

Alignements et recherche de similarités

Analyse de séquences génomiques et phylogénie

Guy Perrière

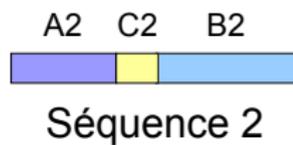
Laboratoire de Biométrie et Biologie Évolutive
UMR CNRS n° 5558
Université Claude Bernard – Lyon 1

3-6 avril 2017

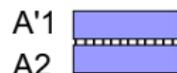
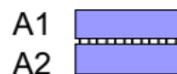
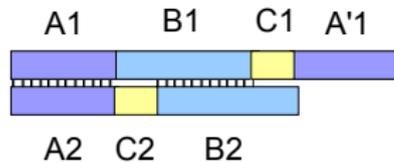
Objectifs poursuivis

- Identification d'homologues.
- Recherche de contraintes fonctionnelles.
- Prédiction de structure (ARN, protéine).
- Prédiction de fonction.
- Reconstitution des relations évolutives entre séquences (phylogénie).
- Assemblage de lectures (séquençage).

Alignement global et local



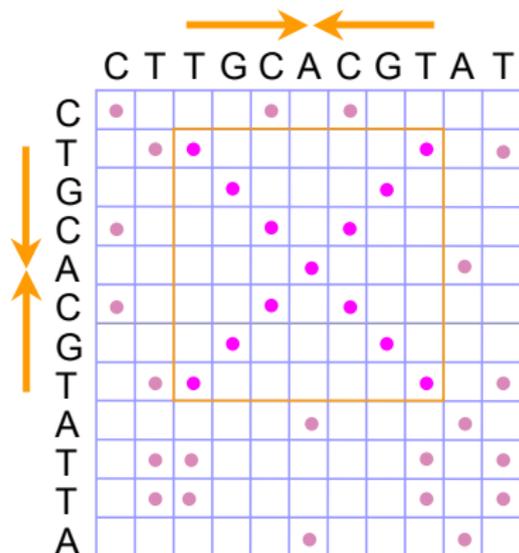
Needleman
& Wunsch
FASTA



Smith &
Waterman
BLAST

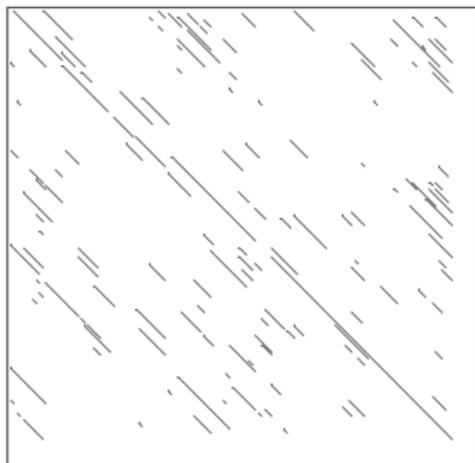
Matrices de points

- Comparaison visuelle de deux séquences :
 - Une diagonale indique une similarité locale.
 - Une croix indique une répétition inverse.
 - Méthode simple et rapide :
 - Algorithme en $O(nm)$.
 - Pas d'alignement ni de score global.

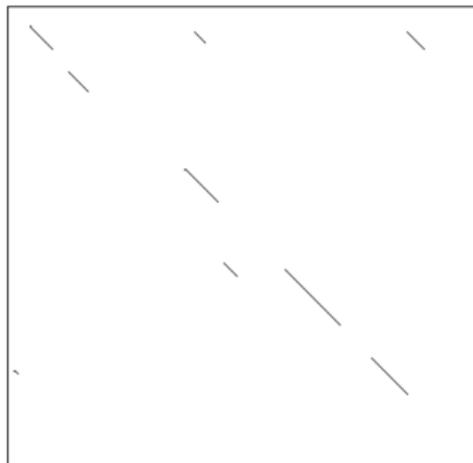


Élimination du bruit de fond

- Filtrage en affichant un point uniquement si plusieurs résidus successifs correspondent :
 - Exemple des hémoglobines α et β humaines :



Identités = 3/10



Identités = 5/10

Représentation

- Les résidus (nucléotides, acides aminés) sont superposés de façon à maximiser les identités entre les séquences :

```

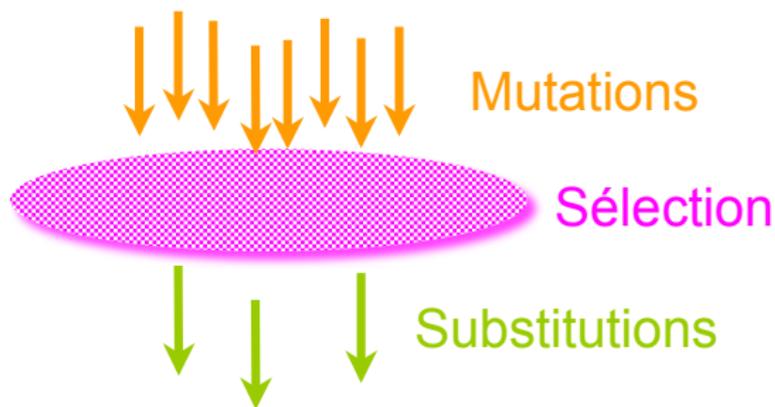
G T T A A G G C G - G G A A A
G T T - - - G C G A G G A C A
* * *           * * *   * * *   *

```

- Il existe deux sortes de différences :
 - Substitutions (*mismatches*).
 - Insertions et délétions (*indels* ou *gaps*).

Mutations et substitutions

- Les différences observées dans un alignement correspondent aux substitutions :
 - Mutations ayant passé le filtre de la sélection :
 - Mutations neutres (*i.e.*, sans effet sur le phénotype) ou avantageuses du point de vue sélectif.



Quel est le bon alignement ?

```
G T T A C G A
G T T - G G A
* * *      * *
```

ou

```
G T T A C - G A
G T T - - G G A
* * *      * *
```

```
G T T A C G A
G T T G - G A
* * *      * *
```

- Pour le biologiste, le bon alignement est celui qui représente le scénario évolutif le plus probable :
 - Définition d'une *fonction de score* appropriée.
- Autres choix possibles (*e.g.*, assemblage de lectures).

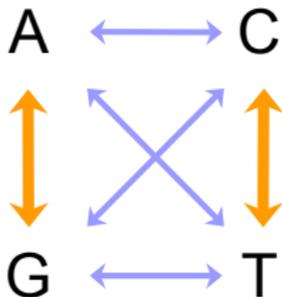
Fonction de score simple

G	T	T	A	A	G	G	C	G	-	G	G	A	A	A
G	T	T	-	-	-	G	C	G	A	G	G	A	C	A
*	*	*				*	*	*		*	*	*		*

$$\text{Score} = \sum \text{Identités} - \sum \text{Différences}$$

$$\left. \begin{array}{l} \text{Identité} \quad = +1 \\ \text{Substitution} \quad = 0 \\ \text{Gap} \quad = -1 \end{array} \right\} \implies \text{Score} = 10 - 4 = 6$$

Modèle d'évolution



$$\mathbb{P}(\text{transition}) > \mathbb{P}(\text{transversion})$$

G	T	T	A	C	G	A		G	T	T	A	C	G	A
G	T	T	G	-	G	A	>	G	T	T	-	G	G	A
*	*	*	:		*	*		*	*	*			*	*

Matrice de substitution ADN

A	1			
C	0	1		
G	0.5	0	1	
T	0	0.5	0	1
	A	C	G	T

$$\delta(A, A) = 1.0$$

$$\delta(A, G) = 0.5$$

$$\delta(-) = -1.0$$

G T T A C G A
 G T T G - G A
 * * * : * *

Score = 4.5

G T T A C G A
 G T T - G G A
 * * * * * *

Score = 4.0

Le cas des acides aminés

- Plus complexe à modéliser que celui des séquences nucléotidiques :
 - Alphabet de vingt lettres au lieu de quatre.
 - Difficulté d'utiliser directement l'information portée par les séquences codantes :
 - Certaines substitutions peuvent avoir plus ou moins d'effet sur la fonction des protéines :

$$\mathbb{P}(\text{AAU}_{\text{Asn}} \rightarrow \text{GAU}_{\text{Asp}}) > \mathbb{P}(\text{AAU}_{\text{Asn}} \rightarrow \text{CAU}_{\text{His}})$$

- Utilisation de modèles empiriques :
 - Alignement de séquences homologues avec la matrice identité.
 - Construction d'arbres phylogénétiques sur la base de ces alignements.
 - Construction des matrices sur la base du nombre de substitutions observées (ou inférées à partir des arbres).

