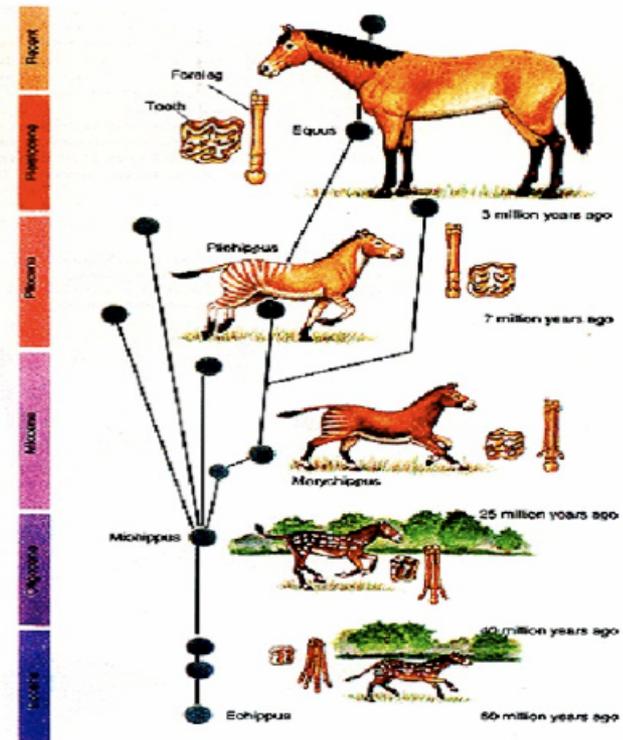


# PARTIE I : Phylogénie moléculaire

PARTIE I : Phylogénie moléculaire

**POURQUOI RÉALISER UNE PHYLOGÉNIE ?**

- Histoire de l'évolution
  - reconstruire l'histoire des espèces  
(→ paléontologie)



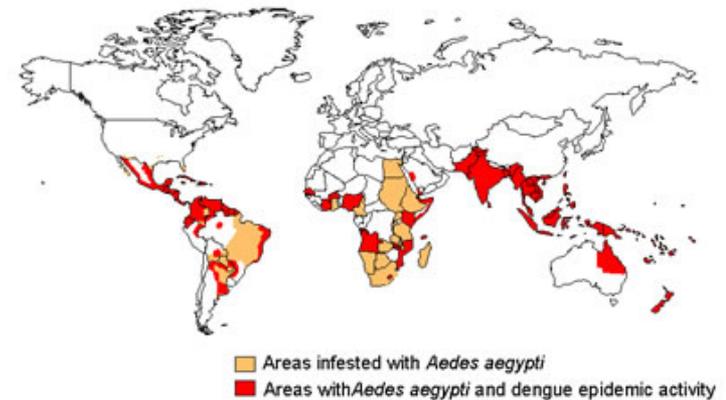
- Histoire de l' évolution
- Evolution des caractères
  - comprendre la mise en place des plans d'organisation
  - évolution-développement



# Pourquoi réaliser une phylogénie ?

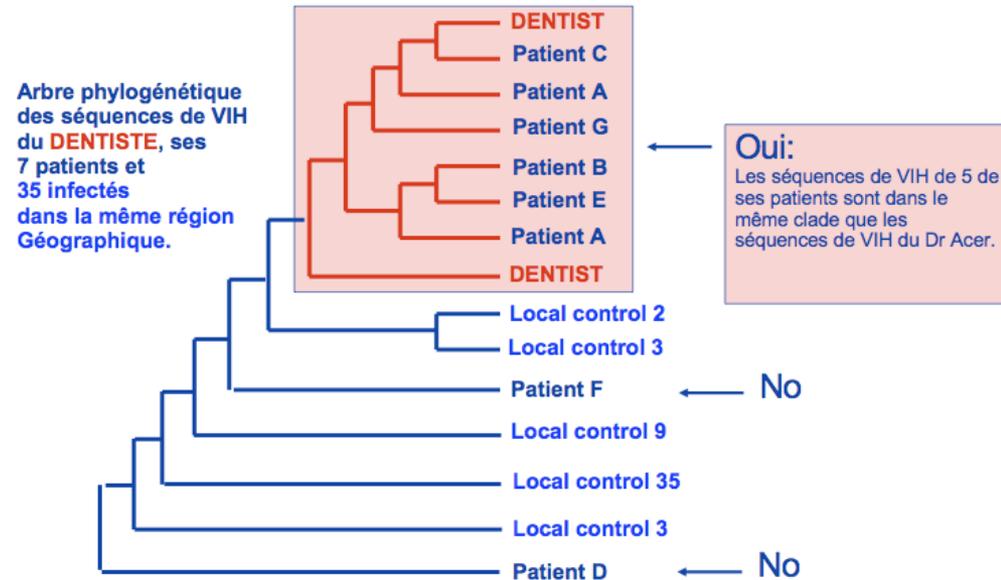
- Histoire de l' évolution
- Evolution des caractères
- Bio- écologie
  - Déplacement des espèces
  - Relations hôtes-parasites
  - mesurer/appréhender la biodiversité
  - gestion, conservation des écosystèmes

