rightarrow \infty} S_{xx}(f) \propto \frac{1}{f^\beta}$$

$$0 < \alpha \leq 1 \quad \quad \quad 0 < \beta \leq 1 \quad \quad \beta = 1 - \alpha$$




## dans l'ADN



## pour l'ADN codant

des résultats controversés :




pas de corrélation ?  
(Stanley group, 1992-1995)

L'ADN codant est sans doute moins corrélé que le non codant...

## revenons à la fonction de corrélation

fonction de corrélation pour une séquence codante :  
périodicité 3



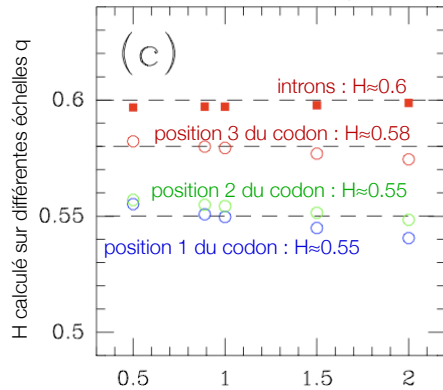
comment évolue l'amplitude des pics en position 3i ?

on la reporte en échelle log : décroissance en  $d^\alpha$  !  
corrélation longue portée pour « une base sur trois » ?



séquences codantes :  
la dégénérescence du code laisse « passer »  
un peu de corrélation longue portée


H = indice de corrélation longue portée




la position 3  
du codon,  
plus libre,  
peut suivre  
la contrainte  
« globale »

## pourquoi une mémoire étendue ?

eucaryotes : CHROMATINE !




## d'autres images



## un rôle pour les séquences non codantes

la corrélation à longue portée  
indique  
la présence d'un ordre global ;

les séquences non codantes  
montrent toujours  
une corrélation à longue portée



↓  
l'ADN « pouvelle » participe à l'établissement d'un arrangement  
fonctionnel de l'ADN dans le noyau/la cellule !

et l'ADN codant ? il a aussi un autre rôle, participe peut-être en  
moindre mesure...



## 5. en pratique



33

signal discret → fonction de corrélation de  $\xi_n$

n = 1 2 3 4 5 6 7 8 9 10 11...  
 A T C G G T C A T A C...  
 ↓ ↓ ↓ ↓ ↓ ↓ ↓ ↓ ↓ ↓ ↓  
 $\xi_n = +1 +1 -1 -1 -1 +1 -1 +1 +1 +1 -1...$

si  $\langle \xi_n \rangle = 0$  (autrement, on soustrait la moyenne)

$$C(d) = \langle \xi_n \xi_{n+d} \rangle = \frac{1}{N} \sum_{n=1}^N \xi_n \xi_{n+d}$$

d = distance entre 2 sites le long de la séquence  
 moyenne « temporelle » → moyenne sur n

(attention à la stationnarité...)

34

→ fonction de corrélation de  $\xi_n$

en pratique :

sur un ordinateur, le signal est toujours discret !

$$z(t) \rightarrow (z_1, z_2, z_3, z_4, \dots, z_N) = Z$$

pour nous, le signal est *intrinsèquement* discret (pas=1), car c'est la séquence.


sous scilab, on peut utiliser la fonction :

corr :  $\text{corr}(z, d_{\max}) =$  fonction de corrélation de  $x_n$   
 en fonction de la distance d,  
 pour  $d = 0, 1, 2, \dots, d_{\max}-1$


(remarque : corr soustrait automatiquement la moyenne de z)

35

→ DSP de  $\xi_n$  – 1. calculer la TF :



Signal échantillonné  $\Delta t$  → Spectre **périodique** de période  $f_e = 1/\Delta t$



Signal échantillonné :

$$x_k = k \Delta t \\ \text{de } 0 \text{ à } T_e = N \Delta t$$

FFT du signal :

$$f_n = n \Delta f \\ \text{de } 0 \text{ à } f_e = N \Delta f$$

36

→ DSP de  $\xi_n$  – 2. déduire la DSP :

FFT = transformée de Fourier Rapide

sous scilab :

fft :  $\text{fft}(z, -1) = \text{fft}(z) = \text{TF de } z$   
donne TF pour  $f = 0, \Delta f, 2\Delta f, \dots, f_e - 1$

Wiener-Khintchine : estimateur DSP =  $\left\langle \frac{1}{T} |TF[\xi^T(t)]|^2 \right\rangle_{ensemble}$

d'où  $|\text{fft}(z)|^2 / N \approx \underline{\text{DSP de } z}$

sous scilab, commencer par soustraire la moyenne de z 37

fin

38