BLOSUM (*Blocks Substitution Matrices*)

- Matrices fondées sur des alignements locaux de domaines conservés (Henikoff et Henikoff, 1992) :
 - Utilisation de ≈ 2000 domaines provenant de ≈ 500 familles de protéines.
 - Matrice identité.
 - Alignements sans *gaps*.
- Ensemble de quinze matrices créées à partir de domaines comprenant des séquences \pm divergentes :
 - Toutes les paires ayant servi à construire une matrice BLOSUM k ($30 \leq k \leq 100$) ont une identité \geq à $k\%$.
 - Bien adaptées pour l'alignement de séquences très divergentes.

Construction I

- Calcul de la fréquence *observée* de chaque paire d'acide aminé dans l'alignement :
 - Soit n_{ij} le nombre de paires (i, j) observées, $i, j \in \{A, C, D, \dots, W\}$.
 - Soit w la largeur du bloc considéré et a le nombre de séquences alignées.
 - Dans ce cas, le nombre total de paires possibles q est tel que :

$$q = wa(a - 1)/2$$

et f_{ij} , la fréquence observée de chaque paire (i, j) est égale à :

$$f_{ij} = n_{ij}/q$$

Construction II

- Calcul de la fréquence *attendue* de chaque paire :
 - Soit π_i la fréquence de l'acide aminé i dans l'alignement.
 - Dans ce cas, les fréquences attendues g_{ij} de chaque paire (i, j) sont égales à :

$$g_{ij} = 2\pi_i\pi_j \quad (i \neq j)$$

$$g_{ii} = \pi_i^2$$

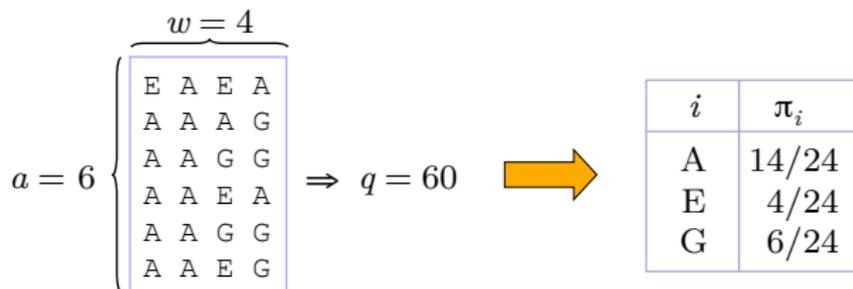
- Calcul des éléments de la matrice de substitution $\Delta = (\delta_{ij})$ par :

$$\delta_{ij} = 2 \log_2(f_{ij}/g_{ij})$$

avec arrondissement à l'entier le plus proche :

- $\delta_{ij} > 0 \Rightarrow$ substitution plus fréquente qu'attendue.
- $\delta_{ij} < 0 \Rightarrow$ substitution moins fréquente qu'attendue.

Exemple simple



(i, j)	f_{ij}	g_{ij}	δ_{ij}
(A, A)	26/60	196/576	0.70
(A, E)	8/60	112/576	-1.09
(A, G)	10/60	168/576	-1.61
(E, E)	3/60	16/576	1.70
(E, G)	6/60	48/576	0.53
(G, G)	7/60	36/576	1.80

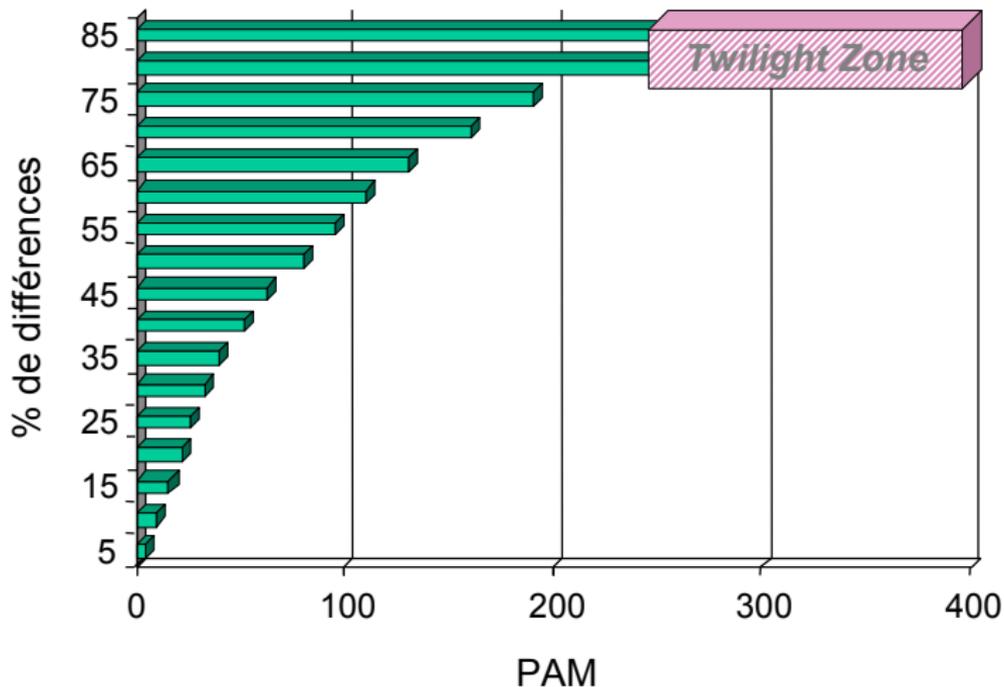


A	1		
E	-1	2	
G	-2	1	2
	A	E	G

PAM (*Point Accepted Mutations*)

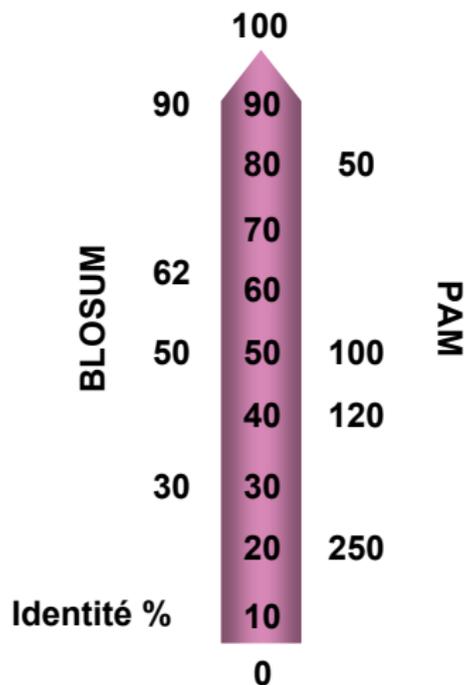
- Matrices construites sous l'hypothèse que les séquences évoluent selon un processus markovien (Dayhoff *et al.*, 1978).
- Alignements globaux de protéines conservées :
 - Utilisation de la matrice identité.
 - Pas de *gaps* dans les alignements.
 - 71 familles de gènes correspondant à 1300 séquences et contenant un total de 1572 substitutions :
 - Identité $\geq 85\%$ entre chaque paire possible au sein d'une famille.
- Matrices JTT (Jones, Taylor et Thornton, 1992) et Gonnet (Gonnet *et al.*, 1992) :
 - Construites avec une méthodologie comparable, mais sur des échantillons bien plus grands.
- Construction : *cf.* cours sur les modèles d'évolution.

Limites de validité



Choix d'une matrice

- Pas de matrice idéale.
- Meilleurs résultats avec les matrices construites avec un plus grand nombre de séquences.
- Choix principalement en fonction du degré de similarité entre les séquences.
- Il est recommandé d'expérimenter !



Pondération des *gaps*

- Avec la fonction de score telle que présentée dans la Diapo 9, la pénalité w associée à un *gap* de longueur k est égale à :

$$w = k\delta(-)$$

avec $\delta(-)$, la pénalité d'un *gap* individuel.

- Amélioration par l'emploi de fonctions affines ou logarithmiques :

$$w = \delta_o(-) + (k - 1)\delta_e(-)$$

$$w = \delta_o(-) + \ln(k - 1)\delta_e(-)$$

avec $\delta_o(-)$ la pénalité associée à l'ouverture d'un *gap*, et $\delta_e(-)$ la pénalité associée à l'extension de ce *gap*.

Influence sur les alignements

■ Pénalités affines :

- Évitement de *gaps* trop rapprochés :

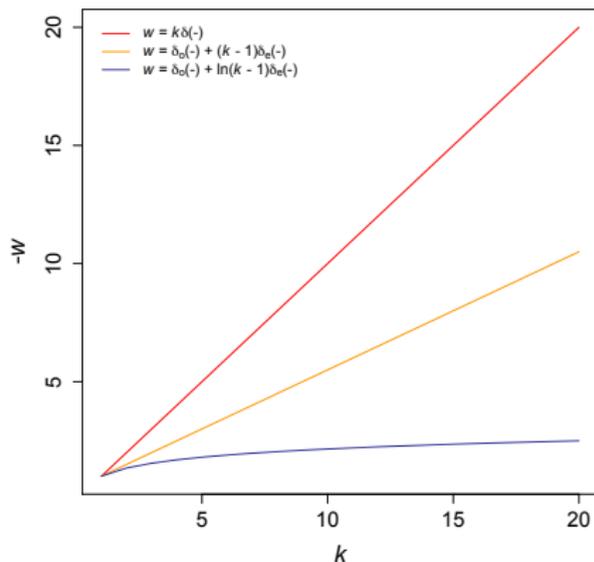
```

TGATATCGCCA      TGATATCGCCA
TGAT---TCCA  >  TGAT-T--CCA
****      ***      ***** *   ****
  
```

- Alignements plus réalistes du point de vue évolutif.