World Distribution of Dengue - 2005



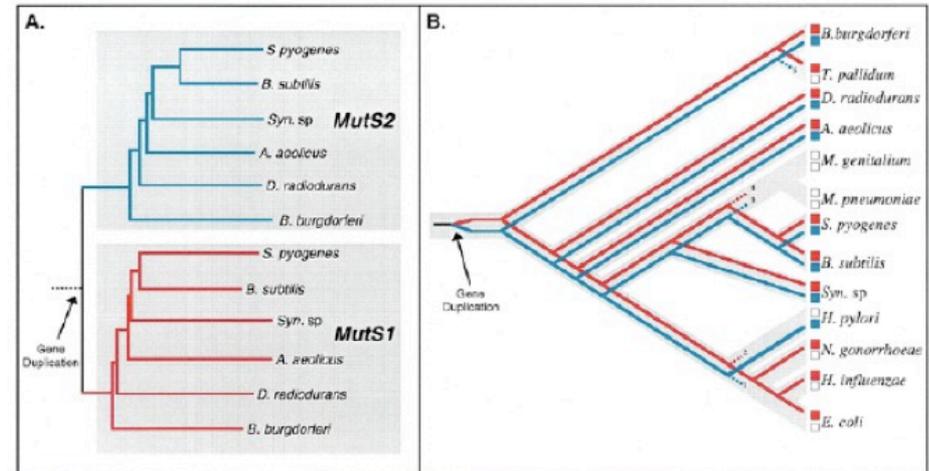
# Pourquoi réaliser une phylogénie ?

- Histoire de l' évolution
  - Evolution des caractères
  - Bio- écologie
  - Epidémiology, microbiologie, virologie
- caractériser la dynamique d' interactions durables



# Pourquoi réaliser une phylogénie ?

- Histoire de l' évolution
- Evolution des caractères
- Bio- écologie
- Epidémiology
- Evolution des gènes au sein des espèces
  - caractériser les gènes de l'adaptation
  - amélioration des espèces domestiquées

