

Démarche

Alignement 2 à 2

2 séquences quelconques

Détecter une similarité syntaxique

Il y a-t-il une fonction commune ?

Alignement multiple

Famille de séquences avec la même fonction

A quelle conservation syntaxique cela correspond-il ?

Exemple: Motif doigt de Zinc (JS Varré H Touzet)

Voici un alignement multiple de séquences protéiques:

```

TY11_HUMAN YVCFPDCNKKFAQSTNLSKSHL--TH- 25
TF3B_BUFAM YVCFPDCNCKTFTTFLNLSKSHL--TFH 26
ZN77_HUMAN YVCFPDCNCRGPTSATNKKYKVR--IH- 25
ZN76_HUMAN YVCFPDCNCRGPTSATNKKYKVR--AH- 25
P44_XENBO YVCFYEDCQVSPFWALGTLK--KH- 25
TSH_DROME FRCVW--CWGSPFTLEALTSMKDSKH- 25
XF1N_XENLA FRCSE--CSRFTNSDLTAMR--KH- 23
EVI1_HUMAN YKCY--CDRSFISSSLQRHVNR--IH- 24
TRAL_CABEL YKCFADCKEAFSNADRAKQNR--TH- 26
TF3A_BUFAM CKCETENCLAFATSNMRLHFPR--AH- 26
SRVC_DROME FRCNY--CFRDTNFPNWLKHTER--RH- 24
ZG2-9_XENL FVCTV--CKTFYKGLATLHLS--H- 23
ZG58_XENLA FVCTK--CNLSFAGLANLRSQHL--H- 23
YKQ8_CABEL YKCTV--CRKDISSESLETRMFK--QHR 25
BAGO_HUMAN FQCDI--CKTFPKACSVKIHNR--MH- 24
SIRK_DROM YACKL--CKGFPFVRLRQKQY--SRK 25
ZN10_HUMAN YKCNQ--CQIFSQNSPFIHQI--AH- 23
P43_XENBO LKCSVPOCKRFRKRALRHSV--KH- 25
IKAR_MOUSE FRCNM--CQVHQDQRYFSSHTRGEH- 25

```

Exemple: Motif doigt de Zinc (JS Varré H Touzet)

Regardons les résidus totalement conservés:



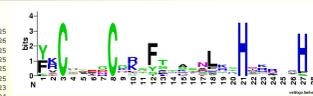
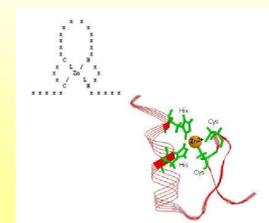
```

TY11_HUMAN YVCFPDCNKKFAQSTNLSKSHL--TH- 25
TF3B_BUFAM YVCFPDCNCKTFTTFLNLSKSHL--TFH 26
ZN77_HUMAN YVCFPDCNCRGPTSATNKKYKVR--IH- 25
ZN76_HUMAN YVCFYEDCQVSPFWALGTLK--KH- 25
P44_XENBO YVCFYEDCQVSPFWALGTLK--KH- 25
TSH_DROME FRCVW--CWGSPFTLEALTSMKDSKH- 25
XF1N_XENLA FRCSE--CSRFTNSDLTAMR--KH- 23
EVI1_HUMAN YKCY--CDRSFISSSLQRHVNR--IH- 24
TRAL_CABEL YKCFADCKEAFSNADRAKQNR--TH- 26
TF3A_BUFAM CKCETENCLAFATSNMRLHFPR--AH- 26
SRVC_DROME FRCNY--CFRDTNFPNWLKHTER--RH- 24
ZG2-9_XENL FVCTV--CKTFYKGLATLHLS--H- 23
ZG58_XENLA FVCTK--CNLSFAGLANLRSQHL--H- 23
YKQ8_CABEL YKCTV--CRKDISSESLETRMFK--QHR 25
BAGO_HUMAN FQCDI--CKTFPKACSVKIHNR--MH- 24
SIRK_DROM YACKL--CKGFPFVRLRQKQY--SRK 25
ZN10_HUMAN YKCNQ--CQIFSQNSPFIHQI--AH- 23
P43_XENBO LKCSVPOCKRFRKRALRHSV--KH- 25
IKAR_MOUSE FRCNM--CQVHQDQRYFSSHTRGEH- 25

```

On peut établir une carte par position des résidus conservées :
 WebLogo : <http://weblogo.berkeley.edu/logo.cgi>

Exemple: Motif doigt de Zinc (JS Varré H Touzet)