■ Pénalités logarithmiques :

- Seulement dans le cas où il est nécessaire d'avoir de très longs *gaps*.



Nombre d'alignements

- Le nombre d'alignements possibles entre deux séquences de longueur m et n est égal à (Waterman, 1984) :

$$f(m, n) = f(m - 1, n) + f(m - 1, n - 1) + f(m, n - 1)$$

avec $f(0, j) = f(i, 0) = 1 \forall i, j$.

- Par ailleurs, ce nombre croît de manière exponentielle (Torres *et al.*, 2003) :

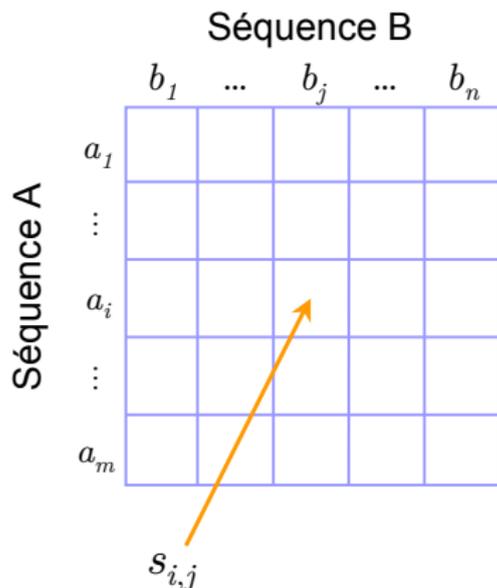
$$f(m, n) = \sum_{k=0}^{\min(m, n)} 2^k \binom{m}{k} \binom{n}{k}$$

Trouver le bon alignement

- Calcul de tous les alignements possibles :
 - Trop long (croissance exponentielle du nombre d'alignements).
 - Peu efficace (recalcul des mêmes valeurs).
- Utilisation d'un algorithme de *programmation dynamique* :
 - Recherche du meilleur alignement possible sur une fraction de la longueur des séquences :
 - Construction progressive de l'alignement.
 - Needleman et Wunsch (1970) : alignement global.
 - Smith et Waterman (1981) : alignement local.

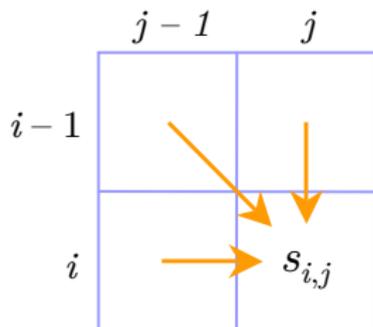
Needleman et Wunsch

- Soit deux séquences A et B de longueurs m et n .
- Soit $\mathbf{S} = (s_{i,j})$, la matrice de chemin associée à ces deux séquences.
- Stockage dans chaque case de \mathbf{S} du score du chemin menant à cette case :
 - Utilisation d'une fonction de score donnée.
 - Le score de l'alignement est la valeur en $s_{m,n}$.



Construction de la matrice

- Soit $s_{i,j}$ la valeur du score optimum dans la case de coordonnées (i, j) :
 - Calcul au moyen des scores dans les trois cases adjacentes $(i-1, j)$, $(i-1, j-1)$ et $(i, j-1)$.
 - Si pas de pénalités affines pour les *gaps* :

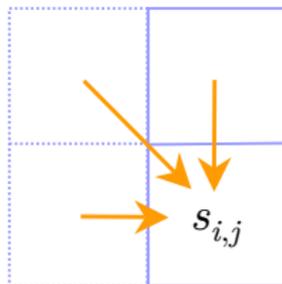


$$s_{i,j} = \max \begin{cases} s_{i-1,j} + \delta(-) \\ s_{i-1,j-1} + \delta(a_i, b_j) \\ s_{i,j-1} + \delta(-) \end{cases}$$

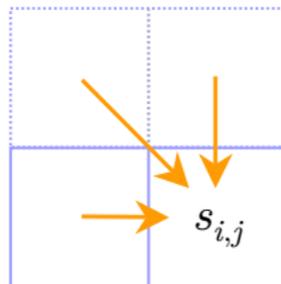
Bords de la matrice

- Les cases situées sur le bord du haut ou le bord gauche ne possèdent pas le total requis de trois cases adjacentes :
 - Ajout d'une ligne et d'une colonne afin d'initialiser la matrice :
 - Le balayage ne se faisant plus qu'avec des indices ≥ 1 , on ne rencontre plus de cases nécessitant un traitement particulier.

Bord gauche



Bord du haut



Initialisation de la matrice

- Pénalisation des *gaps* terminaux :

$$s_{0,0} = 0$$

$$s_{i,0} = s_{i-1,0} + \delta(-) \quad \forall i \in [1, m]$$

$$s_{0,j} = s_{0,j-1} + \delta(-) \quad \forall j \in [1, n]$$

- Pas de pénalisation des *gaps* terminaux :

$$s_{0,0} = s_{i,0} = s_{0,j} = 0 \quad \forall i \in [1, m], \forall j \in [1, n]$$

Option par défaut de beaucoup de programmes d'alignement (*e.g.*, ClustalW).

Exemple de calcul

		A	G	C	T	A
	0	-2	-4	-6	-8	-10
A	-2	+1	-2	-4	-6	-7
		-4	-1	-3	-5	-7
T	-4	-2	+1	-1	-2	-5
		-6	-3	-1	-3	-4
T	-6	-4	-1	+1	0	-2
		-8	-5	-3	-1	-2
A	-8	-5	-3	-1	+1	-4
		-10	-7	-5	-3	-1

Identité : +1

Substitution : 0

Gap : -2

A	G	C	T	A
A	-	T	T	A
+1	-2	+0	+1	+1

 $s = +1$

A	G	C	T	A
A	T	-	T	A
+1	+0	-2	+1	+1

 $s = +1$

Pénalités affines pour les gaps

- Soit $u_{i,j}$ et $v_{i,j}$, les scores associés à l'alignement entre les positions i et j et se terminant par un *gap* dans B ou dans A :

$$u_{i,j} = \max \begin{cases} u_{i-1,j} + \delta_e(-) \\ s_{i-1,j} + \delta_o(-) + \delta_e(-) \end{cases}$$

$$v_{i,j} = \max \begin{cases} v_{i,j-1} + \delta_e(-) \\ s_{i,j-1} + \delta_o(-) + \delta_e(-) \end{cases}$$

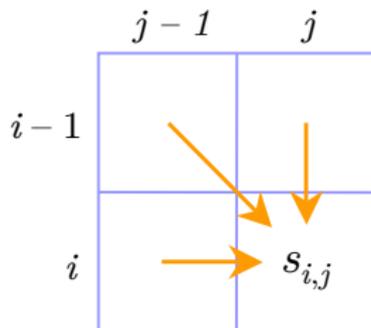
- Dans ces conditions, le calcul de $s_{i,j}$ est donné par :

$$s_{i,j} = \max \begin{cases} u_{i,j} \\ v_{i,j} \\ s_{i-1,j-1} + \delta(a_i, b_j) \end{cases}$$

Smith et Waterman

■ Algorithme dérivé de Needleman et Wunsch :

- Initialisation des bords à 0.
- N'importe quelle case de la matrice peut être considérée comme point de départ pour le calcul du score.