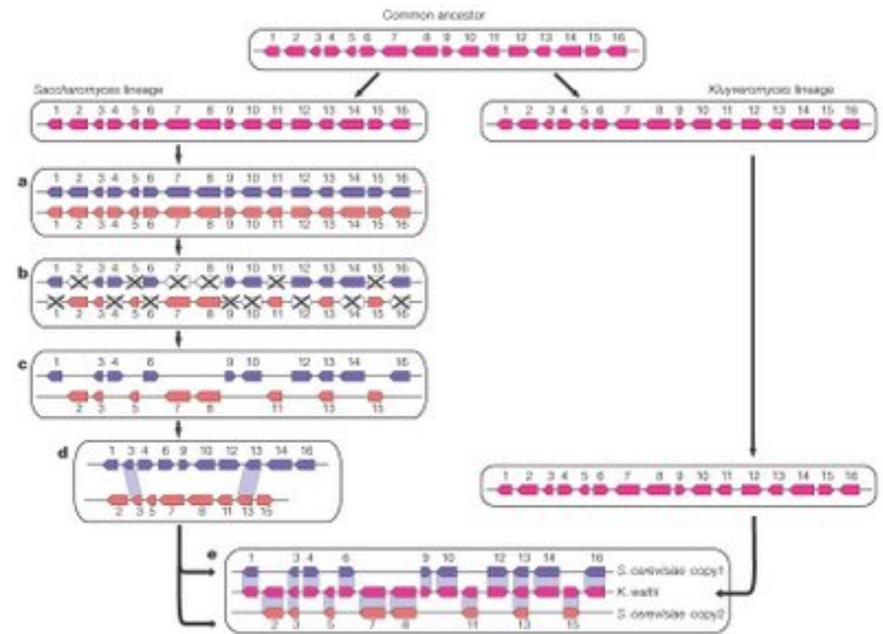


A. Arbre de gène

B. L'arbre de gènes superposé à un arbre d'espèces pour identifier les pertes de gènes.

# Pourquoi réaliser une phylogénie ?

- Histoire de l' évolution
- Evolution des caractères
- Bio- écologie
- Epidémiology
- Evolution des gènes au sein des espèces
- Annotation des génomes (Genomique fonctionnelle)
  - comprendre les mécanismes de l'évolution moléculaire (→ génomique structurale)



# Pourquoi réaliser une phylogénie ?

Deux domaines d'application majeurs :

- Reconstruire l'histoire évolutive de taxons, caractères ou de gènes.
  
- Analyse de caractères et de vitesses d' évolution

## PARTIE I : Phylogénie moléculaire

# LES ÉLÉMENTS D'UNE PHYLOGENIE

- Les caractères
- Le jeu de données
- Les banques
- Les alignements
- Les arbres

Cinq étapes de l'analyse phylogénétique

1. Choix du jeu de données
  - Une bonne connaissance des séquences que l'on analyse
  - S'assurer de la validité du jeu de donnée (qualité des séquences et cohérence du JDD)
  
2. Alignement des séquences
  - Obtenir un bon alignement
  - Tester différentes méthodes et revenir à la main sur les résultats
  
3. Détermination du modèle de substitution
4. Construction des arbres
5. Evaluation des arbres

## PARTIE I : Phylogénie moléculaire

# LES ÉLÉMENTS D'UNE PHYLOGENIE

- Les caractères
- Le jeu de données
- Les banques
- Les alignements
- Les arbres

- **1 Description et codage des états.**

Présence absence : +/-; 0/1; a/b

Etats multiples :

Les 20 acides aminés

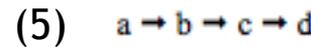
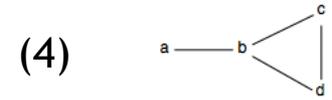
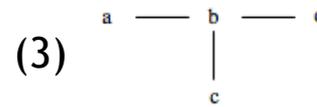
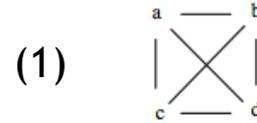
Les 4 nucléotides A,T,C,G

Nb de répétitions en tandem (microsatellites)

Morphologie (a, b, c, d, ...)

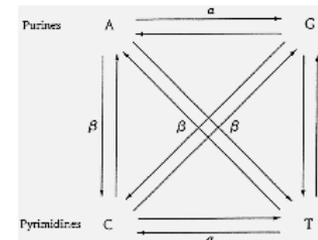
- **2 Transformation des états**

- Non additives <sup>(1)</sup>
- Additives (ou ordonnées)
  - Linéaires <sup>(2)</sup>
  - Non linéaires <sup>(3)</sup>
  - Complexes <sup>(4)</sup>
- Polarisées (ou orientées) <sup>(5)</sup>



- **3 Pondérations**

- Des transformations (PAM/JTT ou ts/tv)
- Des caractères



Au début les modes de classifications des espèces étaient:

- Les comparaisons morphologiques
- Les comparaisons comportementales
- Les répartitions géographiques

## Morphologie vs. Données moléculaires



**African white-backed vulture**  
(old world vulture)



**Andean condor**  
(new world vulture)

Les vautours du vieux et du nouveau monde semblent être étroitement liés sur la base de leur morphologie

