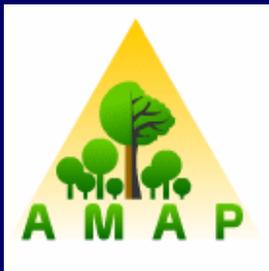


# Analyse de séquences

Partie III : Alignement multiple

Sèverine Bérard



AMAP - Université Montpellier 2



- 
- Introduction
  - Méthodes de score
  - Alignement multiple exact
  - MSA Global
  - MSA Local
  - Éditeurs de MSA
  - Références

- Permet d'aligner plusieurs séquences simultanément
- En général pour les protéines
- Alignements faits à la main par les experts biologistes
- Généralisation naturelle de l'alignement 2 à 2 mais beaucoup plus complexe en terme de calcul

Problème : Étant données  $k$  séquences  $s_1, s_2, \dots, s_k$ , trouver le meilleur alignement multiple pour ces séquences

- Ce pb est NP-complet ( $\Rightarrow$   $\nexists$  de solution exacte en tps raisonnable)

# Exemples d'alignement

```
          10          20          30          40          50          60          70          80          90
sw: IL8_CANFA/1-97  MTSKLAVALLAAAFVLSAALCEAAVLSRVSSSELRCOCIKTHSTPFHPKFIKELRVIDSGPHCENSEIIIVKLFNGNEVCLDPEKEKWVQKVYQIFLKKAE--
sw: EMF1_CHICK/20-96 -----OGRTLVKMGNELRCOCISTHSKFIHPKSIQDVKLTTPSGPHCKNVEIIATLKDGREVCLDPTAPWVOLIIVKALMAKAG--
sw: GRO_CRIGR/32-96 -----ANELRCOCLQITMTG-VHLKNIQSLKVTTPPGPHCTQTEVIATLKNNGOEACLNPEAPMVOKIIVOKMLK-----
sw: SZ06_BOVIN/44-112 -----RELRCYCLTITTPG-IHPKTIWSDLOVIAAGPQCSKVEVIATLKNNGREYCLDPEAPLIKKIIVOKIILDSGKNN
sw: IL8_CERTO/1-98  MTSKLAVALLAAAFLLSAALCEGAVLERSAKELRCLCIKTYSKPFHPKFIKELRVIESGPHCYNTEIIIVKLSDGRELCLDPEKPWVORVVEKFLKRAES-
sw: IL8_BOVIN/1-97  MTSKLAVALLAAAFLLSAALCEAAVLSRMSTELRCOCIKTHSTPFHPKFIKELRVIESGPHCENSEIIIVKLTNGNEVCLNPEKEKWVQKVYQVYFKRAE--
sw: GRO_RAT/28-92   -----ANELRCOCLQITVAG-IHFKNIQSLKVTTPPGPHCTQTEVIATLKNGREACLDPEAPMVOKIIVOKMLK-----
sw: AMC2_PIG/48-110 -----RELRCMCLTITTPG-IHPKMISDLOVIPAGPQCSKAEVIATLKNNGKEVCLDPKAPLIKKIIVOKML-----
sw: IL8_FELCA/1-97  MTSKLVALLAAAFMLSAALCEAAVLSRISSELRCOCIKTHSTPFNPKLKELTVIDSGPHCENSEIIIVKLVNGKEVCLDPKQKWVQKVVEIFLKKAE--
sw: IL8_PIG/1-97    MTSKLAVAFLLAAAFLLSAALCEAAVLSRISSELRCOCINTHSTPFHPKFIKELRVIESGPHCENSEIIIVKLVNGKEVCLDPKEKWVQKVYQIFLKRTE--
sw: IL8_RABIT/1-97  MNSKLAVALLATFLLSLTLC EAAVLTTRIGTELRCOCIKTHSTPFHPKFIKELRVIESGPHCANSEIIIVKLVNGKEVCLDPKEKWVQKVYQIFLKRTE--
sw: IL8_HUMAN/1-99  MTSKLAVALLAAAFLLSAALCEGAVLERSAKELRCECIKTYSKPFHPKFIKELRVIESGPHCANTEIIIVKLSDGRELCLDPKENWVORVVEKFLKRAENS-
sw: IL8_CAYPO/20-98 -----CEGMVYTKLYSELRCOCIKIHTTTPFHPKFIKELRVIESGPHCANSEIIIVKLSDNROLCLDPKQKWVQKVYQVSMFLKRTE--
sw: MIP2_RAT/31-98  -----ASELRCOCLTITLPR-VDFKNIQSLTYTTPPGPHCAQTEVIATLKNNGREYCLNPEAPLVORIVOKIILNKGK--
sw: GRO_CAYPO/34-99 -----AASELRCRCLRPVRLG-LHPKNIQSVAVTAPGPHCHQTEVLATLKNNGREYCLDPEAPMVOKVYQVSMFLKRTE--
sw: IL8_HORSE/1-97  MTSKLAVALLAAAFLLSAALCEAAVLSRISSELRCOCIKTHSTPFNPKLKELTVIDSGPHCENSEIIIVKLVNGKEVCLDPKQKWVQKVVEIFLKKAE--
sw: IL8_SHEEP/1-97  MTSKLAVALLAAAFLLSAALCEAAVLSRMSTELRCOCIKTHSTPFHPKFIKELRVIESGPHCENSEIIIVKLTNGNEVCLDPEKEKWVQKVYQVYFKRAE--
sw: IL8_MACMU/1-98  MTSKLAVALLAAAFLLSAALCEGAVLERSAKELRCECIKTYSKPFHPKFIKELRVIESGPHCANTEIIIVKLSDGRELCLDPEKPWVORVVEKFLKRAEN-
sw: GRO_MOUSE/28-92 -----ANELRCOCLQITMAG-IHLKNIQSLKVTTPPGPHCTQTEVIATLKNNGREACLDPEAPLVOKIIVOKMLK-----
sw: GRO_HUMAN/38-101 -----ATELRCOCLQITLQI-IHPKNIQSVYVYKSPGPHCAQTEVIATLKNNGRKAACLNPEASPIVKKIIEKML-----
```

Quality/1-99



- Recherche dans les banques  $\Rightarrow$  plrs séquences similaires à la requête  
Il est naturel de vouloir aligner ces séquences entre elles
- MSA détectent les régions qui ont été conservées lors de l'évolution  
Très svnt des domaines associés à une fonction clé de la molécule
- Plusieurs protéines de fonctions similaires dans différentes espèces  
 $\rightarrow$  Quelles parties semblables?  $\Rightarrow$  Consensus/Profil  
 $\rightarrow$  Quelles parties différentes?
- Permet de trouver d'autres membres d'une famille de protéines
- Séquençage de génomes (assemblage, recouvrement EST)
- Point de départ pour les analyses phylogénétiques

Alignements multiples plus informatifs que les ali. de 2 séq.

- Un MSA peut être **global** ou **local** (comme un alignement de 2 séquences)
- **Global** : l'alignement 2 à 2 est étendu pour inclure 3 séq. ou plus  
*Des protéines de  $\neq$  organismes peuvent être conservées sur toute la longueur si elles assurent une fonction biologique importante*

Logiciels : CLUSTALW, MULTALIN, T-COFFEE, DIALIGN, ...

- **Local** : recherche de domaines/régions conservés  
*Les domaines fonctionnels de protéines peuvent être conservés tandis que le reste de la séquence diverge*

Logiciels : BLOCKS Web site, eMOTIF, GIBBS, HMMER, ...

- Notions utiles pour comparer des méthodes
- **Par exemple** : on prend une séquence membre d'une famille de protéine et on l'utilise comme requête, les algorithmes retournent une liste de *hits* et on coupe à un certain seuil

	Séq. membres famille	Séq. non membres
Séq. trouvé au-dessus du seuil	Vrais positifs	Faux positifs
Séq. trouvé en dessous du seuil	Faux négatifs	Vrai négatifs

- $\text{Sensibilité} = \frac{\text{Vrais positifs}}{\text{Vrais positifs} + \text{Faux négatifs}}$
- $\text{Sélectivité} = \frac{\text{Vrais positifs}}{\text{Vrais positifs} + \text{Faux positifs}}$

- 
- Introduction
  - Méthodes de score
  - Alignement multiple exact
  - MSA Global
  - MSA Local
  - Éditeurs de MSA
  - Références

Comment quantifier la qualité d'un alignement multiple ?

- Généraliser une fonction de score pour un alignement de  $k$  séq.
- Le score d'un MSA est la somme des scores de ses colonnes (ici les colonnes sont de hauteur  $k$ )
- Les colonnes sont considérées indépendantes
- Fonction à  $k$  paramètres ?  
Si alphabet de taille  $\alpha \Rightarrow \alpha^k$  colonnes possibles ( $21^5 > 4$  millions)  
On ne peut pas associer un coût à chaque colonne!?!
- Mesure raisonnable  $S$ , quelles propriétés ?

1. Même score pour les colonnes contenant les mêmes caractères (indépendamment de l'ordre)

$$S(I, -, I, V) = S(V, I, I, -) = S(V, I, -, I) = S(V, -, I, I) = \dots$$

2. Récompense les colonnes avec beaucoup de résidus identiques ou similaires
3. Pénalise les colonnes avec des résidus différents et des espaces
  - Plusieurs méthodes de score : méthode SP, méthode basée sur la phylogénie (arbre ou étoile), contenu en information, ...