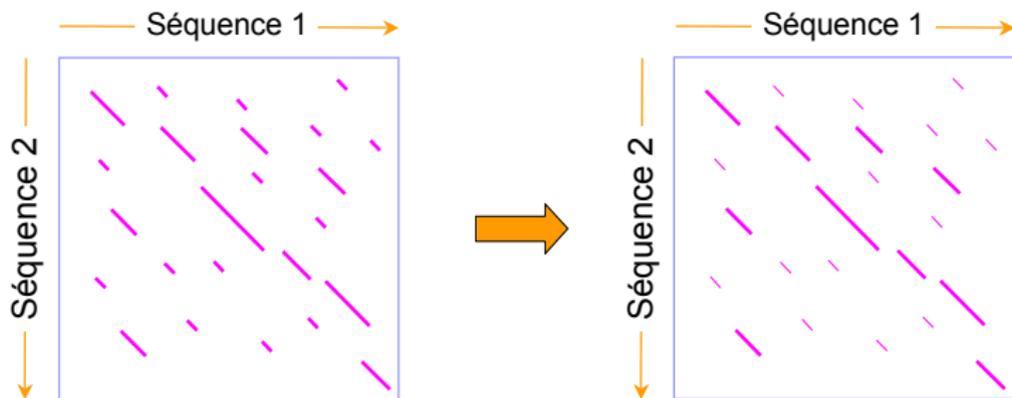
$$s_{i,j} = \max \begin{cases} s_{i-1,j} + \delta(-) \\ s_{i-1,j-1} + \delta(a_i, b_j) \\ s_{i,j-1} + \delta(-) \\ 0 \end{cases}$$

$$s_{i,j} < 0 \Rightarrow s_{i,j} = 0$$

Recherche dans les banques

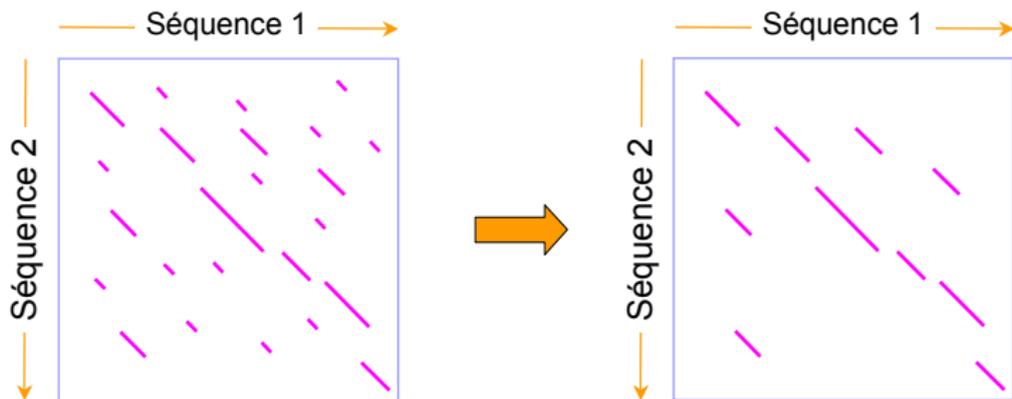
- Algorithme exact (Smith-Waterman) :
 - SSEARCH :
 - Alignements locaux optimaux.
 - Trop lent en pratique et nécessitant beaucoup de mémoire vive.
- Algorithmes fondés sur des heuristiques :
 - FASTA :
 - Recherche de mots *identiques*.
 - Alignement global, ancré sur des régions similaires.
 - BLAST :
 - Recherche de mots *similaires*.
 - Alignements locaux par extension autour de ces mots.

Procédure d'alignement I



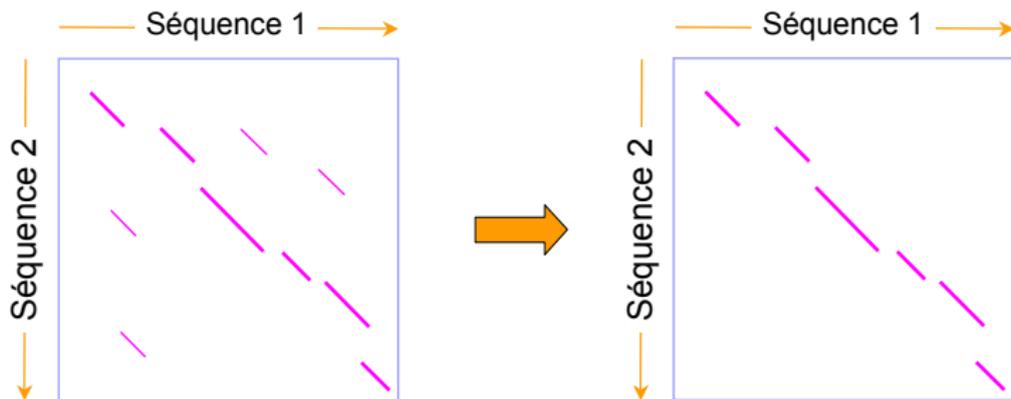
- Calcul de l'ensemble des alignements locaux en partant des mots communs détectés.
- Calcul des scores pour chaque alignement local puis élimination des scores les plus faibles.

Procédure d'alignement I



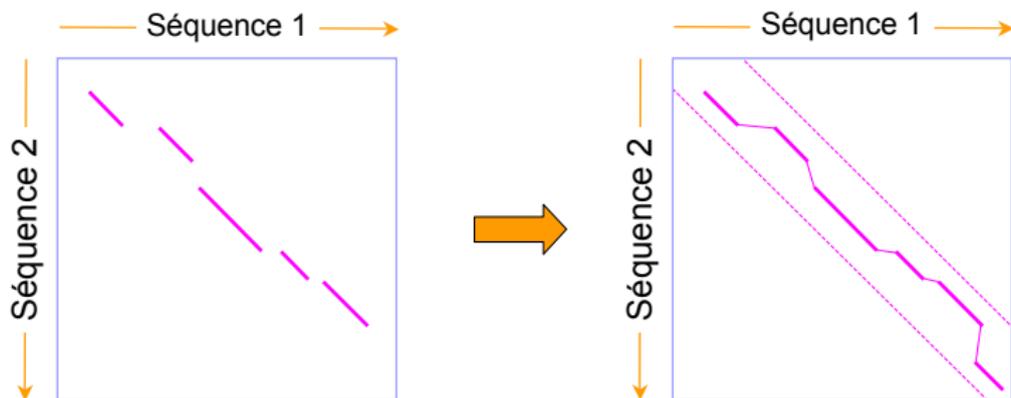
- Calcul de l'ensemble des alignements locaux en partant des mots communs détectés.
- Calcul des scores pour chaque alignement local puis élimination des scores les plus faibles.

Procédure d'alignement II



- Élimination des segments incompatibles avec le segment de score le plus élevé.
- Algorithme de programmation dynamique afin de joindre les segments entre eux, à l'intérieur d'une diagonale.

Procédure d'alignement II

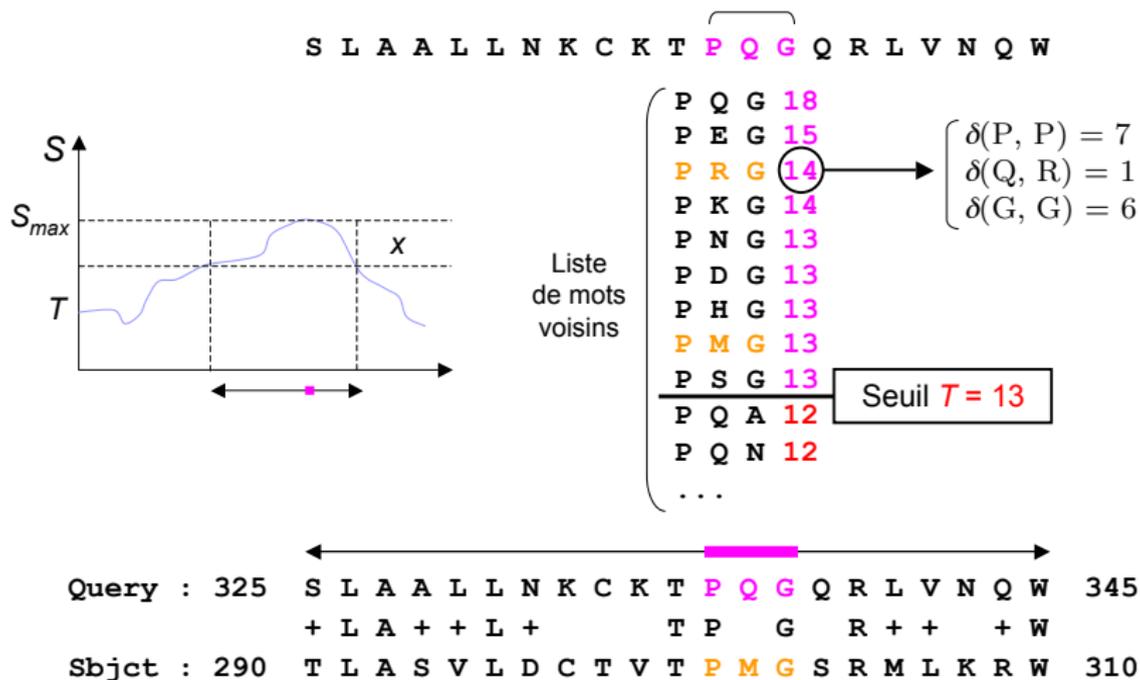


- Élimination des segments incompatibles avec le segment de score le plus élevé.
- Algorithme de programmation dynamique afin de joindre les segments entre eux, à l'intérieur d'une diagonale.

