

Alignement optimal ?

AACT--GGTAACCG  
AGCTACGGT--CCG



Calcul d'un score

Le score de l'alignement doit prendre en compte toutes les positions alignées : identités, substitutions et indels. Chacun de ces événements va recevoir un poids, appelé score élémentaire  $s_e$ . Le score de l'alignement correspondra à la somme des scores élémentaires correspondant aux positions alignées.

$$S = \sum_{i=1}^l s_e(i)$$

Où  $l$  est le nombre de positions alignées

exemple:  $l = 14$

$s_e$  identité = +2

$s_e$  substitution = -1

$s_e$  indels = -2



$S = 9$

Prenons comme exemple deux séquences X et Y de longueur M et N :

**X = AGTCCATC M=8**

**Y = TCCGC N=5**

Matrice de programmation dynamique :

|     |   |     |   |   |   |   |   |   |   |
|-----|---|-----|---|---|---|---|---|---|---|
|     |   | → i |   |   |   |   |   |   |   |
|     |   | A   | G | T | C | C | A | T | C |
| ↓ j | T |     |   |   |   |   |   |   |   |
|     | C |     |   |   |   |   |   |   |   |
|     | C |     |   |   |   |   |   |   |   |
|     | G |     |   |   |   |   |   |   |   |
|     | C |     |   |   |   |   |   |   |   |
|     |   |     |   |   |   |   |   |   |   |

Le score optimal sera calculé récursivement. Le score calculé pour la cellule (i,j) correspondra au meilleur alignement des résidus  $x_1 \dots x_i$  avec les résidus  $y_1 \dots y_j$



# Matrices PAM

**PAM : Point/Percent Accepted Mutation (Dayhoff, 1978)**

**Construction :**

- 71 familles de protéines
- alignements multiples (global)
- reconstruction des arbres phylogénétiques et inférences des séquences ancêtres (1 572 mutations)
- pour chaque a.a. on compte le nombre de fois où il a été substitué  
Exemple : pour *Val* combien de fois il est resté inchangé, et combien de fois il a été substitué par *Ala*, par *Arg*, ...
- Cumul des mutations « acceptées » par la sélection naturelle au sein des différentes familles
- Calcul de la mutabilité des a.a. (propension d'un a.a. à être remplacé,  $f(\text{Val} \rightarrow X)$ )
- Calcul de la matrice de probabilités de mutation à partir des 2 étapes précédentes
  - Pour chaque a.a., ex:  $\text{Val} \rightarrow \text{Ala} = \text{mutabilité}(\text{Val}) * \text{cumul}(\text{Val} \rightarrow \text{Ala}) / \text{nb}(\text{Val})$
- Calcul de la matrice Lods (Log odd ratios) : PAM1

1
2
3

1 2 3 4 5 6 7 8 9 0 1 2 3 4 5 6 7 8 9 0 1 2 3 4 5 6 7 8 9 0 1 2 3 4 5 6 7 8 9...

KAPPA

|                  |  |
|------------------|--|
| 1 HUMAN EU       | T - V A A P S V F I F P P S D E Q - L K S - G T A S V V C L L N N F Y P - R E... |
| 2 MOUSE MOPC 21  | A - D A A P T V S I F P P S S E Q - L T S - G G A S V V C F L N N F Y P - K D    |
| 3 QAT S211       | A - N A A P T V S I F P P S T Z Z - L A T - G G A S V V C L M N K . F Y P - R D  |
| 4 84 RA881T 4135 | D - P V A P T V L I F P P A A D Q - V A T - G T V T I V C V A N K Y F P - - D    |
| B9 RA881T        | D P P I A P T V L L F P P S A D Q - L T T - Z T V T I V C V A N K F R P - D D    |

LAMBDA

|                   |   |
|-------------------|---|
| 6 HUMAN SH        | Q P K A A P S V T L F P P S S E E - L Q A - N K A T L V C L I S D F Y P - G A   |
| 7 PIG             | Q P K A A P T V N L F P P S S E E - L G T - N K A T L V C L I S D F Y P - G A   |
| 8 MOUSE MOPC 104E | Q P K S S P S V T L F P P S S E E - L T E - N K A T L V C T I T O F Y P - G V   |
| 9 MOUSE MOPC 315  | Q P K S T P T L T V F P P S S E E - L K E - N K . A T L V C L I S N F S P - G S |

...