L'alignement multiple permet de mieux comprendre l'organisation d'un motif particulier et permet de modéliser le motif : (Prosite)
 C-x(2,4)-C-x(3)-[LIVMFYWC]-x(8)-H-x(3,5)-H

Notion de séquence consensus

A partir de l'alignement multiple, on peut déterminer la séquence consensus:

On attribue à chaque position l'acide aminé ou le nucléotide qui est le plus souvent retrouvé (totalement conservé ou partiellement).

```

130 140 150 160 170 180
UR2E3_MOUSE TILGPGQVYKGGVFFLDITFSBDYFPKPKVTFTRIVYCHINSQVILCLDLKNNQSP
UR2C2_DROME TILGPGQVYKGGVFFLDITFSBDYFPKPKVTFTRIVYCHINSQVILCLDLKNNQSP
UR2D2_HUMAN TIMGPNDSYVQGVFFLTIHFPTDYFPKPKVAFTRIVYHPNINSQVILCLDLRQNSP
UR2D3_HUMAN TIMGPNDSYVQGVFFLTIHFPTDYFPKPKVAFTRIVYHPNINSQVILCLDLRQNSP
UR2D4_RAT TIMGPNDSYVQGVFFLTIHFPTDYFPKPKVAFTRIVYHPNINSQVILCLDLRQNSP
UR2D1_HUMAN TIMGPNDSYVQGVFFLTIHFPTDYFPKPKVAFTRIVYHPNINSQVILCLDLRQNSP
UR2C1_DROME TIMGPNDSYVQGVFFLTIHFPTDYFPKPKVAFTRIVYHPNINSQVILCLDLRQNSP
UR2C1_COLGL TIMGPNDSYVQGVFFLTIHFPTDYFPKPKVAFTRIVYHPNINSQVILCLDLRQNSP
UR2C1_MAGEB TIMGPNDSYVQGVFFLTIHFPTDYFPKPKVAFTRIVYHPNINSQVILCLDLRQNSP
UR2C2_ARATH VIFGPDPTVMDGTFKLSLQFSDYFNKPTVRFVSRMHPHNIYADGSLCLDLQNNQSP
UR2C2_MESGA VIFGPDPTVMDGTFKLSLQFSDYFNKPTVRFVSRMHPHNIYADGSLCLDLQNNQSP
UR2C1_ARATH VIFGPDPTVMDGTFKLSLQFSDYFNKPTVRFVSRMHPHNIYADGSLCLDLQNNQSP
UR2C2_MHEAT VIFGPDPTVMDGTFKLSLQFSDYFNKPTVRFVSRMHPHNIYADGSLCLDLQNNQSP
UR2C1_CABEL IIFGPDPTVMDGTFKLSLQFSDYFNKPTVRFVSRMHPHNIYADGSLCLDLQNNQSP
UR2E2_HUMAN VIFGPDPTVMDGTFKLSLQFSDYFNKPTVRFVSRMHPHNIYADGSLCLDLQNNQSP
UR2C2_CANAL VIFGPDPTVMDGTFKLSLQFSDYFNKPTVRFVSRMHPHNIYADGSLCLDLQNNQSP
UR2C2_SCHPO VIFGPDPTVMDGTFKLSLQFSDYFNKPTVRFVSRMHPHNIYADGSLCLDLQNNQSP
Prim.cons. TILGPGQVYKGGVFFLDITFSBDYFPKPKVTFTRIVYCHINSQVILCLDLQNNQSP

```

Alignement multiple: principe

L'approche la plus courante consiste à aligner progressivement des paires de séquences:

Alignements itératifs et progressifs

Algorithme Needleman & Wunsch 2 à 2 traditionnel répété n fois

Alignement multiple: principe

L'approche la plus courante consiste à aligner progressivement des paires de séquences.

Les différentes approches se distinguent par:
La façon de choisir la paire initiale de séquences

Pour progresser dans l'alignement, les programmes vont:
Soit aligner chaque séquence les unes après les autres à un alignement unique enrichi à chaque étape
Soit créer des sous-familles de séquences d'abord alignées au sein de ces familles puis entre les familles.

La méthode de pondération des alignements individuels des paires de séquences et des alignements cumulés.

Alignement basé sur un arbre

Idee: reconstruire l'alignement multiple à partir d'un arbre guide (clusters)

feuilles : séquences
noeuds : alignements

Partir des feuilles puis remonter dans l'arbre
Utilisation de la technique de **profil alignement** -> produire un seul alignement multiple avec deux.

CLUSTer + **AL**ignement **CLUSTAL**

Thompson et al. 1994

ClustalW EBI <http://www.ebi.ac.uk/clustalw/index.html>

ClustalW est l'un des programmes les plus utilisés pour l'alignement progressif.