- SP pour Sum of Pairs, c'est la méthode la plus utilisée
- Somme des scores de toutes les paires d'a.a. possibles dans une colonne ( $p(-, -) = 0$ ), puis somme des scores des colonnes
$$SP(I, -, I, V) = p(I, -) + p(I, I) + p(I, V) + p(-, I) + p(-, V) + p(I, V)$$
- Exemple avec BLOSUM62 et indel=-2

1	N	N	N	I	V
2	N	N	N	I	V
3	N	N	N	-	V
4	N	N	C	I	V
5	N	C	C	I	V

- Il y a  $\frac{k(k-1)}{2}$  paires/scores à calculer pour chaque colonne

- SP pour Sum of Pairs, c'est la méthode la plus utilisée
- Somme des scores de toutes les paires d'a.a. possibles dans une colonne ( $p(-, -) = 0$ ), puis somme des scores des colonnes

$$SP(I, -, I, V) = p(I, -) + p(I, I) + p(I, V) + p(-, I) + p(-, V) + p(I, V)$$

- Exemple avec BLOSUM62 et indel=-2

$$p(N, N) = 6$$

1	N	N	N	I	V
2	N	N	N	I	V
3	N	N	N	-	V
4	N	N	C	I	V
5	N	C	C	I	V
60					

- Il y a  $\frac{k(k-1)}{2}$  paires/scores à calculer pour chaque colonne

- SP pour Sum of Pairs, c'est la méthode la plus utilisée
- Somme des scores de toutes les paires d'a.a. possibles dans une colonne ( $p(-, -) = 0$ ), puis somme des scores des colonnes

$$SP(I, -, I, V) = p(I, -) + p(I, I) + p(I, V) + p(-, I) + p(-, V) + p(I, V)$$

- Exemple avec BLOSUM62 et indel=-2

$$p(N, N) = 6$$

$$p(N, C) = -3$$

1	N	N	N	I	V
2	N	N	N	I	V
3	N	N	N	-	V
4	N	N	C	I	V
5	N	C	C	I	V
	60	24			

- Il y a  $\frac{k(k-1)}{2}$  paires/scores à calculer pour chaque colonne

- SP pour Sum of Pairs, c'est la méthode la plus utilisée
- Somme des scores de toutes les paires d'a.a. possibles dans une colonne ( $p(-, -) = 0$ ), puis somme des scores des colonnes

$$SP(I, -, I, V) = p(I, -) + p(I, I) + p(I, V) + p(-, I) + p(-, V) + p(I, V)$$

- Exemple avec BLOSUM62 et indel=-2

$$p(N, N) = 6$$

$$p(N, C) = -3$$

$$p(C, C) = 9$$

1	N	N	N	I	V
2	N	N	N	I	V
3	N	N	N	-	V
4	N	N	C	I	V
5	N	C	C	I	V
	60	24	9		

- Il y a  $\frac{k(k-1)}{2}$  paires/scores à calculer pour chaque colonne

- SP pour Sum of Pairs, c'est la méthode la plus utilisée
- Somme des scores de toutes les paires d'a.a. possibles dans une colonne ( $p(-, -) = 0$ ), puis somme des scores des colonnes

$$SP(I, -, I, V) = p(I, -) + p(I, I) + p(I, V) + p(-, I) + p(-, V) + p(I, V)$$

- Exemple avec BLOSUM62 et indel=-2

$$p(N, N) = 6$$

$$p(N, C) = -3$$

$$p(C, C) = 9$$

$$p(I, I) = 4$$

$$p(I, -) = -2$$

1	N	N	N	I	V
2	N	N	N	I	V
3	N	N	N	-	V
4	N	N	C	I	V
5	N	C	C	I	V
	60	24	9	16	

- Il y a  $\frac{k(k-1)}{2}$  paires/scores à calculer pour chaque colonne

- SP pour Sum of Pairs, c'est la méthode la plus utilisée
- Somme des scores de toutes les paires d'a.a. possibles dans une colonne ( $p(-, -) = 0$ ), puis somme des scores des colonnes

$$SP(I, -, I, V) = p(I, -) + p(I, I) + p(I, V) + p(-, I) + p(-, V) + p(I, V)$$

- Exemple avec BLOSUM62 et indel=-2

$$p(N, N) = 6$$

$$p(N, C) = -3$$

$$p(C, C) = 9$$

$$p(I, I) = 4$$

$$p(I, -) = -2$$

$$p(V, V) = 4$$

1	N	N	N	I	V
2	N	N	N	I	V
3	N	N	N	-	V
4	N	N	C	I	V
5	N	C	C	I	V
	60	24	9	16	40

- Il y a  $\frac{k(k-1)}{2}$  paires/scores à calculer pour chaque colonne

- SP pour Sum of Pairs, c'est la méthode la plus utilisée
- Somme des scores de toutes les paires d'a.a. possibles dans une colonne ( $p(-, -) = 0$ ), puis somme des scores des colonnes

$$SP(I, -, I, V) = p(I, -) + p(I, I) + p(I, V) + p(-, I) + p(-, V) + p(I, V)$$

- Exemple avec BLOSUM62 et indel=-2

$$p(N, N) = 6$$

$$p(N, C) = -3$$

$$p(C, C) = 9$$

$$p(I, I) = 4$$

$$p(I, -) = -2$$

$$p(V, V) = 4$$

1	N	N	N	I	V	
2	N	N	N	I	V	
3	N	N	N	-	V	
4	N	N	C	I	V	
5	N	C	C	I	V	
	60	24	9	16	40	=

- Il y a  $\frac{k(k-1)}{2}$  paires/scores à calculer pour chaque colonne

- SP pour Sum of Pairs, c'est la méthode la plus utilisée
- Somme des scores de toutes les paires d'a.a. possibles dans une colonne ( $p(-, -) = 0$ ), puis somme des scores des colonnes

$$SP(I, -, I, V) = p(I, -) + p(I, I) + p(I, V) + p(-, I) + p(-, V) + p(I, V)$$

- Exemple avec BLOSUM62 et indel=-2

$$p(N, N) = 6$$

$$p(N, C) = -3$$

$$p(C, C) = 9$$

$$p(I, I) = 4$$

$$p(I, -) = -2$$

$$p(V, V) = 4$$

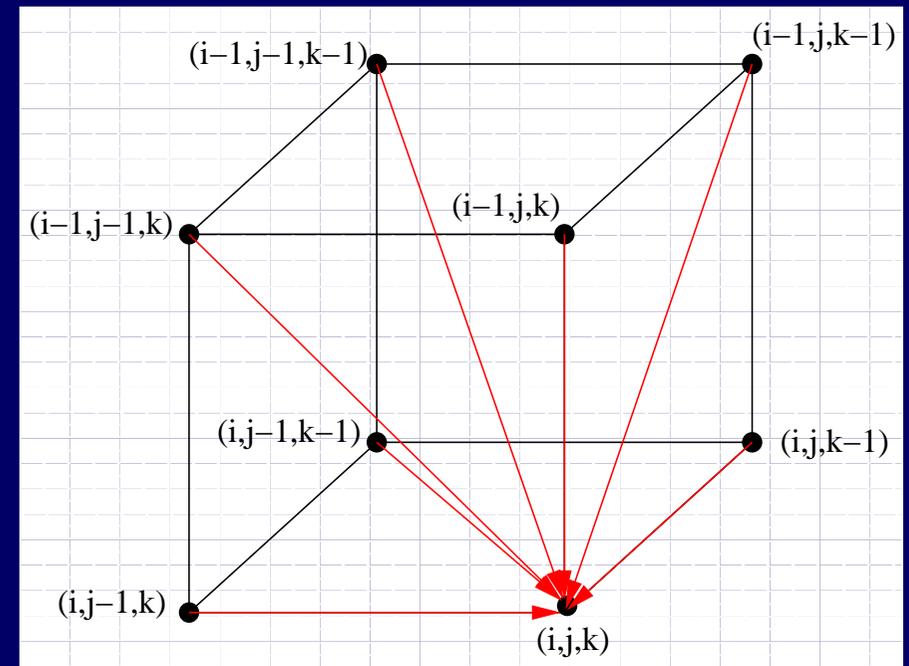
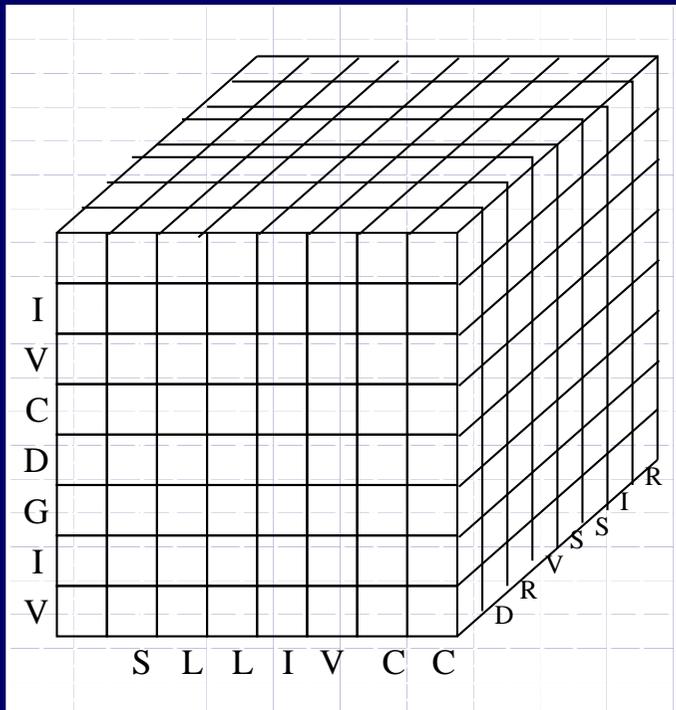
1	N	N	N	I	V	
2	N	N	N	I	V	
3	N	N	N	-	V	
4	N	N	C	I	V	
5	N	C	C	I	V	
	60	24	9	16	40	= 149

- Il y a  $\frac{k(k-1)}{2}$  paires/scores à calculer pour chaque colonne

- 
- Introduction
  - Méthodes de score
  - **Alignement multiple exact**
  - MSA Global
  - MSA Local
  - Éditeurs de MSA
  - Références

- Le principe de programmation dynamique est généralisable à  $k$  séquences de longueur  $n$
- Matrice  $\mathcal{A}$  de dimension  $n^k$
- $\mathcal{A}(i_1, i_2, \dots, i_k)$  contient le score d'alignement optimal entre les préfixes  $s_1[1..i_1], s_2[1..i_2], \dots, s_k[1..i_k]$
- Remplissage des  $O(n^k)$  cases la table  $\Rightarrow$  espace mémoire  $O(n^k)$
- Chaque entrée dépend de  $2^k - 1$  entrées déjà calculées
- Calculer le score SP requiert  $O(k^2)$  car il y a  $\frac{k(k-1)}{2}$  paires

Temps total d'exécution en  $O(k^2 2^k n^k)$



- 3 séquences :  $r$ ,  $s$  et  $t$ , méthode de score  $SP$  et  $g$  pénalité de gap
- $\mathcal{A}$  matrice de prog. dyn.