Principe général

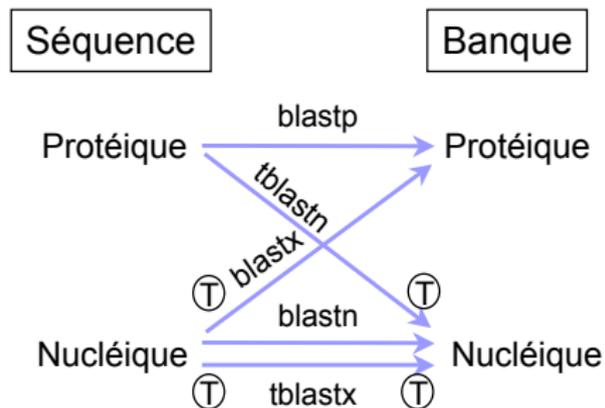
- Recherche de tous les mots de longueur w similaires entre la séquence requête et une séquence de la banque.
- Soit S , le score de ce mot au sens de la matrice de substitution utilisée (BLOSUM62 par défaut) :
 - Si $S \geq T$, extension du segment similaire (*High-scoring Segment Pair* – HSP) à droite et à gauche du mot.
 - Extension stoppée quand :
 - La fin d'une des deux séquences est atteinte.
 - $S \leq 0$.
 - $S \leq S_{\max} - x$.
 - Les valeurs de w , T , et x sont paramétrables par l'utilisateur :
 - Par défaut, $w = 3$ pour les séquences protéiques et $w = 7$ pour les séquences nucléotidiques.

Exemple



Versions

- blastp : protéine *vs.* protéine.
- blastn : utile pour le non-codant.
- blastx : identification de séquences codantes.
- tblastn : homologues dans un génome non complètement annoté.



Évaluation statistique

- Similarités détectées :
 - Distinguer les relations significatives des similarités dues au hasard.
- Évaluation de la significativité fondée sur :
 - Le score brut d'alignement observé (S).
 - Distribution de probabilité de ce score (loi de Gumbel).
- Mesure sous la forme :
 - Valeur en bits (S').
 - Espérance mathématique (E -value).
 - Probabilité (P -value).

Équivalences entre les scores I

- Tout d'abord le score en bits S' est donné par :

$$S' = (\lambda S - \ln K) / \ln 2$$

avec K et λ deux paramètres *d'échelle* dépendant de la matrice de substitution utilisée et des pénalités associées aux *gaps*.

- L'espérance mathématique E d'avoir par hasard une HSP dont le score d'alignement serait \geq au score brut observé est égale à :

$$E = Km'n'e^{-\lambda S}$$

avec m' et n' les tailles *effectives* de la séquence requête et de la banque, calculées à partir des valeurs réelles m et n .

Équivalences entre les scores II

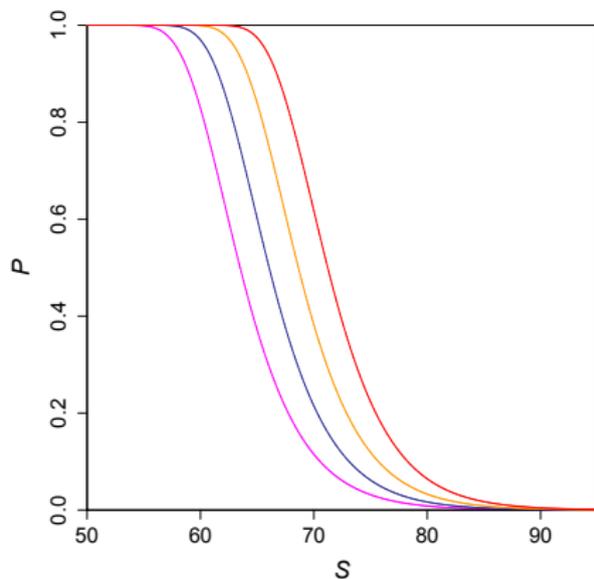
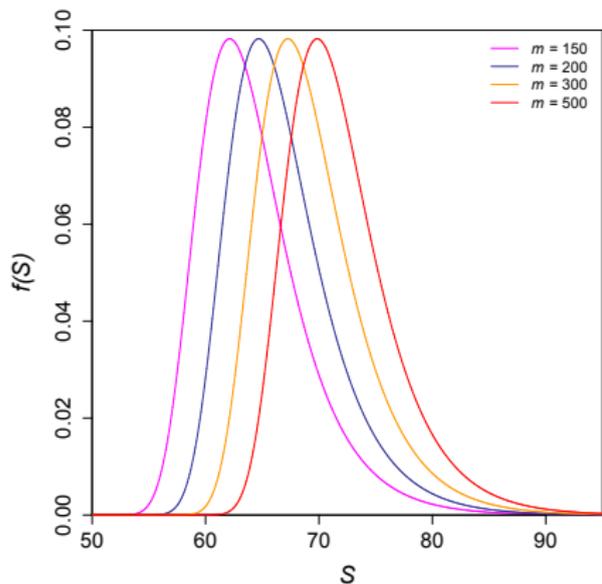
- La relation entre E et S' est donc telle que :

$$E = m'n'2^{-S'}$$

- Enfin, la probabilité P d'avoir par hasard un HSP dont le score d'alignement serait \geq au score brut observé est telle que :

$$P \simeq 1 - e^{-E}$$

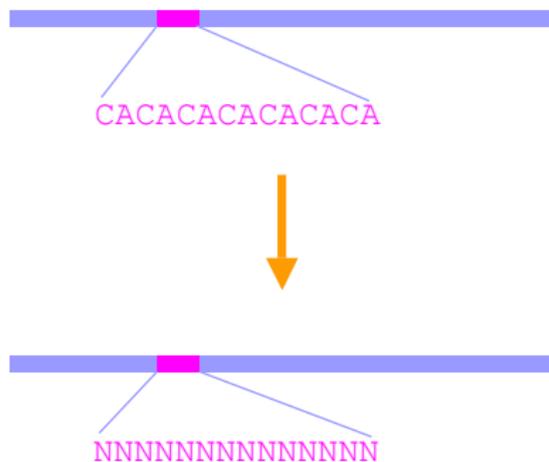
- Utilisation de E plutôt que de P dans les sorties de BLAST :
 - Différences plus directement compréhensibles (*e.g.*, $E = 5$ ou 10 au lieu de $P = 0.9933$ ou 0.99995).
 - A noter que $P \simeq E$ dès que $E \leq 0.01$.

Distribution des valeurs de S 

$n = 9418064$, $\delta_o(-) = -11$, $\delta_e(-) = -1$, BLOSUM62

Séquences abondantes

- Immunoglobulines :
 - > 127000 séquences dans GenBank.
- Séquences répétées :
 - 10^6 Alu et 10^5 L1 dans le génome humain.
- Programmes de masquage pour BLAST :
 - DUST, XNU, SEG, RepeatMasker.



Serveurs

- Il existe un grand nombre de serveurs permettant d'effectuer des recherches BLAST mais...
 - Toutes les options ne sont pas toujours accessibles.
 - Peu sont exhaustifs du point de vue des banques de données accessibles.
 - Tous ne permettent pas d'accéder à des banques mises à jour quotidiennement.
 - Les possibilités de filtrage pré- ou post-recherche sont rares et limitées.
 - Généralement pas de liens directs avec d'autres applications (*e.g.*, alignements multiples).

BLAST au NCBI

- Répond à (quasiment) toutes les questions précédentes :
 - Accès aux options.
 - Mises à jour en continu.
 - Filtrage taxonomique pré- et post-recherche.
 - Alignements multiples.
- Est particulièrement rapide.
- Bénéficie d'une interface graphique de visualisation des résultats.
- Est très sollicité!
 - Utilisation en matinée recommandée pour les européens si calculs lourds (*e.g.*, PSI-BLAST).

Quelle approche adopter ?

- Stratégie de recherche (nucléique ou protéique).
- Choix d'un algorithme.
- Banque sur laquelle effectuer la recherche.
- Choix de la matrice de substitution.
- Choix des paramètres (pondération des *gaps*, longueurs des mots, seuils, etc.)
- Traitement du bruit de fond.
- Répétition de la recherche.

Du bon usage de BLAST

- L'annotation par similarité peut conduire à certains abus...

```

MZEORFG      ILNSPDRACNLAKQAFDEAISELDSLGEESYKDSTLIMQLLXDNLTLWTSDTNEDGGDE
BOV1433P     IQNAPEQACLLAKQAFDDAIAELDTLNEDSYKDSTLIMQLLLRDNLTLWTSDQQDEEAGE
* * * : . ** ***** : ** * . * * : ***** ***** . : : *
  
```

Score = 87.4 bits (213), Expect = 1e-17
 Identities = 41/59 (69%), Positives = 50/59 (84%)

```

LOCUS      BOV1433P      1696 bp      mRNA                MAM      26-APR-1993
DEFINITION Bovine brain-specific 14-3-3 protein eta chain mRNA, complete
            cds.
  