Etape 1: Alignements globaux 2 à 2

Etape 2: Regroupements des alignements (clusters), construction arbre guide

Etape 3: Alignement multiple obtenu par combinaisons des alignements 2 à 2 (profils)



ClustalW exemple

4 séquences

```
s1 cgatgagtcattgtgactg
s2 cgagccattgtagctactg
s3 cgaccattgtagctactg
s4 cgatgagtcactgtgactg
```

Jeu de score:

Indel=-2
Substitution=-1
Identité= 1

ClustalW étape 1: Calcul des scores

Les alignements de toutes les paires de séquences sont réalisés puis le programme génère une matrice de distances décrivant leur taux de similitude.

```
s1 cgatgagtcattgtg--actg s2 cgagccattgtageta-ctg
  ||| | ||||| | |||||
s2 cga-g--ccattgtagetaactg s3 cga--ccattgtagetaactg
  ||| | ||||| | |||||
s1 cga-tgagtcattg-tgactg s2 cga-g--ccattgtagetaactg
  ||| | ||||| | |||||
s3 cgaccattgtagctactg s4 cgatgagtcactgtg-actg
  ||| | ||||| | |||||
s1 cga-tgagtcattgtgactg s3 cgaccattgtagetaactg
  ||| | ||||| | |||||
s4 cga-tgagtcactgtgactg s4 cga-tgagtcactgtgactg
  ||| | ||||| | |||||
```

Tableau des scores d'alignement:

	s1	s2	s3	s4
s1		2	0	17
s2	2		14	0
s3	0	14		-1
s4	17	0	-1	

Pour N séquences:

$N(N-1) / 2$ calculs

ClustalW étape 2: Construction arbre

A l'aide de la matrice de scores, un arbre guide (ou dendrogramme) est ensuite construit par un algorithme dit de neighbor-joining:

	s1	s2	s3	s4
s1		2	0	17
s2	2		14	0
s3	0	14		-1
s4	17	0	-1	

s1

s2

s3

s4

Regroupement des séquences suivant leur similitude à partir de la matrice des scores 2 à 2.

ClustalW étape 2: Construction arbre

A l'aide de la matrice de scores, un arbre guide (ou dendrogramme) est ensuite construit par un algorithme dit de neighbor-joining:

	s1	s2	s3	s4
s1		2	0	17
s2	2		14	0
s3	0	14		-1
s4	17	0	-1	

ClustalW étape 2: Construction arbre

A l'aide de la matrice de scores, un arbre guide (ou dendrogramme) est ensuite construit par un algorithme dit de neighbor-joining:

	s1	s2	s3	s4
s1		2	0	17
s2	2		14	0
s3	0	14		-1
s4	17	0	-1	

ClustalW étape 2: Construction arbre

A l'aide de la matrice de scores, un arbre guide (ou dendrogramme) est ensuite construit par un algorithme dit de neighbor-joining:

	s1	s2	s3	s4
s1		2	0	17
s2	2		14	0
s3	0	14		-1
s4	17	0	-1	

ClustalW étape 2: Construction arbre

A l'aide de la matrice de scores, un arbre guide (ou dendrogramme) est ensuite construit par un algorithme dit de neighbor-joining:

	s1	s2	s3	s4
s1		2	0	17
s2	2		14	0
s3	0	14		-1
s4	17	0	-1	

ClustalW étape 2: Construction arbre

A l'aide de la matrice de scores, un arbre guide (ou dendrogramme) est ensuite construit par un algorithme dit de neighbor-joining:

	s1	s2	s3	s4
s1		2	0	17
s2	2		14	0
s3	0	14		-1
s4	17	0	-1	

Alignement s1s2 est plus proche que s1s3

Alignement s4s2 est plus proche que s4s3

Matrice de score -> matrice de distance

ClustalW étape 2: Construction arbre

A l'aide de la matrice de scores, un arbre guide (ou dendrogramme) est ensuite construit par un algorithme dit de neighbor-joining:

	s1	s2	s3	s4
s1		2	0	17
s2	2		14	0
s3	0	14		-1
s4	17	0	-1	

Arbre guide construit

Etape 3: Construction alignement final

ClustalW aligne les séquences en se servant de l'arbre guide: chaque paire de séquences situées sur une même branche extérieure de l'arbre est alignée par programmation dynamique.

Les alignements partiels permettent de constituer des **profils**, représentés sous forme de tableau dans lequel sont données pour chaque position la fréquence observée de chaque lettre.