Initialisation :  $\mathcal{A}(0, 0, 0) = 0$  ;  $\mathcal{A}(i, 0, 0) = i \times 2g$  ;

$$\mathcal{A}(0, j, 0) = j \times 2g ; \mathcal{A}(0, 0, k) = k \times 2g.$$

$$\text{Remplissage : } \mathcal{A}(i, j, k) = \max \left\{ \begin{array}{l} \mathcal{A}(i-1, j-1, k-1) + SP(r_i, s_j, t_k) \\ \mathcal{A}(i, j-1, k-1) + SP(-, s_j, t_k) \\ \mathcal{A}(i-1, j, k-1) + SP(r_i, -, t_k) \\ \mathcal{A}(i-1, j-1, k) + SP(r_i, s_j, -) \\ \mathcal{A}(i, j, k-1) + SP(-, -, t_k) \\ \mathcal{A}(i, j-1, k) + SP(-, s_j, -) \\ \mathcal{A}(i-1, j, k) + SP(r_i, -, -) \end{array} \right.$$

- Méthode **guère plus complexe** pour  $k$  séquences que pour 2
- Facilement programmable
- Mais il est clair que le **temps de calcul** en  $O(k^2 2^k n^k)$  devient **prohibitif** quand  $k$  augmente
- **Illustration :**
  - 2 séquences de 100 a.a. → 1 sec.
  - 3 séquences de 100 a.a. → 10 min
  - 4 séquences de 100 a.a. → ~ 3 jours
  - à partir de 9 séq. le tps de calcul dépasse l'âge de l'univers ...

⇒ Mise au point d'**algorithmes heuristiques** performants et de bonne qualité (pb encore ouvert aujourd'hui)

- 
- Introduction
  - Méthodes de score
  - Alignement multiple exact
  - **MSA Global**
    - Alignement progressif (ex : CLUSTALW)
    - Alignement itératif (ex : DIALIGN)
    - Alignement structurel & hybride (ex : STAMP, MULTALIN et T-COFFEE)
  - MSA Local
  - Éditeurs de MSA
  - Références

- 
- Introduction
  - Méthodes de score
  - Alignement multiple exact
  - MSA Global
    - Alignement progressif (ex : CLUSTALW)
    - Alignement itératif (ex : DIALIGN)
    - Alignement structurel & hybride (ex : STAMP, MULTALIN et T-COFFEE)
  - MSA Local
  - Éditeurs de MSA
  - Références

- Difficile d'aligner **simultanément**  $k$  séquences  $\Rightarrow$  on les aligne **progressivement** en commençant par les plus proches  
 $\rightarrow$  on aligne alors d'autres séquences avec ces premiers alignements
- Les alignement intermédiaires sont appelés « **profils** »
- À chaque étape on n'aligne que 2 éléments : séquence/séquence, séquence/profil ou profil/profil
- Utilise la **prog. dyn.** pour évaluer la similarité entre les séquences  
 $\Rightarrow$  création d'un **arbre évolutif** qui sert de **guide**
- Propriété de cette méthode : toute création d'un trou est **définitive**  
« *once a gap, ever a gap* »

- Programme original CLUSTAL utilisé depuis 1988, régulièrement amélioré depuis [Higgins & Sharp, 88]
- CLUSTALW ([Thompson *et al*, 94]) est la version la plus récente, W pour *Weighting*; les séquences et les paramètres sont pondérés
- Fonctionnalités : ajout d'une séq. ou d'un ali. à un ali. déjà fait, production d'un arbre phylogénétique, paramètre *slow/fast*, ...
- Méthode
  1. Construction de la matrice des  $\frac{k(k-1)}{2}$  distances
  2. Logiciel de reconstruction phylogénétique  $\Rightarrow$  arbre
  3. Alignement progressif suivant cet arbre
- Complexité pour  $k$  séquences de longueur  $n$  :  $O(kn^2)$

- Pondération des séquences :

Une séquence **similaire** à d'autres dans le groupe a un **poids faible**, alors qu'une séquence **moins proche** des autres a un **poids plus fort**

⇒ On diminue ainsi le poids des groupes de séquences similaires et privilégie les changements dans l'arbre évolutif

- Pénalité de gap :

CLUSTALW pénalise les gaps de manière à les placer entre les domaines conservés (utilise une matrice spéciale et  $\neq$  pénalités suivant les régions)

Méthode de score de CLUSTALW  $\neq$  SP-score

EMBL-EBI
EB-eye Search
All Databases

Go
Reset ?  
Advanced Search
Give us feedback

Databases
Tools
EBI Groups
Training
Industry
About Us
Help

- Help Index
- General Help
- Formats
- Gaps
- Matrix
- References
- ClustalW Help
- ClustalW FAQ
- Jalview Help
- Scores Table
- Alignment
- Guide Tree
- Colours

---

- Similar Applications
- Align
- Kalign
- MAFFT
- MUSCLE
- T-Coffee

---

- ClustalW Programmatic Access

EBI > Tools > Sequence Analysis > ClustalW

## ClustalW

ClustalW is a general purpose multiple sequence alignment program for DNA or proteins. It produces biologically meaningful multiple sequence alignments of divergent sequences. It calculates the best match for the selected sequences, and lines them up so that the identities, similarities and differences can be seen. Evolutionary relationships can be seen via viewing Cladograms or Phylograms.

New users, please read the FAQ.

>> Download Software

YOUR EMAIL	ALIGNMENT TITLE	RESULTS	ALIGNMENT	
<input style="width: 100%;" type="text"/>	<input style="width: 100%;" type="text" value="Sequence"/>	<input style="width: 100%;" type="text" value="interactive"/>	<input style="width: 100%;" type="text" value="full"/>	
KTUP (WORD SIZE)	WINDOW LENGTH	SCORE TYPE	TOPDIAG	PAIRGAP
<input style="width: 100%;" type="text" value="def"/>	<input style="width: 100%;" type="text" value="def"/>	<input style="width: 100%;" type="text" value="percent"/>	<input style="width: 100%;" type="text" value="def"/>	<input style="width: 100%;" type="text" value="def"/>
MATRIX	GAP OPEN	END GAPS	GAP EXTENSION	GAP DISTANCES
<input style="width: 100%;" type="text" value="def"/>	<input style="width: 100%;" type="text" value="def"/>	<input style="width: 100%;" type="text" value="def"/>	<input style="width: 100%;" type="text" value="def"/>	<input style="width: 100%;" type="text" value="def"/>
OUTPUT		PHYLOGENETIC TREE		
OUTPUT FORMAT	OUTPUT ORDER	TREE TYPE	CORRECT DIST.	IGNORE GAPS
<input style="width: 100%;" type="text" value="aln w/numbers"/>	<input style="width: 100%;" type="text" value="aligned"/>	<input style="width: 100%;" type="text" value="none"/>	<input style="width: 100%;" type="text" value="off"/>	<input style="width: 100%;" type="text" value="off"/>

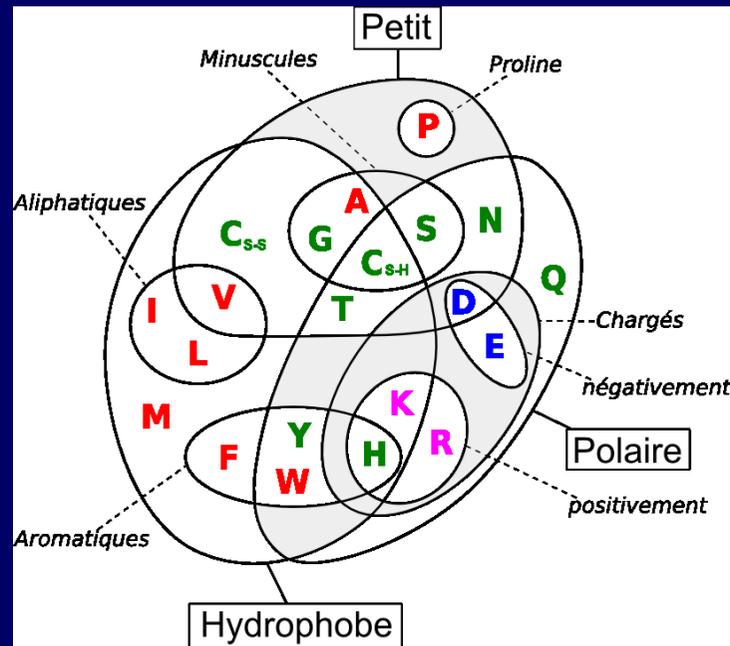
Enter or Paste a set of Sequences in any supported format: Help