# Matrices PAM

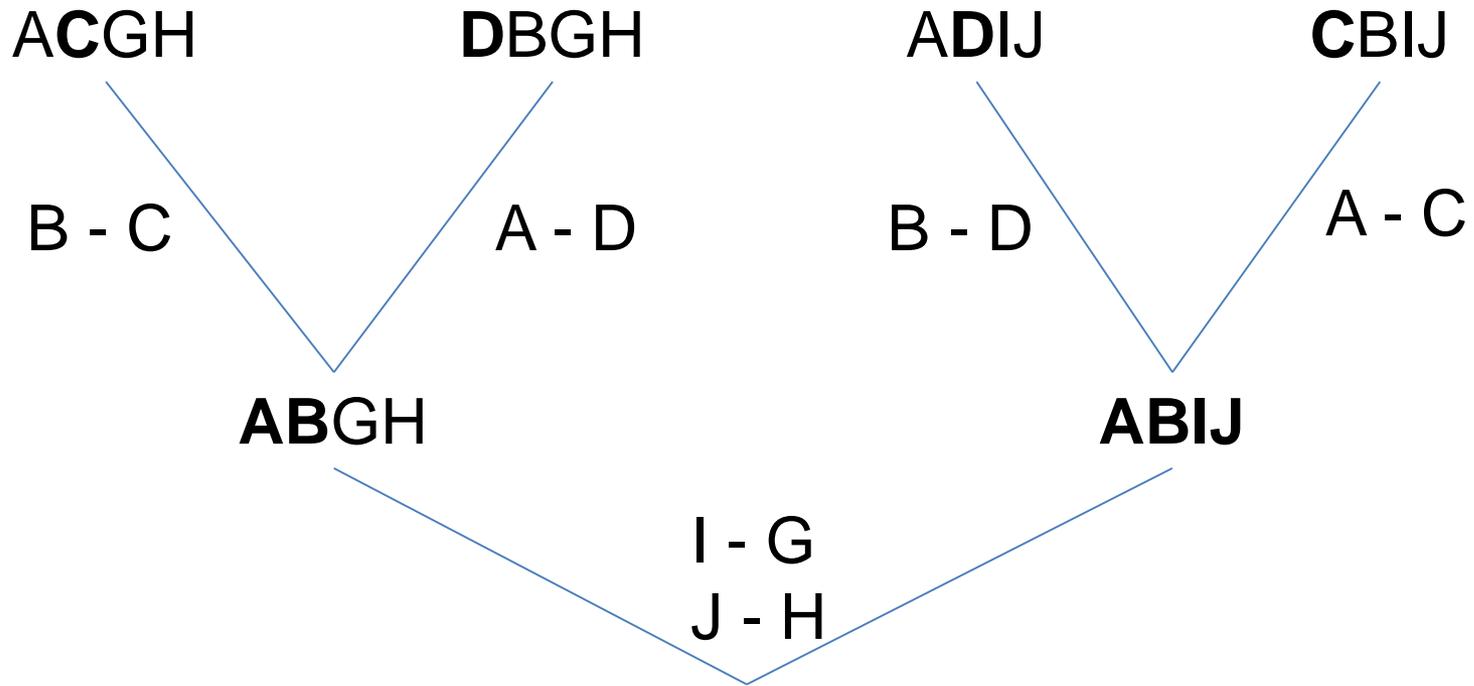
**PAM : Point/Percent Accepted Mutation (Dayhoff, 1978)**

**Construction :**

- 71 familles de protéines
- alignements multiples (global)
- reconstruction des arbres phylogénétiques et inférences des séquences ancêtres (1 572 mutations)
- pour chaque a.a. on compte le nombre de fois où il a été substitué  
Exemple : pour *Val* combien de fois il est resté inchangé, et combien de fois il a été substitué par *Ala*, par *Arg*, ...

- Cumul des mutations « acceptées » par la sélection naturelle au sein des différentes familles
- Calcul de la mutabilité des a.a. (propension d'un a.a. à être remplacé,  $f(\text{Val} \rightarrow X)$ )
- Calcul de la matrice de probabilités de mutation à partir des 2 étapes précédentes
  - Pour chaque a.a., ex:  $\text{Val} \rightarrow \text{Ala} = \text{mutabilité}(\text{Val}) * \text{cumul}(\text{Val} \rightarrow \text{Ala}) / \text{nb}(\text{Val})$
- Calcul de la matrice Lods (Log odd ratios) : PAM1

# Arbre phylogénétique



## Matrice des mutations acceptées

|   | A | B | C | D | G | H | I | J |
|---|---|---|---|---|---|---|---|---|
| A |   |   | 1 | 1 |   |   |   |   |
| B |   |   | 1 | 1 |   |   |   |   |
| C | 1 | 1 |   |   |   |   |   |   |
| D | 1 | 1 |   |   |   |   |   |   |
| G |   |   |   |   |   |   | 1 |   |
| H |   |   |   |   |   |   |   | 1 |
| I |   |   |   |   | 1 |   |   |   |
| J |   |   |   |   |   | 1 |   |   |