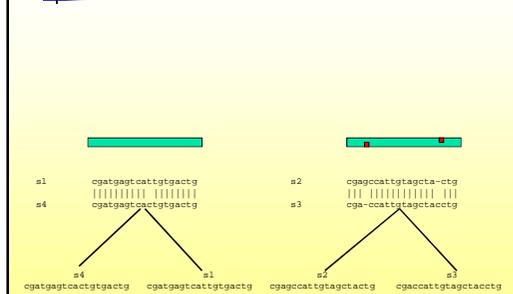
L'algorithme aligne ensuite les profils associés par un même nœud de l'arbre. Cet alignement de séquences puis de profils se poursuit de façon récursive jusqu'à l'alignement final complet depuis les branches de l'arbre vers la racine.

Etape 3: Construction alignement final

L'alignement et création des profils:

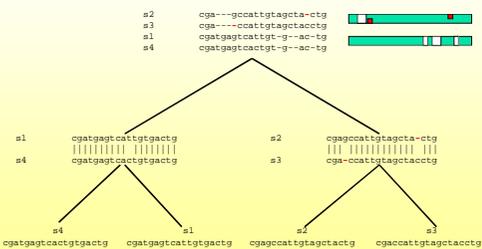


Etape 3: Construction alignement final



Etape 3: Construction alignement final

Once a gap, always a gap



ClustalW

ClustalW est optimisé pour les protéines:

Pondération des séquences en fonction de leur sur/sous représentation

Adaptation des matrices de similitudes au fil de l'algorithme en fonction de la divergence des séquences à aligner
Blosum 80 pour aligner des séquences proches
Blosum 50 pour aligner des séquences distantes

Pénalités de gaps spécifiques à chaque résidu.
Par exemple, les Glycines sont davantage susceptible d'avoir un gap que les Valines.

Pénalités de gaps réduites dans les régions hydrophiles
Encourage la formation de gaps dans des boucles plutôt que dans des régions structurées.

Pénalités de gaps augmentées dans le voisinage d'autres gaps
Evite la formation de petits gaps voisins, au profit de longs gaps.

Autre méthode

A partir des alignements locaux

Idée: repérer des similitudes locales fortes entre les séquences (les diagonales du dotplot par exemple)

Incorporer les diagonales dans l'alignement multiple

Conséquence: les gaps inter-diagonales sont moins importants

DIagonal + ALIGNement

DIALIGN

DIALIGN Morgenstern et al. 1996

DIALIGN sur Pasteur: <http://bioweb.pasteur.fr/seqanal/interfaces/dialign2-simple.html>

Alignements des paires avec optimisation des poids des diagonales

Tri des diagonales selon leur poids et leur chevauchement

DIALIGN : DNA and protein sequence alignment based on segment-to-segment comparison (Morgenstern, Dress, Werner)

Reconstruction gloutonne
Insertion des diagonales par poids décroissants
Vérification de la consistance avec les diagonales déjà introduites

Recommencer ...

DIALIGN exemple

3 séquences:
YIAFLFAWDD
LACFIFGS
SWEDFMFAED

Etape 1 : Détection des diagonales dans les paires de séquences:

DIALIGN exemple

3 séquences:
YIAFLFAWDD
LACFIFGS
SWEDFMFAED

Etape 1 : Détection des diagonales dans les paires de séquences:

DIALIGN exemple

3 séquences:
YIAFLFAWDD
LACFIFGS
SWEDFMFAED

Etape 1 : Détection des diagonales dans les paires de séquences:

DIALIGN exemple

3 séquences:
YIAFLFAWDD
LACFIFGS
SWEDFMFAED

Etape 2 : Sélection d'un ensemble cohérent de diagonales pour construire l'alignement:

Pas de croisement
Pas de chevauchements
score maximal

```

yIA-FLFAWd
-LAcFIFgs--
swedFMFAED-
  
```

CLUSTAL vs DIALIGN

Exemple (C. Notre-Dame)

```

GARFIELD THE LAST FAT CAT
GARFIELD THE FAT CAT
GARFIELD THE VERY FAST CAT
THE FAT CAT
  
```

CLUSTAL vs DIALIGN

Alignement fourni par ClustalW:

```
seq2xx1 GARFIELDTHE----FAT-CAT
seq4xx3 -----THE----FAT-CAT
seq1xx0 GARFIELDTHELASTFAT-CAT
seq3xx2 GARFIELDTHEVERYFASTCAT
```

Clustal 1ère version:

```
GARFIELDTHELASTFA-TCAT
---GARFIELDTHEFA-TCAT
GARFIELDTHEVERYFASTCAT
-----THEFA-TCAT
```

Alignement fourni par Dialign2:

```
seq1 1 GARFIELDTHELASTFA-TCAT
seq2 1 GARFIELDTHE----FA-TCAT
seq3 1 GARFIELDTHEVERYFASTCAT
seq4 1 -----THE----FA-TCAT
```

Quelles méthode utiliser

Cela dépend du type de séquences à aligner !