Upload a file: 
Parcourir...
Run
Reset

```

uniprot_MYH6_MESAU      EEDKKNLVRLQDLVDKLLKVKAYKRAEEAEEQANTNLSKFRKVQHELDEAEERADIAE 1916
uniprot_MYH6_RAT       EEDKKNLVRLQDLVDKLLKVKAYKRAEEAEEQANTNLSKFRKVQHELDEAEERADIAE 1915
uniprot_MYH6_MOUSE     EEDKKNLMRLQDLVDKLLKVKAYKRAEEAEEQANTNLSKFRKVQHELDEAEERADIAE 1916
uniprot_MYH6_HUMAN     EEDKKNLLRLQDLVDKLLKVKAYKRAEEAEEQANTNLSKFRKVQHELDEAEERADIAE 1916
uniprot_MYH7_HUMAN     EEDRKNLLRLQDLVDKLLKVKAYKRAEEAEEQANTNLSKFRKVQHELDEAEERADIAE 1914
uniprot_MYH7_MESAU     EEDRKNLLRLQDLVDKLLKVKAYKRAEEAEEQANTNLSKFRKVQHELDEAEERADIAE 1913
uniprot_MYH1_HUMAN     EEDRKNILRLQDLVDKLLQAKVKSYSKRAEEAEEQSNVNLKFRRIQHELEEAERADIAE 1918
uniprot_MYH4_RABIT     EEDRKNVLRQLDLVDKLLQAKVKSYSKRAEEAEEQCNINLSKFRKLQHELEEAERADIAE 1917
uniprot_MYH2_HUMAN     EEDRKNILRLQDLVDKLLQAKVKSYSKRAEEAEEQSNVNLAKFRKLQHELEEAERADIAE 1920
uniprot_MYH4_HUMAN     EEDRKNILRLQDLVDKLLQAKVKSYSKRAEEAEEQSNVNLAKFRKLQHELEEAERADIAE 1918
uniprot_MYH3_CHICK     EEDRKNVLRQLDLVDKLLQMKVKSYSKRAEEAEEQSNVNLKFRKIQHELEEAERADIAE 1919
uniprot_MYH3_HUMAN     EEDRKNVLRQLDLVDKLLQVKVKSYSKRAEEADEQANAHLTKFRKAQHELEEAERADIAE 1915
uniprot_MYH3_RAT       EEDRKNVLRQLDLVDKLLQVKVKSYSKRAEEADEQANVHLTKFRKAQHELEEAERADIAE 1915
uniprot_MYH3_MOUSE     EEAXKNVLRQLDLVDKLLQVKVKSYSKRAEEADEQANAHLTKFRKAQHELE----- 159
**  **::*****:*****:* .* :*:***: *****:
    
```

- CLUSTALW affiche par défaut les symboles suivants pour indiquer la **degrés de conservation** dans chaque colonne :
  - \* caractère identique dans toute la colonne
  - : substitutions conservatives (suivant la table des couleurs)
  - . substitutions semi-conservatives



A.A.	Couleur	Description
AVFPMILW	Rouge	Petits (petits + hydrophobes (incl. aromatiques -Y))
DE	Bleu	Acides
RK	Magenta	Basiques - H
STYHCNGQ	Vert	Hydroxyl + sulfhydryl + amine + G
Autres	Gris	Unusual amino/imino acids ...

- Un autre type d'alignement progressif : l'alignement étoile
- Principe : alignement 2 à 2 entre une séquence fixée (le centre de l'étoile) et toutes les autres séquences
- Méthode :
  1. Choisir la séquence centre  $s_c$
  2. Alignement optimal entre toutes les  $s_i$  pour  $i \neq c$  et  $s_c$
  3. Agrégation des alignements avec la technique « *Once a gap, always a gap* »,  $s_c$  est utilisée comme guide
- Procédure en  $O(kn^2 + k^2l)$

- 
- Introduction
  - Méthodes de score
  - Alignement multiple exact
  - MSA Global
    - Alignement progressif (ex : CLUSTALW)
    - **Alignement itératif (ex : DIALIGN)**
    - Alignement structurel & hybride (ex : STAMP, MULTALIN et T-COFFEE)
  - MSA Local
  - Éditeurs de MSA
  - Références

- 
- Le pb majeur avec l'alignement progressif est qu'une erreur faite au début de l'alignement ne peut être corrigée par la suite
  - Les méthodes itératives tentent de pallier ce pb en réalignant des sous-groupes de séquences de manière répétée puis en alignant ces sous-groupes dans l'alignement global de toutes les séquences
  - L'objectif est d'améliorer le score d'alignement global
  - La sélection de ces sous-groupes peut se faire sur la base d'un arbre phylogénétique (prédit de manière similaire aux méth. prog.), ou la séparation d'une à deux séquences du reste, ou de manière aléatoire

- 
- DIALIGN 2.2.1 (oct. 2007) [Morgenstern, 2004]
  - Spécialité : se base sur des similarités locales pour aligner des séquences très divergentes ou de longueur différentes
  - Méthode :
    1. Repérer les régions alignées sans gaps dans les alignements 2 à 2 (~ diagonales continues dans un dotplot)
    2. Cherche un ensemble compatibles de diagonales pondérées pouvant produire un ali. et maximisant la somme des poids
    3. DIALIGN produit un alignement à partir de ces diagonales
  - Disponible sur <http://bibiserv.techfak.uni-bielefeld.de/dialign/>

The screenshot shows the DIALIGN web interface. At the top, there is a 'Sequence Mode' dropdown menu set to 'none (Protein/DNA)'. Below this, there are two options for uploading sequences: 'Upload a set of sequences (in FASTA or other formats):' with a text input field and a 'Parcourir...' button, and 'or copy/paste a set of sequences (in FASTA or other formats):' with a larger text area. At the bottom of the form, there are two dropdown menus: 'threshold T:' set to 'T = 0' and 'Regions of maximum similarity' set to '5'. At the very bottom, there are three buttons: 'Submit', 'example', and 'Reset'.

- Schéma de score dans DIALIGN : score de l'ali = somme des scores des diagonales qui le composent ⇒ pas de pénalités de gap
- Paramètres particuliers :
  - Seuil  $T$  → permet de ne considérer que les diagonales de score supérieur à  $T$  (nécessaire dans la V1)
  - Régions de similarité maximale → donne le nb max de caractères '\*' utilisés pour représenter la similarité locale sous chaque col.



- 
- Introduction
  - Méthodes de score
  - Alignement multiple exact
  - MSA Global
    - Alignement progressif (ex : CLUSTALW)
    - Alignement itératif (ex : DIALIGN)
    - Alignement structurel & hybride (ex : STAMP, MULTALIN et T-COFFEE)
  - MSA Local
  - Éditeurs de MSA
  - Références

- Lorsqu'on dispose de structures 3D, on peut comparer des protéines en les **superposant**
- Mais il faut connaître **quels sont les a.a. qui se correspondent**
- C'est le but des méthodes d'alignement multiple structurel
  - Alignement structurel des séquences
  - Superposition 3D de leur structure
- Logiciels, pour 2 ou plusieurs protéines : **SSAP, DALI, STAMP, ...**
- Méthode de STAMP
  1. **Alignement structurel** de 2 séquences
  2. Les structures sont superposées selon cet alignement
  3. Calcul d'une **matrice de scores de similarité structurelle**
  4. Prog. dyn. sur cette matrice pour trouver meilleur score & ali.
  5. Étant donné l'alignement on recommence jusqu'à convergence

Si **plusieurs séquences**, toutes les paires de structures sont comparées et un **arbre est calculé**, et on le suit comme pour un **alignement progressif**

- Programme de Florence Corpet de l'INRA Toulouse [Corpet, 88]
- Alignement multiple avec **clustering hiérarchique**
- Principe similaire à CLUSTAL mais pas d'évolution depuis 2000
- **Méthode** :
  1. **Initialisation** : tous les ali. 2 à 2 sont faits et on garde leur score
  2. **Clustering hiérarchique** des séquences à partir de ces scores
  3. Alignements selon cet **arbre hiérarchique** → ali. complet
  4. L'alignement est montré et on calcule son **score SP** (et donc le score de chaque paire de séquences alignées)
  5. Nouveau clustering hiérarchique avec ces nouveaux scores
  6. Si le nouveau clustering est différent du 1er, on peut recommencer (pas 3.) jusqu'à ce que ce soit stable

# MultiAlin

## Multiple sequence alignment by Florence Corpet

Published research using this software should cite:  
"Multiple sequence alignment with hierarchical clustering"  
F. CORPET, 1988, Nucl. Acids Res., 16 (22), 10881-10890



### ● Sequence data

Cut and paste your sequences here below. 

[\(sample sequences\)](#)