```

```

LOCUS      MZEORFG      187 bp      mRNA                PLN      31-MAY-1994
DEFINITION Zea mays putative brain specific 14-3-3 protein, tau protein
            homolog mRNA, partial cds.
  
```

Similarités faibles

```

SéqA      CGRRLLILFMLATCGECDTDSSE-...-HICCIKQCDVQDIIRVCC
          || | | | | | | | | | | | | | | | | | | | |
SéqB      CGSHLVEALYLVCGERGFFYTP-...-EQCCTSIICSLYQLENYCN
          ||| | | | | | | | | | | | | | | | | |
SéqC      YQSHLLIVLLAITLECFFSDRK-...-KRQWISIFDLQTLRPMTA
  
```

- Les comparaisons par paires présentent des limitations dans le cas de similarités limitées à quelques acides aminés :
 - Paire (A, B) : 25% d'identité.
 - Paire (B, C) : 25% d'identité.
 - Triplet (A, B, C) : < 5% d'identité.

Recherche par profils

- Recherche d'un ensemble d'homologues proches.
- Alignement de ces homologues entre eux.
- Calcul d'une matrice de score position-spécifique (ou *profil*) à partir de l'alignement entier ou d'une région définie :
- Recherche dans la banque en utilisant la matrice au lieu de la séquence :
 - Sélection des *hits* ayant un score supérieur à un seuil.
- Éventuellement, modification itérative de la matrice en incorporant les séquences détectées.

Construction de la matrice

- Soit π_i la fréquence du résidu i dans l'ensemble des séquences utilisées pour construire le profil.
- Soit n le nombre de séquences dans l'alignement et n_{ik} le nombre de résidus i à la position k de l'alignement.
- Positions contenant un ou plusieurs *gaps* :
 - Soit ignorées, soit prises en compte en considérant qu'un *gap* constitue un état de caractère supplémentaire.
- Calcul du score δ_{ik} associé au résidu i à la position k :

$$\delta_{ik} = 2 \log_2 \left[\frac{n_{ik} + 1}{\pi_i (n + 1)} \right]$$

avec arrondissement à l'entier le plus proche.

Exemple de construction

```

AGGCGTGGGGTATAAGTTAG
GTGCGGGTATAAGGGCAGCC
TGGGACTATATGAGCCCGAG
CCGGCGCACATAAAGGCCCG
GGGCGTTATAAGCCGCCGCG
TATGCACCTCCTATAAGACT
AGATCAATAAAAGGGGGCGT
CACTTCGCATATTAAGGTGA
CCGCATTTAAGGCGTTGTTG
CGGGTTGGCACAAAAAGACC

```

Famille de séquences



```

-AGGCGTGGGGTATAAGTTAG-----
-----GTGCGGGTATAAGGGCAGCC-----
-----TGGGACTATATGAGCCCGAG-----
---CCGGCGCACATAAAGGCCCG-----
-----GGGCGTTATAAGCCGCCGCG-----
TATGCACCTCCTATAAGACT-----
-----AGATCAATAAAAGGGGGCGT-----
--CACTTCGCATATTAAGGTGA-----
-----CCGCATTTAAGGCGTTGTTG-----
---CGGGTTGGCACAAAAAGACC-----

```

Alignement



A	-1	-2	2	-4	2	2	1	1	-2	-2
C	4	3	-1	1	-1	-1	-1	-1	1	4
G	2	-1	-3	-3	-3	-3	2	1	3	1
T	-3	2	-1	4	0	1	-3	-1	-1	0

Matrice de score



A	2	1	9	0	8	7	6	6	1	1
C	4	3	0	1	0	0	0	0	1	4
G	4	1	0	0	0	0	4	3	7	3
T	0	5	1	9	2	3	0	1	1	2

Matrice des fréquences

Exemples de recherche

Base	Position									
	1	2	3	4	5	6	7	8	9	10
A	-1	-2	2	-4	2	2	1	1	-2	-2
C	4	3	-1	1	-1	-1	-1	-1	1	4
G	2	-1	-3	-3	-3	-3	2	1	3	1
T	-3	2	-1	4	0	1	-3	-1	-1	0

$$S_{\max} = 27$$

Matrice de pondération

G C A G T A T A A G G G G A . . .

Fenêtre
glissante

G C A G T A T A A G

$$S = +2 + 3 + 2 - 3 + 0 + 2 - 3 + 1 - 2 + 1 = +3$$

. C A G T A T A A G G

$$S = +4 - 2 - 3 + 4 + 2 + 1 + 1 + 1 + 3 + 1 = +12$$

. . A G T A T A A G G G

$$S = -1 - 1 - 1 - 4 + 0 + 2 + 1 + 1 + 3 + 1 = +1$$

. . . G T A T A A G G G G

$$S = +2 + 2 + 2 + 4 + 2 + 2 + 2 + 1 + 3 + 1 = +21$$

. . . . T A T A A G G G G A

$$S = -3 - 2 - 1 - 4 + 2 - 3 + 2 + 1 + 3 - 2 = -7$$

Exemples de recherche

Base	Position									
	1	2	3	4	5	6	7	8	9	10
A	-1	-2	2	-4	2	2	1	1	-2	-2
C	4	3	-1	1	-1	-1	-1	-1	1	4
G	2	-1	-3	-3	-3	-3	2	1	3	1
T	-3	2	-1	4	0	1	-3	-1	-1	0

$$S_{\max} = 27$$

Matrice de pondération

G	A	A	A	G	G	T	G	A	G	T	C	A	T	...
---	---	---	---	---	---	---	---	---	---	---	---	---	---	-----

Fenêtre glissante

G A A A G G T G A G

$$S = +2 - 2 + 2 - 4 - 3 - 3 - 3 + 1 - 2 + 1 = -11$$

. A A A G G T G A G T

$$S = -1 - 2 + 2 - 3 - 3 + 1 + 2 + 1 + 3 + 0 = 0$$

. . A A G G T G A G T C

$$S = -1 - 2 - 3 - 3 + 0 - 3 + 1 + 1 - 1 + 4 = -7$$

. . . A G G T G A G T C A

$$S = -1 - 1 - 3 + 4 - 3 + 2 + 2 - 1 + 1 - 2 = -2$$

. . . . G G T G A G T C A T

$$S = +2 - 1 - 1 - 3 + 2 - 3 - 3 - 1 - 2 + 0 = -10$$

Test de significativité

- Soit S_{obs} , le meilleur score observé sur une séquence requête :
 - Dans notre exemple $S_{\text{obs}} = 21$.
- Génération de B séquences aléatoires ($B \geq 100$) :
 - Même longueur et même composition que la séquence requête.
 - Soit b , le nombre de ces séquences où l'on observe un score $S \geq S_{\text{obs}}$.
 - Dans ce cas la mesure de la significativité est donnée par :

$$\mathbb{P}(S \geq S_{\text{obs}}) = b/B$$

- Dans notre exemple, pour $B = 1000$, une seule séquence générée aléatoirement avait un score $S \geq 21$:

$$\mathbb{P}(S \geq 21) = 1/1000$$

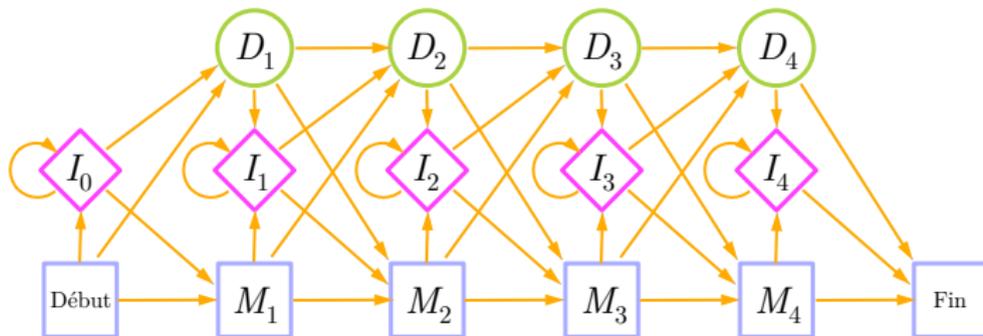
PSI-BLAST

■ *Position-Specific Iterated* BLAST :

- ➊ Recherche BLAST classique.
- ➋ Calcul d'un profil au moyen des *hits* significatifs sélectionnés par l'utilisateur (utilisation de la *E*-value).
- ➌ Nouvelle recherche en utilisant le profil.
- ➍ Répétition des étapes 2-3 jusqu'à convergence.

Profils généralisés

- Intègrent des modèles de Markov cachés (*Hidden Markov Models* – HMM) au cours de la construction du profil :
 - Meilleure prise en compte des *indels*.
- Programmes disponibles :
 - PFSEARCH (Bücher *et al.*, 1996) :
 - HMMER (Eddy, 1998) :



Alignements multiples

■ Généralisation de Needleman et Wunsch ?