BaliBase : base de données d'alignements multiples et de benchmarks
<http://www-bio3d-igbmc.u-strasbg.fr/balibase/>

Plusieurs références!

Ref1 : Séquences équidistantes avec différents niveaux de conservation

Ref2: Protéines homologues + une séquence orpheline

Ref3: Sous-groupes avec moins de 25% d'identité entre les groupes

Ref4: Extensions N/C terminales

Ref5: Insertions internes

Ref6: Répétitions internes

Ref7: Protéines transmembranaires

Ref8: Permutations de domaines

Ref1, 2, 3: Préférer Clustal à Dialign
Ref4 et 5: Préférer Dialign à Clustal

Quelles méthode utiliser

Plus les séquences sont divergentes, moins le résultat est fiable.
Quand le taux d'identité est supérieur à 35%, toutes les méthodes sont satisfaisantes.

Twilight Zone : 10-20% d'identité
Aucune méthode rassure un alignement avec plus de 50% de correction.

Clustal a tendance à autoriser moins de gaps que Dialign

Similitude locale : Dialign
Similitude globale : Clustal

Existe d'autres méthodes : MultiAlign, Tcoffee, etc...

Pas de méthode universelle
Pas de confiance aveugle vis-à-vis du résultat obtenu

Visualiser des alignements multiples

Il existe des outils simples pour visualiser ou modifier un alignement multiple:

SeaView : <http://pbil.univ-lyon1.fr/software/seaview.html>



BioEdit : <http://www.mbio.ncsu.edu/BioEdit/bioedit.html>

Autre type d'alignement: structuraux

On peut aussi vouloir aligner non pas des séquences mais des structures protéiques (Cela permet de mieux comprendre les zones clés, structurellement conservées).

TM-Align : <http://zhang.bioinformatics.ku.edu/TM-align/>
Permet d'aligner 2 structures au format PDB

ISuperpose : <http://bioserv.rpbs.jussieu.fr/cgi-bin/iSuperpose>
Permet d'aligner plusieurs structures (format PDB). Possibilité de fournir l'alignement ou pas.

...

Exercices

Exo 1: A partir du jeu de séquences [seq1](#), lancer un ClustalW et analyser l'alignement obtenu.

Regarder les différentes sorties proposées par ClustalW (lancer l'applet JalView)

Sauvegarder les différents fichiers de sortie.
Télécharger et installer SeaView et Njplot.

Regarder l'alignement avec SeaView et visualiser l'arbre guide avec NjPlot.

Exercices

Exo 2: Analyse des domaines SH3

Intro: SH3 (Src homology 3) domains are often indicative of a protein involved in signal transduction related to cytoskeletal organization. The SH3 domain has a characteristic fold which consists of five or six beta-strands arranged as two tightly packed anti-parallel beta sheets. The linker regions may contain short helices.

Voici 5 protéines à aligner: [seq2](#)

Ce sont des séquences courtes avec des similitudes faibles et diffuses (<25%).

Tester les différents alignements obtenus avec ClustalW, Dialign2, Multialign.
Proposer des régions ou résidus clés pour ce type de domaine.

Exercices

Exo 2: Les structures de ces protéines sont connues:

Voici pour chaque protéine les éléments de structures secondaires:

```
> laboA 58
NLFVALYDFVARGENTLSITKQKLRVLYGNHNMCEAQTENQOMVPSNITTPVRS
CEREKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCC
> lycsB 60
KIVLYALMDYEPQNDDELPMKEDDCMTIIHREDEDELEWWRARLNKREGYVPRNLLGLYF
CEREKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCC
> lpht 83
AEQYQFALYDFKRREREDIDLRLGIDLTVNKGSLVALGFSQQEARPEIIGWLNQVNETTGERGDFPQTVEYIGRKKISPP
CEREKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCC
> llnvA 52
MIQNFVYVYRSDRDFVKGPAKLLKNGEGAVVIQNSDIKVVFRKAKIIRD
CCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCC
> lvis 60
PQNTAFQMDRVRKESGAAMQQQIVWYCTNLPFGYAVESRAHPGSVQLYPVAALERIN
CCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCCCKCC
```

Voici les protéines alignées structurellement visualisées avec Pymol [fit](#)

Que peut-on dire au niveau de la structure ?
(par rapport à l'alignement ?)