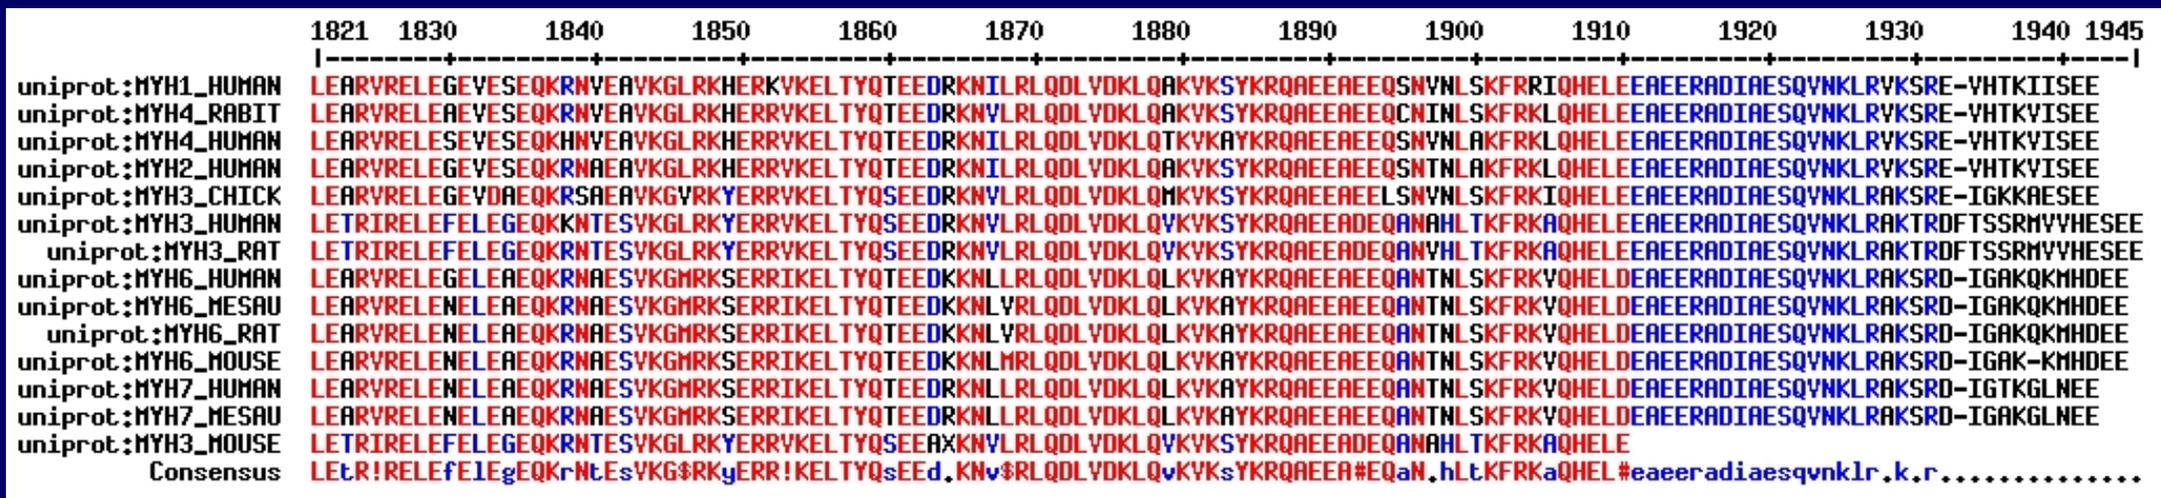
or select a file:  Parcourir... 

● Sequence input format: Auto

● For nucleotidic sequences, you must change the Symbol comparison Table (see below) 

Start MultiAlin !

Clear Entire Form



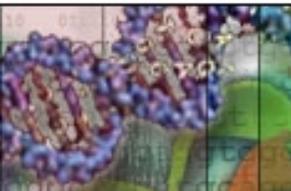
- Plusieurs formats d'entrée et de sortie disponibles
- Code couleur suivant le degrés de consensus de la colonne :
  - Rouge → fort consensus, lettre majuscule
  - Bleu → faible consensus, lettre minuscule
  - Noir → neutre, pas de caractère reporté
- Possibilité de modification des paramètres de la méthode et en particulier de ceux d'affichage

- T-COFFEE V5.05 (2007), [Notredame et al, 2000]
- Méthode :
  1. Construction d'une bibliothèque d'alignement 2 à 2, **globaux et locaux**, pour chaque paire de séquences du jeu d'entrée
  2. Phase de "scorage" pour donner un poids aux alignements puis aux caractères alignés (« *library extension* »)
  3. Cette bibliothèque est ensuite utilisée pour **guider** une phase d'alignement progressif pour trouver un **MSA** préservant la **consistance des alignements 2 à 2**
- Produit de **meilleurs alignements** mais encore **trop lent** pour de gros jeux de séquences
- **Originalité** : permet de combiner des résultats de CLUSTALW, DIALIGN et d'un alignement structural par exemple

## Swiss Institute of Bioinformatics

Institut Suisse de Bioinformatique  
Schweizerisches Institut für Bioinformatik







[HOME](#) | [references](#) | [help](#) | 

# TCoffee

A collection of tools for Computing, Evaluating and Manipulating Multiple Alignments of DNA, Protein Sequences and Structures

*Mirror sites:*       

ALIGNMENT				
TCOFFEE	<input type="button" value="Regular"/>	<input type="button" value="Advanced"/>	<a href="#">cite</a>	<a href="#">?</a>
EXPRESSO(3DCoffee)	<input type="button" value="Regular"/>	<input type="button" value="Advanced"/>	<a href="#">cite</a>	<a href="#">?</a>
MCOFFEE	<input type="button" value="Regular"/>	<input type="button" value="Advanced"/>	<a href="#">cite</a>	<a href="#">?</a>
COMBINE	<input type="button" value="Regular"/>	<input type="button" value="Advanced"/>	<a href="#">cite</a>	<a href="#">?</a>

```

*
BAD AVG GOOD
*
uniprot MYH3 CH : 86
uniprot MYH3 MO : 39
uniprot MYH7 HU : 87
uniprot MYH7 ME : 87
uniprot MYH6 ME : 87
uniprot MYH6 MO : 87
uniprot MYH6 HU : 87
uniprot MYH6 RA : 87
uniprot MYH1 HU : 86
uniprot MYH2 HU : 85
uniprot MYH3 HU : 85
uniprot MYH3 RA : 85
uniprot MYH4 HU : 86
uniprot MYH4 RA : 86
    
```

```

uniprot MYH3 CH AEELSNVNLSKFRKIQHELEEEAEERADIAESQVNKLRAKSREIGK
uniprot MYH3 MO ADEQANAHLTKFRKAQHELE-----
uniprot MYH7 HU AEEQANTNLSKFRKVQHELDEAEERADIAESQVNKLRAKSRDIGT
uniprot MYH7 ME AEEQANTNLSKFRKVQHELDEAEERADIAESQVNKLRAKSRDIGA
uniprot MYH6 ME AEEQANTNLSKFRKVQHELDEAEERADIAESQVNKLRAKSRDIGA
uniprot MYH6 MO AEEQANTNLSKFRKVQHELDEAEERADIAESQVNKLRAKSRDIGA
uniprot MYH6 HU AEEQANTNLSKFRKVQHELDEAEERADIAESQVNKLRAKSRDIGA
uniprot MYH6 RA AEEQANTNLSKFRKVQHELDEAEERADIAESQVNKLRAKSRDIGA
uniprot MYH1 HU AEEQSNVNLSKFRRIQHELEEEAEERADIAESQVNKL RVKSREVHT
uniprot MYH2 HU AEEQSNNTNLAKFRKLQHELEEEAEERADIAESQVNKL RVKSREVHT
uniprot MYH3 HU ADEQANAHLTKFRKAQHELEEEAEERADIAESQVNKLRAKTRDFTS
uniprot MYH3 RA ADEQANVHLTKFRKAQHELEEEAEERADIAESQVNKLRAKTRDFTS
uniprot MYH4 HU AEEQSNVNLSKFRKLQHELEEEAEERADIAESQVNKL RVKSREVHT
uniprot MYH4 RA AEEQCNINLSKFRKLQHELEEEAEERADIAESQVNKL RVKSREVHT

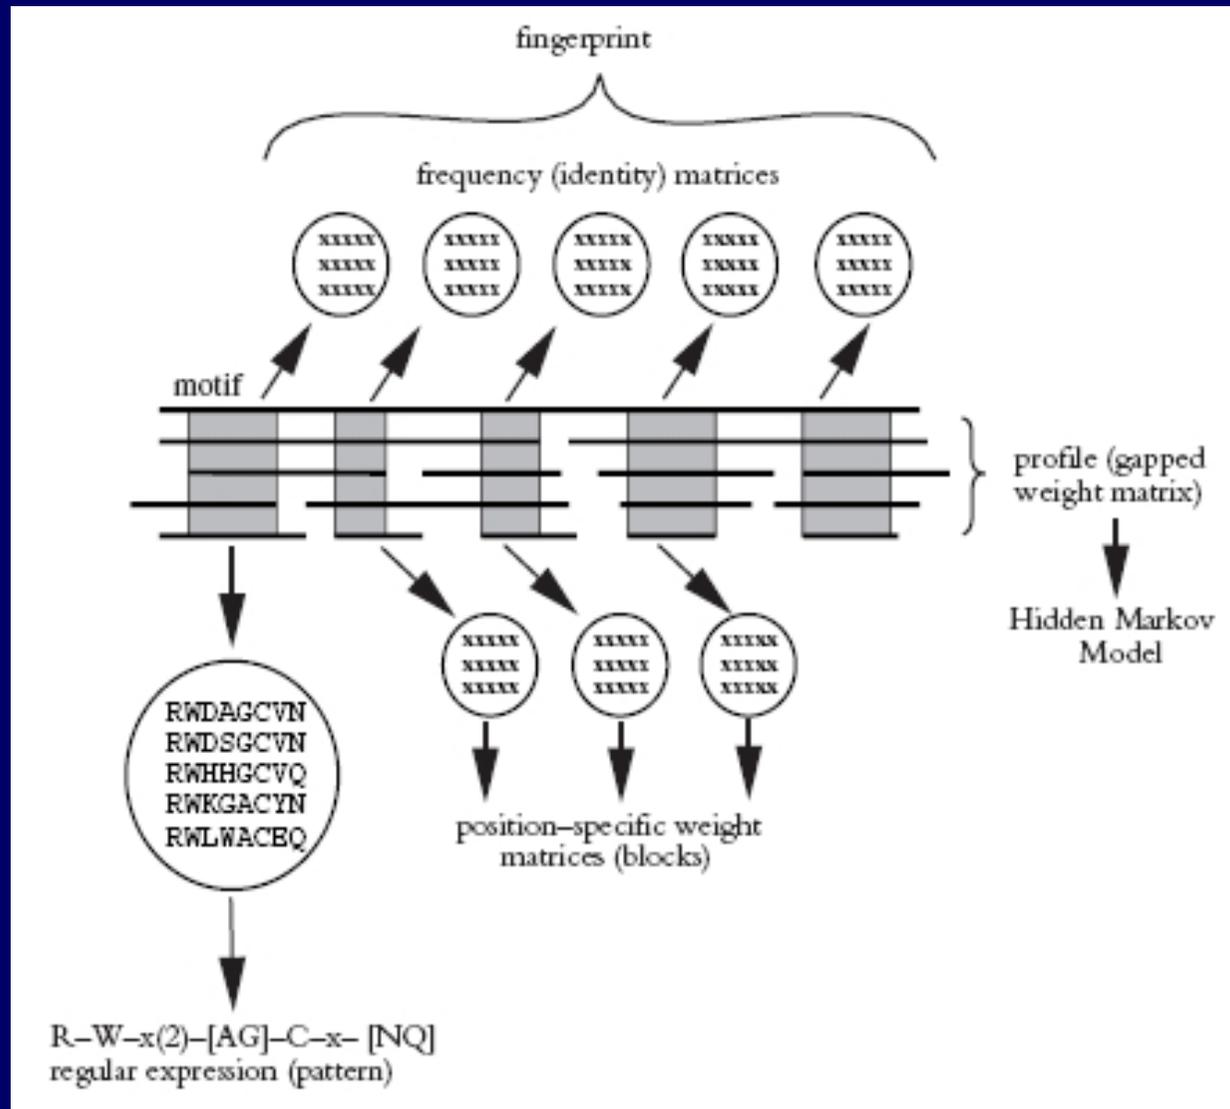
cons *: * . * : * : * * * : * * * * :
    
```