- Pour n séquences de longueur ℓ :
 - Complexité en $O(\ell^n)$.
 - Croissance exponentielle du temps de calcul et de l'espace mémoire.

■ Utilisation d'heuristiques :

- Approximation de l'alignement optimal.

n	t	t
2	0.01 sec	10^{-4} sec
3	1.5 sec	0.015 sec
4	225 sec	2.25 sec
5	9h22 min	5.6 min
6	58 jours	14.06 h
7	24 ans	87.9 jours
8	3612 ans	36 ans

Temps de calcul pour aligner n séquences de longueur $\ell = 150$

Principe de l'alignement progressif

- Construction itérative par ajout progressif de séquences :
 - Établissement d'une *matrice de distances* entre toutes les paires possibles de séquences.
 - Construction d'un *arbre guide* à partir de cette matrice.
 - Ajout de paires et/ou de séquences individuelles dans l'alignement en remontant dans la structure de cet arbre.
- Nombreuses implémentations disponibles :
 - Clustal (Higgins *et al.*, 1988).
 - T-Coffee (Notredame *et al.*, 2000).
 - Mafft (Katoh *et al.*, 2002).
 - Muscle (Edgar, 2004).
 - ProbCons (Do *et al.*, 2005).

Procédure de Clustal

- Alignement de toutes les paires possibles au moyen d'une heuristique de l'algorithme de Needleman et Wunsch.
- Construction d'une matrice de distance en utilisant les scores d'alignement par paires.
- Construction de l'arbre guide en utilisant cette matrice :
 - La 1^{ère} paire regroupe les deux séquences présentant la distance la plus faible.
 - L'alignement en question est « fixé » et ne changera plus par la suite :
 - Si un *gap* doit être introduit, il le sera à la même position dans les deux séquences.
 - Application du même principe pour toutes les séquences ajoutées par la suite.

Illustration

SéqB	0.17			
SéqC	0.59	0.60		
SéqD	0.59	0.59	0.13	
SéqE	0.77	0.77	0.75	0.75
	SéqA	SéqB	SéqC	SéqD

Hélices α

A	PEEKSAVTALWGKVN--VDEVGG	} 2	} 3	} 4
B	GEEKA AVLALWDKVN--EEEVGG			
C	PADKTNVKA AWGKVG AHAGEYGA	} 1	} 3	} 4
D	AADKTNVKA AWSKVGGHAGEYGA			
E	EHEWQLV LHVWAKVEADVAGHGQ			

Calcul de tous les alignements simples et construction de la matrice de distance



Arbre guide par *Neighbour-joining*



Alignement progressif

Pondérations initiale des *gaps*

- Fonction affine pour les *gaps* dans les alignements par paires.
- Correction des valeurs de $\delta_o(-)$ et $\delta_e(-)$ en fonction de différents facteurs :
 - Le degré de similarité entre les séquences :

$$\delta_o(-) \propto \% \text{ identité}(A, B)$$

- La longueur des séquences :

$$\delta_o(-) \propto \log[\min(m, n)]$$

- La différence de longueur entre les séquences :

$$\delta_e(-) \propto 1.0 + |\log(n/m)|$$

Pondérations supplémentaires

- Prises en compte au moment du groupement des alignements :
 - Diminution de la pénalité à l'emplacement de *gaps* préexistants.
 - Augmentation de la pénalité au voisinage (8 résidus) de *gaps* préexistants.
 - Réduction de la pénalité au niveau de régions contenant une suite d'acides aminés hydrophiles (≥ 5 résidus) :
 - Lien avec la structure 3D des protéines globulaires.
 - Modification spécifiques en fonction des acides aminés présents (*e.g.*, la pénalité est plus faible avec Gly, Asn, Pro).

Le succès de Clustal

- Fut l'un des tous premiers programmes réellement utilisable disponibles (1^{ère} version en 1988).
- Temps de calcul raisonnable pour des jeux de données de taille importante ($n \leq 500$).
- Fonctionnalité de calcul d'arbres phylogénétiques (méthode du *Neighbour-Joining*) avec *bootstrap*.
- Utilisable sur la quasi-totalité des architectures disponibles à l'époque :
 - Windows, Unix/Linux, MacOS, VMS.
- Interface graphique (ClustalX).

Limitations

- Perte de l'optimalité au moment du regroupement des paires :
 - Existence de minima locaux.
 - Importance de l'ordre dans lequel sont regroupées les séquences.
 - Impossibilité de corriger ces erreurs par la suite.
- Pas de fonction objective :
 - Impossibilité de déterminer la qualité de l'alignement.
- Désormais beaucoup moins performant que ses concurrents directs :
 - Développement d'une nouvelle version appelée Clustal Ω (Sievers *et al.*, 2011).

Importance de l'arbre guide

SéqA	GARFIELD THE LAST FAT CAT	SéqB	GARFIELD THE ---- FAST CAT
SéqB	GARFIELD THE FAST CAT ---	SéqC	GARFIELD THE VERY FAST CAT
SéqA	GARFIELD THE LAST FA-T CAT	SéqB	GARFIELD THE FAST CAT
SéqC	GARFIELD THE VERY FAST CAT	SéqD	----- THE FA-T CAT
SéqA	GARFIELD THE LAST FAT CAT	SéqC	GARFIELD THE VERY FAST CAT
SéqD	----- THE ---- FAT CAT	SéqD	----- THE ---- FA-T CAT

Alignement par paires



Arbre guide



SéqA GARFIELD THE LAST FA-T CAT
 SéqB GARFIELD THE FAST CA-T ---
 SéqC GARFIELD THE VERY FAST CAT
 SéqD ----- THE ---- FA-T CAT

Alignement multiple

Alignement progressif

Contraintes de consistance

- Utilisées pour améliorer les méthodes d'alignement progressif.
- Prise en compte de combinaisons consistantes de séquences :
 - Données intrinsèques (alignements par paires et par triplets).
 - Données extrinsèques (*e.g.*, structures 3D).
- Introduites dans différents programmes :
 - T-Coffee (Notredame *et al.*, 2000).
 - ProbCons (Do *et al.*, 2005).
 - ProbAlign (Roshan et Livesay, 2006).

Stratégie de T-Coffee

SéqA	GARFIELD	THE	LAST	FAT	CAT
SéqB	GARFIELD	THE	FAST	CAT	---
SéqA	GARFIELD	THE	LAST	FA-T	CAT
SéqC	GARFIELD	THE	VERY	FAST	CAT
SéqA	GARFIELD	THE	LAST	FAT	CAT
SéqD	-----	THE	----	FAT	CAT

SéqB	GARFIELD	THE	----	FAST	CAT
SéqC	GARFIELD	THE	VERY	FAST	CAT
SéqB	GARFIELD	THE	FAST	CAT	
SéqD	-----	THE	FA-T	CAT	
SéqC	GARFIELD	THE	VERY	FAST	CAT
SéqD	-----	THE	----	FA-T	CAT

Alignements par paires de départ

SéqA	GARFIELD	THE	LAST	FAT	CAT
SéqB	GARFIELD	THE	FAST	CAT	

SéqA	GARFIELD	THE	LAST	FAT	CAT
SéqC	GARFIELD	THE	VERY	FAST	CAT
SéqB	GARFIELD	THE		FAST	CAT

SéqA	GARFIELD	THE	LAST	FAT	CAT
SéqD		THE		FAT-CAT	
SéqB	GARFIELD	THE		FAST	CAT



SéqA	GARFIELD	THE	LAST	FAT	CAT
SéqB	GARFIELD	THE		FAST	CAT



SéqA	GARFIELD	THE	LAST	FAT	CAT
SéqB	GARFIELD	THE	FAST	---	CAT

Alignement A-B retenu

Aminoacyl-ARNt synthétases d'*E. coli*

```

SYL_ECOLI  HMGHVRNYTIGDVIARYQRMGLKGNVLQPIGWDAFGLPAEGAAVKNNTPA-----/.../
SYV_ECOLI  HMGHAFQQTIMDTMIRYQRMQGKNTLWQVGDHAGIATQMVVERKIAAEEGKTRHDYGRE/.../
SYI_ECOLI  HIGHSVNKKILKDIIVKSKGLSGYDSPYVPGWDCHGLPIELKVEQEYKPGK---EKFTAA/.../
SYM_ECOLI  HLGHMLEHIQADVWVRYQRMRGHEVNFICADDAHGTPIMLKAQQLGITPE---Q-----/.../
*:*:  :  *  :  :  :  *  :  .  *  *  .  .  :

```

```

SYL_ECOLI  LVYTGMSKMSKSKNNGIDPQVMVER-----
SYV_ECOLI  -----KMSKSKGNVIDPLDMVDGISLPELLEKRTGNMMQPQLADKIRKRTEKQFPNGI
SYI_ECOLI  -----KMSKSI GNTVSPQDVMNK-----
SYM_ECOLI  -----KMSKSRGTFIKASTWLNH-----
***** .. :.. :