Les données moléculaires indiquent que les vautours du vieux monde sont liées à des oiseaux de proie (faucons, éperviers, etc), tandis que les vautours du Nouveau Monde sont plus étroitement liés à des cigognes

C'est un exemple de convergence évolutive

Au début les modes de classifications des espèces étaient:

- Les comparaisons morphologiques
- Les comparaisons comportementales
- Les répartitions géographiques

Aujourd'hui les phylogénies sont obtenues à partir:

- des séquences moléculaires (phylogénie moléculaire) : ADN, ARN, Protéines, Codons
- des caractères discrets (présence, absence, 0, 1)
- des fréquences des gènes
- des traits quantitatifs
- des sites de restriction, RFLP
- des microsatellites, SNP

## PARTIE I : Phylogénie moléculaire

# LES ÉLÉMENTS D'UNE PHYLOGENIE

- Les caractères
- **Le jeu de données**
- Les banques et formats
- Les alignements
- Les arbres

Les séquences d'ADN présentent beaucoup d'avantages face aux caractères de taxonomie morphologiques:

- L'état des caractères peut être déterminé sans ambiguïté
- Un grand nombre de caractères peuvent être pris en compte pour chaque individu

Inconvénients :

- Peu d'états donc possibilité de mutations silencieuses (homoplasie)
- Arbre de gène vs Arbre de génome (cad arbre de espèces)
- Alignements de qualité difficile à obtenir

Utilisation de méthodes mathématiques permettant de nous donner la représentation la moins fautive possible.

- Cas de la phylogénie d'espèces
  - il faut choisir le marqueur moléculaire approprié au groupe taxonomique étudié.
- Critères du choix d'un marqueur:
  - universalité
  - structure conservée
  - absence de transfert génétique
  - taux d'évolution approprié
  - absence de biais sélectif
- Quelques exemples:
  - phylogénie de bactéries (16S rDNA)
  - phylogénie d'eucaryotes (18S rDNA, actine, EF1, RPB1(RNA polymerase))
  - phylogénie de plantes (rbcL(ribulose carboxylase), 18S rDNA)
- Phylogénie d'animaux
  - niveau phylum, classe, ordre : (18S rDNA, génome mt)
  - niveau famille : (RAG2(recombination activating gene 2), 12S, 16S mt)
  - niveau genre : (ITS, protéines mt)
  - niveau intra-spécifique : (D-Loop, introns)

- JDD :
  - Eviter les **séquences incomplètes**
  - Eviter les **xénologues** (transfert latéraux)
  - Eviter les **séquences recombinantes** (2 ancêtres)
  - Eviter les grandes familles complexes (répétitions et nombres de domaines importants)
  - **Ajouter un groupe externe** (outgroup)
- **ADN ou protéines :**
  - Quand cela est possible travailler préférentiellement avec des alignement de protéines en particulier lorsque les séquences d'ADN diffèrent de plus 70%. Si les séquences protéiques sont trop proches revenir à l'ADN.
- **Intégralité ou partie du JDD:**
  - Préférer des **JDD réduits** (peu de taxons) -> moins source d'erreur et moins temps pour l'analyse.
  - Ne pas obligatoirement inclure tous les caractères :
    - Supprimer les caractères incertains
    - Supprimer les zones trop variables: parties 3', 5', zones riches en gap.

- Constituer son jeu de données
  - Plan d'expérience (prélèvements, amplification, séquençage ...)
  - Collecte dans les banques de données