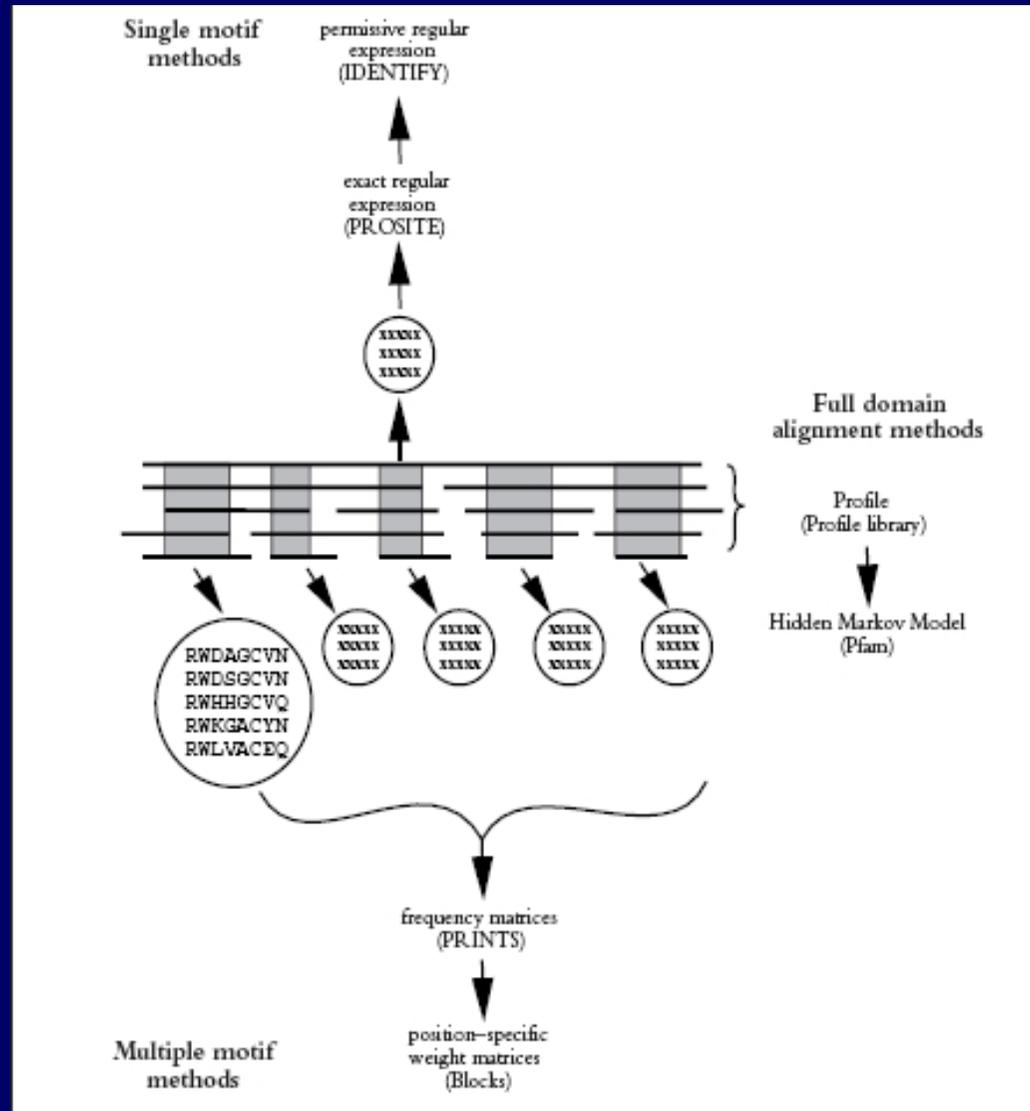
- Les parties oranges et rouges sont considérées comme bien alignées
- Plusieurs formats de sortie : .aln (CLUSTALW), FASTA, PHYLIP et T-COFFEE ci-dessus
- + 2 formats d'arbres

- Les MSA peuvent servir à faire des recherches plus sensibles dans les banques de données qu'en utilisant 1 seule seq. requête
  - Rappel du fonctionnement de PSI-BLAST
    1. On cherche des séquences similaires à la requête
    2. Construction d'un profil ou PSSM
    3. (en boucle) On cherche avec ce profil et on y intègre les nouvelles séquences trouvées
    4. Fin qd l'ensemble de seq. est stable ou le nb max d'itérations est dépassée
  - PSI-BLAST fournit des alignement multiples différents de ceux obtenus avec les outils classiques
- Normalement les MSA sont plus long que les séquences qu'ils contiennent mais PSI-BLAST supprime les régions qui nécessiteraient d'introduire des gap dans la seq. requête

- 
- Introduction
  - Méthodes de score
  - Alignement multiple exact
  - MSA Global
  - **MSA Local**
    - Méthodes à motif unique
    - Méthodes à alignement complet de domaines
    - Méthodes à plusieurs motifs
  - Éditeurs de MSA
  - Références

- 
- Les méthodes de MSA décrites précédemment produisent un alignement global des séquences
    - Bon point de départ pour les analyses phylogénétiques
  - Les méthodes de MSA locaux alignent les régions les plus similaires des séquences, ignorant les régions dissimilaires
  - La production d'un MSA local peut se faire soit
    1. en utilisant des méthodes d'alignements multiple local
    2. en partant d'un MSA global et en sélectionnant les régions les plus conservées
  - Il existe de nombreuses banques de familles de séquences protéiques basées sur le partage d'une caractéristique commune





- 
- Introduction
  - Méthodes de score
  - Alignement multiple exact
  - MSA Global
  - MSA Local
    - Méthodes à motif unique
    - Méthodes à alignement complet de domaines
    - Méthodes à plusieurs motifs
  - Éditeurs de MSA
  - Références

- La nature réutilise souvent un même élément de séquence pour réaliser des fonctions analogues
- Ces éléments conservés se structurent généralement en domaines indépendants dans les protéines et prennent en charge une des tâches de la protéine : liaison à l'ADN ou à l'ARN, fixation d'un ligand, activité enzymatique, ...
- Un gd nb de domaines sont répertoriés dans des bq spécialisées  
→ Ex : PRODOM, INRA Toulouse, ~ 50000 domaines communs à au moins 2 protéines, lg moy 100 a.a.
- Alignement systématique de ces domaines ⇒ identification de motifs caractéristiques

- Il existe des positions (d'un MSA) où l'on trouve toujours un même a.a. ou bien des a.a. similaires (F, Y aromatiques), elles constituent une **signature caractéristique** de la famille de domaines homologues
- On peut donc vouloir chercher des motifs défini de la manière suivante :  
F ou Y, suivi d'un a.a. qcq, suivi de C, suivi de 5 a.a. qcq, suivi de C
- Même motif mais en syntaxe PROSITE : `[FY]-X-C-X(5)-C`
- On appelle ce formalisme **expressions régulières**, *regex* en anglais

- Utilisation du code standard des protéines (**IUPAC**)
- La lettre **X** est utilisée pour identifier une position qui peut accepter **n'importe quel résidu**
- Les positions qui peuvent accepter **plrs résidus** sont indiquées par des **[]** qui renferment les résidus acceptables, ex : **[GTS]**
- Les **résidus polymorphes** sont indiqués par des **{ }** qui indiquent quels résidus sont impossibles
- Chaque indication de contenu est **séparée** de la suivante par un **-**, ex : **A-T-X-T-X-X-[GTS]**
- Les **répétitions** de positions ayant un contenu identique sont indiquées de la manière suivante :  
**A-A-A** → **A(3)** ; **T-T** → **T(2)** ; **[AT](2)** → **A-A** ou **A-T** ou **T-A** ou **T-T**  
**X(1,3)** signifie que les alternatives **X**, **X-X** ou **X-X-X** sont possibles

- **PROSITE** est une base de données où chaque entrée décrit des domaines de protéines, des familles ou des sites fonctionnels ainsi que les motifs et profils associés
- PROSITE contient plus de 1400 motifs documentés
- Consensus PROSITE pour “Zinc finger C2H2-type”

ABC3G_LAGLA/285-305	Cfs..CaekVaeflqenpHvn1..H
ABRU_DROME/546-567	Cpk..CgkiYrsahtlrthledk.H
ACE1_TRIRE/402-424	CrepgCtkeFkrpcdltkHekt..H
ACE2_SCHPO/445-467	ClyngCnkrIarkynvesHiqt..H
ACE2_SCHPO/475-495	Cdl..CkagFvrhhdldkrHlri..H
ACE2_YEAST/605-627	ClypnCnkvFkrrynirsHiqt..H
ACE2_YEAST/635-657	CdfpgCtkaFvrnhdlirHkis..H
ADNP_HUMAN/514-535	Cpy..CrstFndvekmaaHrmv.H
ADNP_MOUSE/233-254	Cpy..CrstFndvekmaaHrmv.H

...