```

Alignement de T-Coffee

```

SYL_ECOLI  HMGHVRNYTIGDVIARYQRMGLKGNVLQPIGWDAFGLPAEGAAVKNNTPAP-----/.../
SYV_ECOLI  HMGHAFQQTIMDTMIRYQRMQGKNTLWQVGDHAGIATQMVVERKIAAEEGKTRHDYGRE/.../
SYI_ECOLI  HIGHSVNKKILKDIIVKSKGLSGYDSPYVPGWDCHGLPIELKVEQEYKPGEK---FTAA/.../
SYM_ECOLI  HLGHMLEHIQADVWVRYQRMRGHEVNFICADDAHGTPIMLKAQQLGITPEQMIG-----/.../
*:*:*:  :  *  :  :  :  *  :  .  *  *  .  .  :

```

```

SYL_ECOLI  MHLLYFRFFHKLMRDAGMVNSDEPAKQLLCQG--MVLADAFYYVGENGERNVVS-----
SYV_ECOLI  EGQKMSKSKGNVIDPLDMVDGISLPELLEKRTGNMMQPQLADKIRKRTEKQFPNGIEPHG
SYI_ECOLI  APYRQVLTHGFVTDGQGRKMSKSI GNTVSPQD-----VMNKLGADILRLWVASTDYTG
SYM_ECOLI  -----

```

Alignement de Clustal

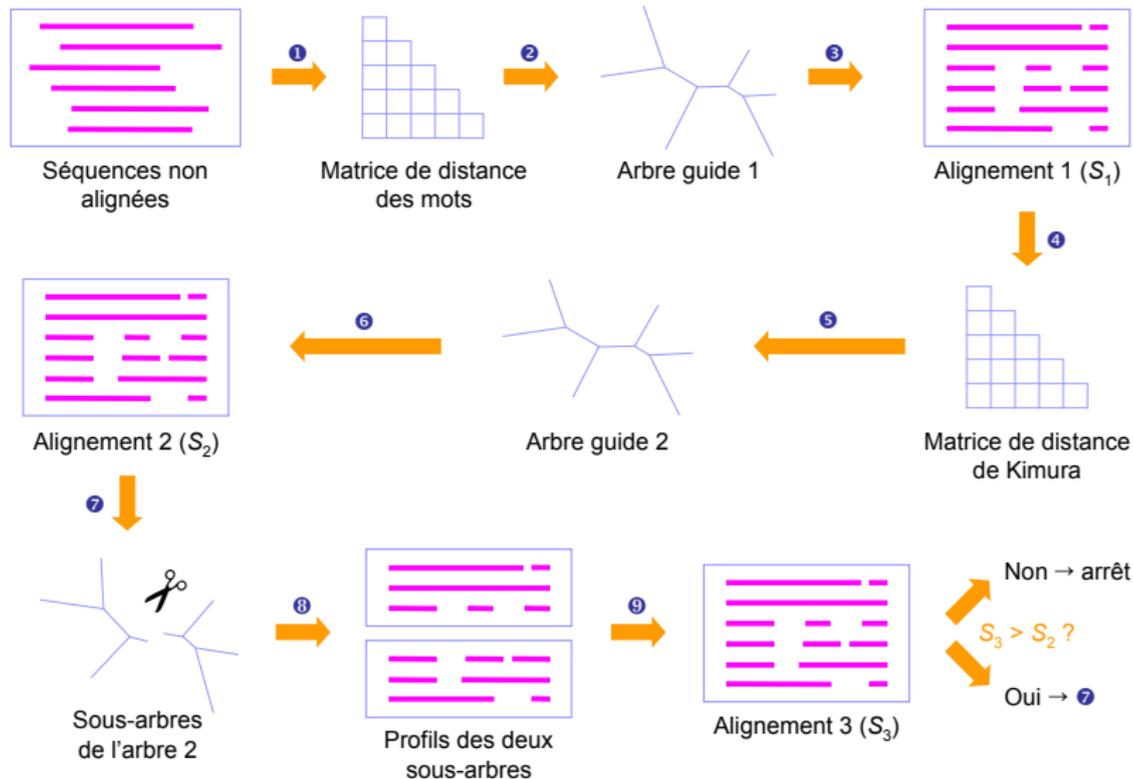
Interêt et limitations

- Résultats très supérieurs à ceux de ClustalW.
- Possibilité d'améliorer les alignements en utilisant des données structurales.
- Intègre une fonction objective d'évaluation de la qualité des alignements.
- Très gourmand en mémoire et en temps de calcul :
 - Jeux de données de taille limitée ($n \leq 100$).

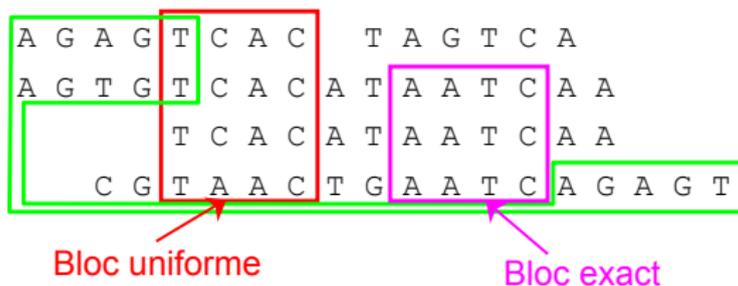
Amélioration par itération

- Premier alignement par la méthode progressive.
- Raffinements successifs de l'alignement de départ jusqu'à convergence.
- Implémentation la plus performante réalisée dans le programme Muscle :
 - Rapide.
 - Peut travailler sur des jeux de données de très grande taille (plusieurs milliers de séquences).
 - Bon résultats en terme de qualité des alignements.

Procédure de Muscle



Alignement par blocs

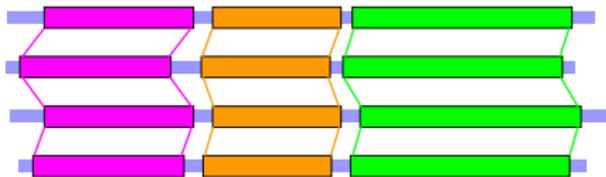


- Recherche des blocs similaires sans *gaps*.
- Sélection de la meilleure combinaison de blocs compatibles entre eux (heuristique).
- Plus lent que les alignements progressifs.
- Implémentation disponible :
 - Dialign2 (Subramanian *et al.*, 2008).

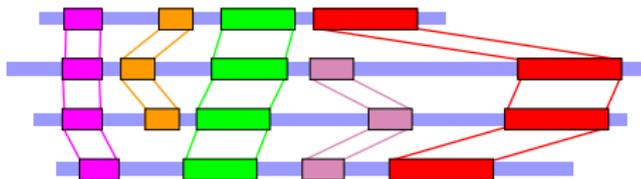
Jeux de données de référence

- Banques créées manuellement, souvent à partir d'alignements structuraux :
 - BALiBASE (Thompson *et al.*, 1999).
 - PALI (Balaji *et al.*, 2001).
 - OXBench (Raghava *et al.*, 2003).
 - PREFAB (Edgar, 2004).
 - SABmark (Van Walle *et al.*, 2005).
 - HomFam (Blackshields *et al.*, 2010).
- Utilisées pour évaluer la qualité des algorithmes disponibles :
 - Certains programmes « passent » mieux sur certaines références que sur d'autres.

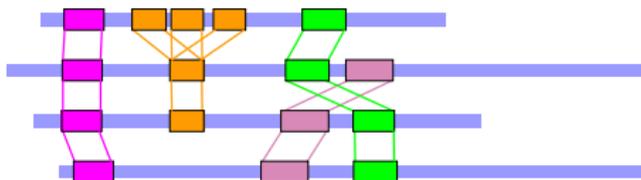
Programmes recommandés



Clustal
Multalin



Dialign2
Muscle
T-Coffee



Match-Box
MEME
PIMA

Cas particuliers

- Alignement de séquences codantes :
 - SeaView (Gouy *et al.*, 2010) :
 - Alignement des séquences protéiques.
 - Calage du nucléique sur l'alignement protéique.
- Alignement ADNc / ADN génomique :
 - SIM4 (Florea *et al.*, 1998).
- Alignement protéine / ADN :
 - GeneWise (Birney *et al.*, 2004).

Quelques conseils

- Considérez les résultats avec recul.
- Pour la phylogénie, n'utilisez que les sites pour lesquels l'hypothèse d'homologie est vraisemblable.
- Essayez d'identifier les régions dont vous pensez qu'elles sont correctement alignées :
 - Un alignement multiple peut (parfois) être amélioré « à la main » à l'aide d'un éditeur :
 - SeaView, STRAP, CINEMA, etc.
 - Il existe des programmes permettant de filtrer automatiquement les régions mal alignées :
 - Gblocks, TrimAl, BMGE, Guidance, etc.