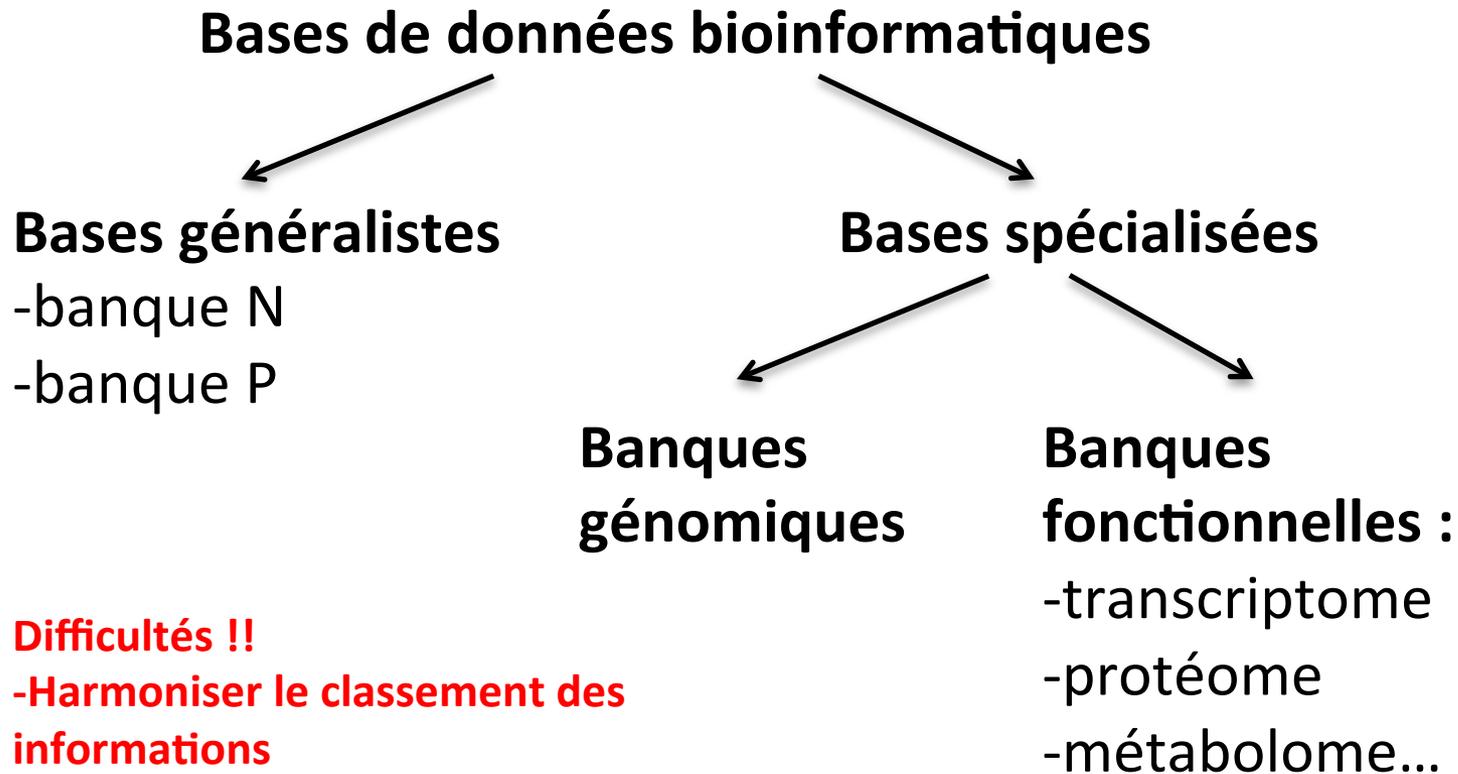


## PARTIE I : Phylogénie moléculaire

# LES ÉLÉMENTS D'UNE PHYLOGENIE

- Les caractères
- Le jeu de données
- **Les banques et formats**
- Les alignements
- Les arbres

Différentes catégories de bases de données :