C - X(2,4) - C - X(3) - [LIVMFYWC] - X(8) - H - X(3,5) - H

- **Avantage :**

- Des algorithmes de recherche de motifs très puissants existent (domaine *pattern matching* en informatique)
- Les expressions régulières permettent un codage simple du motif
- Les méthodes qui cherchent des motifs pointent vers des courtes régions conservées qui peuvent représenter des fonctions biologiques

- **Inconvénients :**

- **Manque de souplesse** : « *matche* ou *ne matche pas* », pas de mesure de similarité
- **N'autorisent pas les gaps**
- Souvent il n'y a pas d'analyse de la significativité du motif
- Si la famille de protéines a plrs régions conservées, laquelle choisir ?

- *Fuzzy regex* en anglais
- Permet de relâcher les contraintes en autorisant les substitutions d'a.a. de même groupe
- Ces groupes sont définis sur la base des partages de propriétés physico-chimiques (cf. diagramme de Venn p. 22)

Petits	A G
Petits hydroxyle	S T
Basiques	K R
Aromatiques	F Y W
Basiques	H K R
Petits hydrophobes	V L I
Moyens hydrophobes	V L I M
Acides/Amides	D E N Q
Petits/polaires	A C G S T P

- Ex : motif [AS]-D-[IVL]-G-X(4)-PG-C-[DE]-R-[FY](2)-Q  
→ Motif flou dérivé [ASCGPT]-D-[IVLM]-G-X(4)-PG-C-[DE]-R-[FYW](2)-Q
- Permet d'identifier des prot. assez éloignées mais augmente le bruit
- Banque de donnée eMOTIF

- 
- Introduction
  - Méthodes de score
  - Alignement multiple exact
  - MSA Global
  - MSA Local
    - Méthodes à motif unique
    - **Méthodes à alignement complet de domaines**
    - Méthodes à plusieurs motifs
  - Éditeurs de MSA
  - Références

- 
- Les profils sont construits à partir d'un MSA global des séquences, en extrayant les **régions les plus conservées**, donnant ainsi un MSA de plus petite taille
  - Une **matrice de scores** pour ce MSA est alors calculée, on l'appelle **profil** (*profile* en anglais)
  - Un profil est composé de colonnes contenant les scores pour les *matches*, les *mismatches* et les pénalités de gap
  - Une fois calculé, le profil peut être utilisé pour chercher une séquence cible

- 
- Les profils sont similaires aux matrices de scores (**PSSM**)
  - Un profil est une matrice de 23 colonnes : une pour chaque a.a., plus une colonne pour un a.a. inconnu 'Z' et 2 colonnes pour les pénalités d'ouverture et d'extension de gap
  - Le profil a autant de lignes que le MSA a de colonnes
  - Une séquence consensus est indiquée verticalement à la gauche du tableau, elle représente les a.a. les plus fréquents à chaque position
  - Les scores reflètent le nb d'occurrences de chaque a.a. dans les séquences alignées

```

BIRC6_HUMAN  RRLAQEAVTLST.....S.....LPLSSSSSVFVRCde.....eRLDIMKVLITGP...ADTPY
COP10_ARATH  KRIQREMAELNI.....D.....PPPDCSAGPKGD-.....NLYHWIATIIGP...SGTPY
FTS1_HUMAN   YSLLAEFTLVVK.....Q.....KLPGVYVQPSYRS.....ALMWFGVIFI--...RHGLY
FTS1_MOUSE   YSLLAEFTLVVK.....Q.....KLPGVYVQPSYRS.....ALVWFGVIFI--...RHGLY
MMS2_SCHPO   FKLLEELEKGEKg1..gE.....SSCSYGLTNADDI.....TlSDWNATILGP...AHSVH
MMS2_YEAST   FRLLEELEKGEK.....Gf.....GPESCSYGLADSDd.....itTMTKWNGTILGP...PHSNH

```

...

	A	B	C	D	E	F	G	H	I	K	L	M	N	P	Q	R	S	T	V	W
'R'	-10	-6	-25	-9	-2	-13	-19	-7	-16	16	-14	-6	-1	-17	1	18	-6	-4	-13	-20
'R'	-15	-12	-26	-13	-4	-13	-20	-5	-21	16	-10	-6	-4	-20	3	47	-9	-6	-14	-21
'L'	-9	-28	-22	-30	-20	4	-32	-22	25	-26	35	17	-26	-26	-19	-20	-24	-9	16	-21
'M'	-7	-14	-20	-19	-8	-8	-23	-7	0	-5	6	14	-13	-19	5	-3	-13	-7	-4	-19
'K'	-7	-2	-28	-1	13	-27	-19	-7	-27	33	-24	-10	-2	-11	11	26	-7	-9	-20	-20
'E'	-12	15	-30	26	50	-32	-18	1	-31	8	-22	-20	3	-2	21	-1	0	-10	-30	-31
'L'	-10	-25	-21	-28	-20	17	-28	-16	10	-19	22	9	-22	-27	-19	-12	-20	-7	7	-12

...

- Les profils sont **très liés** aux MSA globaux dont ils sont extraits (reflet de la variation dans les séquences)
- Si il y a beaucoup de séquences similaires, le MSA et le profil déduit seront **biaisés** en faveur de ces séquences
- Diverses corrections dont pondération des séquences
- **Autre problème** : des a.a. peuvent de pas être représentés dans certaines colonnes à cause d'un trop petit nb de seq. incluses

- Deux méthodes sont principalement utilisées pour construire des profils
  - Méthode **moyenne** : les scores du profil sont pondérés par la proportion de chaque a.a. dans chaque colonne (ex **MEME**)
  - Méthode **évolutive** : basée sur le modèle d'évolution de protéine de Dayoff, elle suppose différentes vitesses d'évolution pour chaque colonne du MSA
- **Évaluation de profils** : le "**ROC plot**" mesure la précision d'un profil pour discriminer entre les membres ou non-membres d'une famille de protéines lors d'une recherche de similarité dans les banques

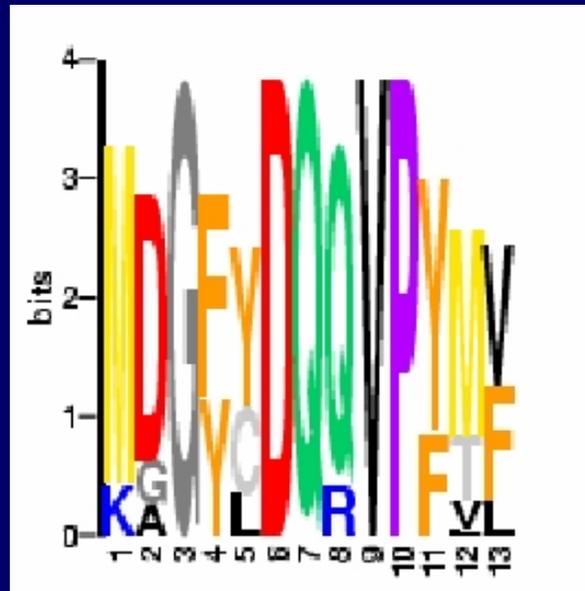
- 
- Introduction
  - Méthodes de score
  - Alignement multiple exact
  - MSA Global
  - MSA Local
    - Méthodes à motif unique
    - Méthodes à alignement complet de domaines
    - **Méthodes à plusieurs motifs**
  - Éditeurs de MSA
  - Références

- 
- Comme les profils, les blocs représentent les **régions conservées** dans un MSA global
  - Les blocs produits de cette manière sont aussi bon (*ou moins bon*) que le MSA dont ils sont issus
  - Les blocs sont différents des profils car **ils n'autorisent pas les indels**
  - Les blocs peuvent être constitués de plusieurs régions similaires mais non adjacentes
  - Le motif trouvé dans chaque séquence est de **même lg**, et qd les séq. sont alignées, les caractères sont dans les mêmes colonnes
  - Le serveur **BLOCKS** fournit des outils pour extraire des blocs de 10 à 55 a.a. provenant de MSA jusqu'à 400 séquences

## Block IPB006715A

ETV5_HUMAN P41161	( 1)	MDGFYDQQVPFMV	35
ETV1_HUMAN P50549	( 1)	MDGFYDQQVPYMV	33
ETV1_MOUSE P41164	( 1)	MDGFYDQQVPYVV	37
ETV4_HUMAN P43268	( 73)	KAGYLDQQVPYTF	77
ETV4_MOUSE P28322	( 81)	KGGYLDQRVPYTF	100
PEA3_BRARE Q9PUQ1	( 5)	MDGYLDQQVPYTL	50

...