# Matrices PAM

**PAM : Point/Percent Accepted Mutation (Dayhoff, 1978)**

**Construction :**

- 71 familles de protéines
- alignements multiples (global)
- reconstruction des arbres phylogénétiques et inférences des séquences ancêtres (1 572 mutations)
- pour chaque a.a. on compte le nombre de fois où il a été substitué  
Exemple : pour *Val* combien de fois il est resté inchangé, et combien de fois il a été substitué par *Ala*, par *Arg*, ...
- Cumul des mutations « acceptées » par la sélection naturelle au sein des différentes familles
- Calcul de la mutabilité des a.a. (propension d'un a.a. à être remplacé,  $f(\text{Val} \rightarrow X)$ )
- Calcul de la matrice de probabilités de mutation à partir des 2 étapes précédentes
  - Pour chaque a.a., ex:  $\text{Val} \rightarrow \text{Ala} = \text{mutabilité}(\text{Val}) * \text{cumul}(\text{Val} \rightarrow \text{Ala}) / \text{nb}(\text{Val})$
- Calcul de la matrice Lods (Log odd ratios) : PAM1

## Matrice de cumul des mutations acceptées (x10)

|   | ala | arg | asn | asp | cys | gln | glu | gly | his | ile | leu | lys | met | phe | pro | ser | thr | trp | tyr | val |
|---|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|-----|
| A |     |     |     |     |     |     |     |     |     |     |     |     |     |     |     |     |     |     |     |     |
| R | 30  |     |     |     |     |     |     |     |     |     |     |     |     |     |     |     |     |     |     |     |
| N | 109 | 17  |     |     |     |     |     |     |     |     |     |     |     |     |     |     |     |     |     |     |
| D | 154 | 0   | 532 |     |     |     |     |     |     |     |     |     |     |     |     |     |     |     |     |     |
| C | 33  | 10  | 0   | 0   |     |     |     |     |     |     |     |     |     |     |     |     |     |     |     |     |
| Q | 93  | 120 | 50  | 76  | 0   |     |     |     |     |     |     |     |     |     |     |     |     |     |     |     |
| E | 266 | 0   | 94  | 831 | 0   | 422 |     |     |     |     |     |     |     |     |     |     |     |     |     |     |
| G | 579 | 10  | 156 | 162 | 10  | 30  | 112 |     |     |     |     |     |     |     |     |     |     |     |     |     |
| H | 21  | 103 | 226 | 43  | 10  | 243 | 23  | 10  |     |     |     |     |     |     |     |     |     |     |     |     |
| I | 66  | 30  | 36  | 13  | 17  | 8   | 35  | 0   | 3   |     |     |     |     |     |     |     |     |     |     |     |
| L | 95  | 17  | 37  | 0   | 0   | 75  | 15  | 17  | 40  | 253 |     |     |     |     |     |     |     |     |     |     |
| K | 57  | 477 | 322 | 85  | 0   | 147 | 104 | 60  | 23  | 43  | 39  |     |     |     |     |     |     |     |     |     |
| M | 29  | 17  | 0   | 0   | 0   | 20  | 7   | 7   | 0   | 57  | 207 | 90  |     |     |     |     |     |     |     |     |
| F | 20  | 7   | 7   | 0   | 0   | 0   | 17  | 20  | 90  | 167 | 0   | 17  |     |     |     |     |     |     |     |     |
| P | 345 | 67  | 27  | 10  | 10  | 93  | 40  | 49  | 50  | 7   | 43  | 43  | 4   | 7   |     |     |     |     |     |     |
| S | 772 | 137 | 432 | 98  | 117 | 47  | 86  | 450 | 26  | 20  | 32  | 168 | 20  | 40  | 269 |     |     |     |     |     |
| T | 590 | 20  | 169 | 57  | 10  | 37  | 31  | 50  | 14  | 129 | 52  | 200 | 28  | 10  | 73  | 696 |     |     |     |     |
| W | 0   | 27  | 3   | 0   | 0   | 0   | 0   | 0   | 3   | 0   | 13  | 0   | 0   | 10  | 0   | 17  | 0   |     |     |     |
| Y | 20  | 3   | 36  | 0   | 30  | 0   | 10  | 0   | 40  | 13  | 23  | 10  | 0   | 260 | 0   | 22  | 23  | 6   |     |     |
| V | 365 | 20  | 13  | 17  | 33  | 27  | 37  | 97  | 30  | 661 | 303 | 17  | 77  | 10  | 50  | 43  | 186 | 0   | 17  |     |