**Difficultés !!**

**-Harmoniser le classement des informations**

**-Utiliser un langage commun pour échanger des informations entre toutes ces bases**

## Types de données

Bases de séquences	Adresse
<ul style="list-style-type: none"> <li><b>Bases génériques (multi-organismes)</b></li> </ul>	
EMBL / trEMBL	<a href="http://www.ebi.ac.uk/embl/">http://www.ebi.ac.uk/embl/</a>
Genbank / GenPept	<a href="http://www.ncbi.nlm.nih.gov/entrez">http://www.ncbi.nlm.nih.gov/entrez</a>
DDBJ (DNA Data Bank of Japan)	<a href="http://www.ddbj.nig.ac.jp/">http://www.ddbj.nig.ac.jp/</a>
SwissProt	<a href="http://www.expasy.org/sprot/">http://www.expasy.org/sprot/</a>
<ul style="list-style-type: none"> <li><b>Bases spécialisées (organisme)</b></li> </ul>	
GenoList	<a href="http://genodb.pasteur.fr/cgi-bin/WebObjects/GenoList">http://genodb.pasteur.fr/cgi-bin/WebObjects/GenoList</a>
Cyanobase	<a href="http://www.kazusa.or.jp/cyano/">http://www.kazusa.or.jp/cyano/</a>
TAIR (The Arabidopsis Information Resource)	<a href="http://www.arabidopsis.org">http://www.arabidopsis.org</a>
FlyBase (Database of the Drosophila Genome)	<a href="http://flybase.bio.indiana.edu/">http://flybase.bio.indiana.edu/</a>
MGD (Mouse Genome Database)	<a href="http://www.informatics.jax.org/">http://www.informatics.jax.org/</a>
GDB (Human Genome data Base)	<a href="http://gdbwww.gdb.org/">http://gdbwww.gdb.org/</a>
<ul style="list-style-type: none"> <li><b>Bases spécialisées (thématique)</b></li> </ul>	
PROSITE (proteins families and domains)	<a href="http://prosite.expasy.org">http://prosite.expasy.org</a>
PRINTS (protein fingerprints : group of motifs)	<a href="http://www.bioinf.manchester.ac.uk/dbbrowser/PRINTS/index.php">http://www.bioinf.manchester.ac.uk/dbbrowser/PRINTS/index.php</a>
EPD (Eukaryotic Promoter Database)	<a href="http://epd.vital-it.ch">http://epd.vital-it.ch</a>

## Types de données

Nom	adresse
<ul style="list-style-type: none"> <li> <b>Métabolisme</b>            KEGG (Kyoto Encyclopedia of Genes and Genomes)            BRENDA (BRAunschweig ENzyme DATabase)            Enzyme            EcoCyc         </li> </ul>	<a href="http://www.genomes.ad.jp/kegg">http://www.genomes.ad.jp/kegg</a> <a href="http://www.brenda-enzymes.org">http://www.brenda-enzymes.org</a> <a href="http://www.expasy.ch/enzyme">http://www.expasy.ch/enzyme</a> <a href="http://ecocyc.org">http://ecocyc.org</a>
<ul style="list-style-type: none"> <li> <b>Régulation transcriptionnelle</b>            RegulonDB         </li> </ul>	<a href="http://regulondb.ccg.unam.mx">http://regulondb.ccg.unam.mx</a>
<ul style="list-style-type: none"> <li> <b>Interactions protéine-protéine</b>            DIP (Database of Interacting Proteins)            BIND (The Biomolecular Interaction Network Database)         </li> </ul>	<a href="http://dip.doe-mbi.ucla.edu/">http://dip.doe-mbi.ucla.edu/</a> <a href="http://www.bind.ca/">http://www.bind.ca/</a>
<ul style="list-style-type: none"> <li> <b>Données structurales (3D)</b>            PDB (Protein Data Bank)            ModBase         </li> </ul>	<a href="http://www.rcsb.org/pdb">http://www.rcsb.org/pdb</a> <a href="http://modbase.compbio.ucsf.edu">http://modbase.compbio.ucsf.edu</a>
<ul style="list-style-type: none"> <li> <b>Famille de gènes ou de protéines</b>            The Protein Kinase Resource (PKR)            5S Ribosomal RNA Database         </li> </ul>	<a href="http://pkr.genomics.purdue.edu">http://pkr.genomics.purdue.edu</a> <a href="http://biobases.ibch.poznan.pl/5Sdata/">http://biobases.ibch.poznan.pl/5Sdata/</a>