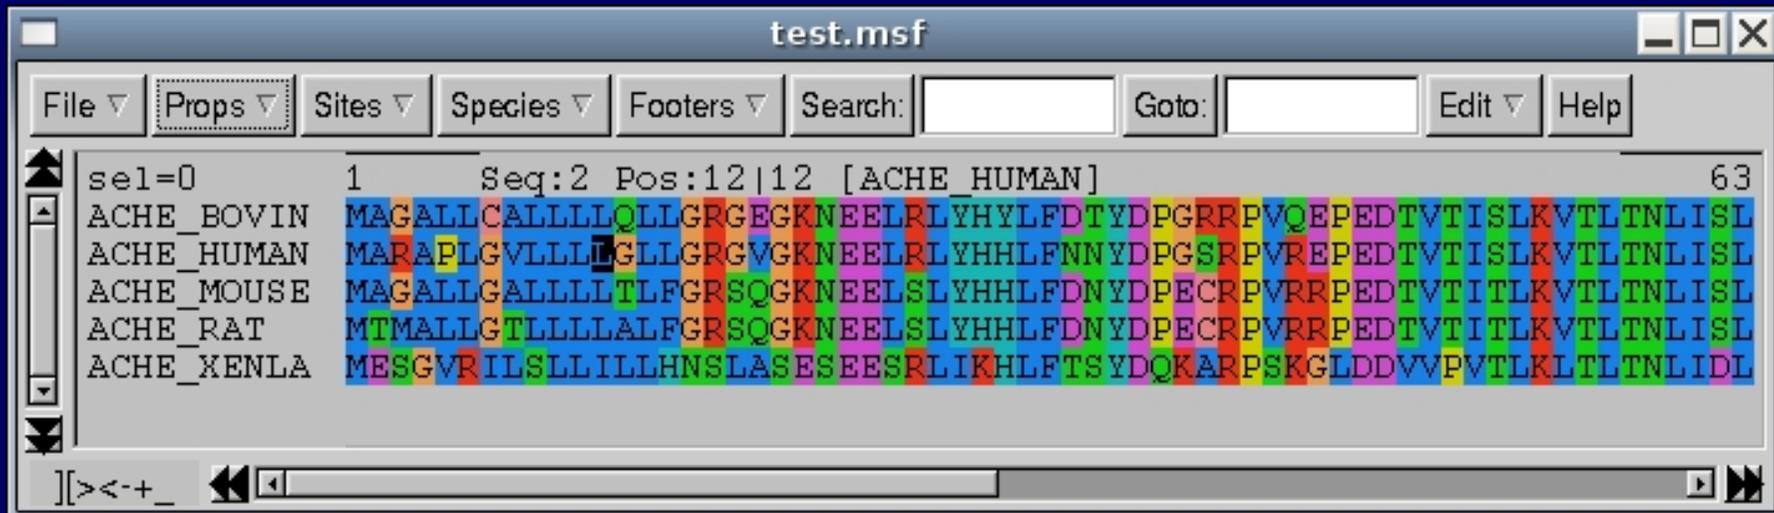
- Les empreintes ou *fingerprints* sont une autre représentation de plusieurs domaines conservés dans le MSA
- Les empreintes sont des matrices de comptage d'a.a. **non pondérées**
- Ces matrices sont donc **creuses** : la plupart des cases contenant 0
- L'utilisation de ces matrices brutes est plutôt rare
- On construit donc des empreintes par **itérations successives** sur les banques Swiss-Prot et TrEMBL pour qu'elles contiennent plus de variabilité
- Banque de données **PRINTS** (Version 38.0) contient **1900** empreintes, encodant **11170** motifs

- 
- Les méthodes que l'on vient de voir utilisent un **MSA global** comme **point de départ** et tentent de localiser les régions conservées
  - Une **alternative** est de chercher les motifs conservés en faisant des alignements "tests" et ensuite d'améliorer ces alignements en utilisant des **méthodes statistiques**
  - **Plusieurs méthodes** regroupées sous ce terme : algorithmes EM (*Expectation Maximisation*), Gibbs Sampler, les modèles de Markov cachés (HMM), ...
  - Les **matrices de scores** produites par ces méthodes peuvent être utilisées pour la recherche de séquences présentant le même motif

- Introduction
- Méthodes de score
- Alignement multiple exact
- MSA Global
- MSA Local
- Éditeurs de MSA
- Références

- Une fois qu'on a obtenu un MSA global, il peut être intéressant d'**éditer** les séquences **manuellement** pour obtenir un *meilleur* alignement
- Un “bon” éditeur de séquences devrait avoir au moins les caractéristiques suivantes :
  - Prendre en compte l'affichage coloré du MSA où les couleurs **aident** à la compréhension
  - Reconnaissance des **formats** de MSA en sortie des logiciels d'alignement et **maintient** de ce format après l'édition
  - Interface graphique **ergonomique**, utilisation de la souris, . . .

- Éditeurs : CINEMA (Colour INteractive Editor for Multiple Alignment), GDE (Genetic Data Environment), GeneDoc (pour Windows), SEAVIEW, ...
- La plupart d'entre eux doivent être installés sur machines



- Il existe un grand nombre de formats de MSA
- Les deux plus fréquents sont le format **MSF** (Genetic's Computer Group) et le format **ALN** (CLUSTALW)
- On peut convertir l'un en l'autre facilement
- Exemple de format ALN :

```
CLUSTAL W (1.82) multiple sequence alignment
```

```
FOSB_MOUSE      MFQAFPGDYDSGSRCSSSPAESQYLSSVDSFGSPPTAAASQECAGLGEMPGSFVPTVTA 60
FOSB_HUMAN      MFQAFPGDYDSGSRCSSSPAESQYLSSVDSFGSPPTAAASQECAGLGEMPGSFVPTVTA 60
*****

FOSB_MOUSE      ITTSQDLQWLVQPTLISSMAQSQGQPLASQPPAVDPYDMPGTSYSTPGLSAYSTGGASGS 120
FOSB_HUMAN      ITTSQDLQWLVQPTLISSMAQSQGQPLASQPPVDPYDMPGTSYSTPGMSGYSSGGASGS 120
*****
*****.*****:*.**:******
```

- Le format **ALN** est le format d'origine du programme ClustalW. Le fichier commence par le mot clé "CLUSTAL" puis diverses informations concernant la version de CLUSTAL utilisée (ex : "CLUSTAL W (1.82) multiple sequence alignment")
- L'alignement est écrit en blocs de taille **60** résidus
- Chaque bloc commence avec le nom de la séquence et termine par la position de fin du bloc
- Des informations concernant les mises en correspondance des résidus est donnée en dessous de chaque bloc : "\*" même résidu dans toute la colonne, ":" substitutions conservatives, "." substitutions semi-conservatives.

- 
- Le fichier commence par autant de lignes de description que nécessaire
  - Les commentaires sont terminés par une ligne commençant avec 2 barres obliques
  - La 1re ligne reconnue est celle qui contient "MSF :", elle contient aussi la lg de la séquence, le type, etc
  - Ensuite une ligne blanche
  - Puis une ligne par séquence avec leur description (nom, lg, poids, ...), ce bloc est aussi terminé par 2 barres obliques
  - Encore une ligne blanche
  - Enfin l'alignement proprement dit

Les commentaires ....

//

MSF: 510 Type: P Check: 7736 ..

Name: ACHE\_BOVIN oo Len: 510 Check: 7842 Weight: 16.0

Name: ACHE\_HUMAN oo Len: 510 Check: 8553 Weight: 17.8

Name: ACHE\_MOUSE oo Len: 510 Check: 229 Weight: 12.5

Name: ACHE\_RAT oo Len: 510 Check: 8410 Weight: 14.2

Name: ACHE\_XENLA oo Len: 510 Check: 2702 Weight: 39.2

//

ACHE\_BOVIN MAGALLCALL LLQLLGRGEG KNEELRLYHY LFDTYDPGRR PVQEPEDTVT

ACHE\_HUMAN MARAPLGVLL LLGLLGRGVG KNEELRLYHH LFNNDPGRSR PVREPEDTVT

ACHE\_MOUSE MAGALLGALL LLTLFGRSQG KNEELSLYHH LFDNYDPECR PVRRPEDTVT

ACHE\_RAT MTMALLGTLL LLALFGRSQG KNEELSLYHH LFDNYDPECR PVRRPEDTVT

ACHE\_XENLA MESGVRILSL LILLHNSLAS ESEESRLIKH LFTSYDQKAR PSKGLDDVVP

ACHE\_BOVIN ISLKVTLTNL ISLNEKEETL TTSVWIGIDW QDYRLNYSKG DFGGVETLRV

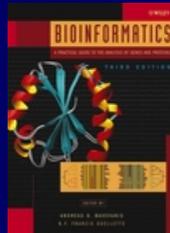
ACHE\_HUMAN ISLKVTLTNL ISLNEKEETL TTSVWIGIDW QDYRLNYSKD DFGGIETLRV

ACHE\_MOUSE ITLKVTLTNL ISLNEKEETL TTSVWIGIDW HDYRLNYSKD DFAGVGILRV

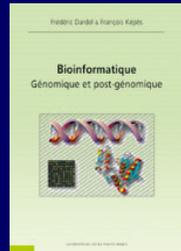
ACHE\_RAT ITLKVTLTNL ISLNEKEETL TTSVWIGIEW QDYRLNFSKD DFAGVEILRV

- 
- Introduction
  - Méthodes de score
  - Alignement multiple exact
  - MSA Global
  - MSA Local
  - Éditeurs de MSA
  - Références

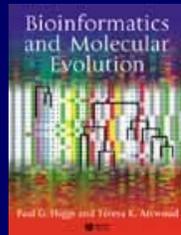
- Chap 8 et 13 dans “Bioinformatics : A Practical Guide to the Analysis of Genes and Proteins, 3rd Edition”  
[Baxevanis & Ouellette,2005]



- Chap 2 et 4 dans “Bioinformatique Génomique et post-génomique”  
[Dardel & Képès, 2002]



- Chap 5, 7 et 9 dans “Bioinformatics and Molecular Evolution”  
[Higgs & Attwood, 2005]



- Illustrations :

→ Transp. 22 : Diagramme de Venn des propriétés des acides aminés. Wikipedia, entrée 'Acide aminé' ([http://fr.wikipedia.org/wiki/Acides\\_aminés](http://fr.wikipedia.org/wiki/Acides_aminés))

→ Transp. 40 et 41 : Ces 2 schémas proviennent de l'article « The role of pattern databases in sequence analysis » de Terri K. Attwood, publié dans *Briefings in Bioinformatics* en 2000