# Matrices PAM

**PAM : Point/Percent Accepted Mutation (Dayhoff, 1978)**

**Construction :**

- 71 familles de protéines
- alignements multiples (global)
- reconstruction des arbres phylogénétiques et inférences des séquences ancêtres (1 572 mutations)
- pour chaque a.a. on compte le nombre de fois où il a été substitué  
Exemple : pour *Val* combien de fois il est resté inchangé, et combien de fois il a été substitué par *Ala*, par *Arg*, ...
- Cumul des mutations « acceptées » par la sélection naturelle au sein des différentes familles
- Calcul de la mutabilité des a.a. (propension d'un a.a. à être remplacé,  $f(\text{Val} \rightarrow X)$ )
- Calcul de la matrice de probabilités de mutation à partir des 2 étapes précédentes
  - Pour chaque a.a., ex:  $\text{Val} \rightarrow \text{Ala} = \text{mutabilité}(\text{Val}) * \text{cumul}(\text{Val} \rightarrow \text{Ala}) / \text{nb}(\text{Val})$
- Calcul de la matrice Lods (Log odd ratios) : PAM1

Séquences alignées

A D A

A D B



|                             |     |   |   |
|-----------------------------|-----|---|---|
| <b>Acides aminés</b>        | A   | B | D |
| <b>Changements observés</b> | 1   | 1 | 0 |
| <b>Occurrences</b>          | 3   | 1 | 2 |
| <b>Mutabilité</b>           | .33 | 1 | 0 |

Mutabilité (Dayhoff, 1978)

Ser 149

Met 122

Asn 111

Ile 110

Glu 102

Ala 100

Gln 98

Asp 90

Thr 90

Gap 84

Val 80

Lys 57

Pro 56

His 50

Gly 48

Phe 45

Arg 44

Leu 38

Tyr 34

Cys 27

Trp 22



Positionnée à 100 arbitrairement

# Matrices PAM

**PAM : Point/Percent Accepted Mutation (Dayhoff, 1978)**

## Construction :

- 71 familles de protéines
- alignements multiples (global)
- reconstruction des arbres phylogénétiques et inférences des séquences ancêtres (1 572 mutations)
- pour chaque a.a. on compte le nombre de fois où il a été substitué  
Exemple : pour *Val* combien de fois il est resté inchangé, et combien de fois il a été substitué par *Ala*, par *Arg*, ...

- Cumul des mutations « acceptées » par la sélection naturelle au sein des différentes familles
- Calcul de la mutabilité des a.a. (propension d'un a.a. à être remplacé,  $f(\text{Val} \rightarrow X)$ )
- Calcul de la matrice de probabilités de mutation à partir des 2 étapes précédentes
  - Pour chaque a.a., ex:  $\text{Val} \rightarrow \text{Ala} = \text{mutabilité}(\text{Val}) * \text{cumul}(\text{Val} \rightarrow \text{Ala}) / \text{nb}(\text{Val})$
  - $m_j$  : mutabilité de l'a.a.  $j$
  - $A_{ij}$  : nombre de fois que l'a.a.  $j$  a été remplacé par l'a.a.  $i$
  - $\lambda$  : paramètre d'ajustement pour avoir 1 mutation acceptée pour 100 résidus

- Calcul de la matrice Lods (Log odd ratios) :  $PAM1_{i,j} = \log \frac{M_{ij}}{f_i}$

# Matrices PAM

## Calcul de la matrice Lods (Log odd ratios) :

Permet de faire la somme des scores élémentaires pour un alignement plutôt que le produit des probabilités :  $\log (a*b) = \log a + \log b$

$$w_{i,j} = \log \frac{q_{ij}}{p_{ij}}$$

où:  
 $q_{ij}$  est la fréquence observée de substitution de l'acide aminé  $i$  en  $j$   
 $p_{ij}$  est la fréquence théorique de substitution de l'acide aminé  $i$  en  $j$

**PAM1** : Normalisée pour avoir 1 mutation acceptée pour 100 a.a.



Temps qu'il faut pour qu'une mutation se fixe dans la population  
= Distance évolutive conceptuelle : 1 PAM

**Hypothèse** : les probabilités de mutations sont indépendantes

$$PAM2 = PAM1 \times PAM1$$

Matrice pour une distance évolutive de 2 PAM

$$\text{De même, } PAM40 = PAM1^{40}, PAM120 = PAM1^{120}, PAM250 = PAM1^{250}$$



# Matrices PAM

Remarques :

- Matrice calculée à partir de séquences ayant moins de 15% de divergence
- Biais dans la sélection des protéines (petites protéines globulaires)
- Actualisées : 16 130 séquences appartenant à 2 621 familles de protéines