AATDB, AceDb, ACUTS, ADB, AFDB, AGIS, AMSdb,  
 ARR, AsDb, BBDB, BCGD, Beanref, Biolmage,  
 BioMagResBank, BIOMDB, BLOCKS, BovGBASE,  
 BOVMAP, BSORF, BTKbase, CANSITE, CarbBank,  
 CARBHYD, CATH, CAZY, CCDC, CD4OLbase, CGAP,  
 ChickGBASE, Colibri, COPE, CottonDB, CSNDB, CUTG,  
 CyanoBase, dbCFC, dbEST, dbSTS, DDBJ, DGP, DictyDb,  
 Picty\_cDB, DIP, DOGS, DOMO, DPD, DPlInteract, ECDC,  
 ECGC, EC02DBASE, EcoCyc, EcoGene, EMBL, EMD db,  
 ENZYME, EPD, EpoDB, ESTHER, FlyBase, FlyView,  
 GCRDB, GDB, GENATLAS, Genbank, GeneCards,  
 Genline, GenLink, GENOTK, GenProtEC, GIFTS,  
 GPCRDB, GPCRD, HAEMB, HAMST,  
 HIDB, HIDC, HIV, HSC-2DPAGE,  
 KDNA, KEGG, KNOTO, LGIC, MAD, MaizeDB, MIBB,  
 Medline, Mendel, MEROPS, MGDB, MGI, MHCPEP5  
 Micado, MitoDat, MITOMAP, MPDB, MRR, MutBase, MycD,  
 OMIA, OMIM, OPD, ORDB, OWL, PAHdb, PatBase, PDB,  
 PDD, Pfam, PhosphoBase, PigBASE, PIR, PKR, PMD,  
 PPDB, PRESAGE, PRINTS, ProDom, Prolysis, PROSITE,  
 PROTOMAP, RatMAP, RDP, REBASE, RGP, SBASE,  
 SCOP, SeqAnaiRef, SGD, SGP, SheepMap, Soybase,  
 SPAD, SRNA db, SRPDB, STACK, StyGene, Sub2D,  
 SubtiList, SWISS-2DPAGE, SWISS-3DIMAGE, SWISS-  
 MODEL Repository, SWISS-PROT, TelDB, TGN, tmRDB,  
 TOPS, TRANSFAC, TRR, UniGene, URNADB, V BASE,  
 VDRR, VectorDB, WDCM, WIT, WormPep, YEPD, YPD,  
 YPM, **etc, etc, etc..... !!!!**

Nucleic Acids Research

<http://www.oxfordjournals.org/nar/database/c/>

## Les banques de données généralistes

- Ces banques contiennent des données hétérogènes
  - Collecte la plus exhaustive possible
  - Banques de séquences nucléiques
  - Banques de séquences protéiques
  - Banques de structure 3D de macromolécules
  - Banques d'articles scientifiques
- **Avantage** : tout est consultable en une fois

## Faiblesses des banques généralistes

- Hétérogénéité dans la nature des séquences
  - ADN nucléaire ou mitochondrial, ARN (t, r, m, ...), génome
- Variabilité de l'état des connaissances
  - caractérisation biologique beaucoup plus lente que le séquençage
- Erreurs dans les séquences
  - Liées à l'origine du fragment, à la technologie, à la méthodologie.
- Biais d'échantillonnage
  - des espèces
  - des gènes
  - redondance des données

**→ création de banques spécialisées**

## Les banques de données spécialisées

- Ces banques contiennent des données homogènes
  - Collecte établie autour d'une thématique particulière
- **Avantages** : facilité pour mettre à jour les données, vérifier leur intégrité, offrir une interface adaptée, ...
- **Inconvénients** : ne cible pas toujours ce que l'on veut; toutes les banques possibles n'existent pas
- **Exemples** : banques spécialisées pour un génome, banques de séquences d'immunologies, banques sur des séquences validées, ...

## Banques nucléiques, format d'une entrée

### EMBL

```

ID MET MOUSE STANDARD; PRT; 1379 AA.
AC P16056; Q62125;
DT 01-APR-1990 (Rel. 14, Created)
DT 01-APR-1990 (Rel. 14, Last sequence update)
DT 10-MAY-2005 (Rel. 47, Last annotation update)
DE Hepatocyte growth factor receptor precursor (EC 2.7.1.112) (Met proto-
DE oncogene tyrosine kinase) (c-met) (HGF receptor) (HGF-SF receptor).
GN Name=Met;
OS Mus musculus (Mouse).
OC Eukaryota; Metazoa; Chordata; Craniata; Vertebrata; Euteleostomi;
OC Mammalia; Eutheria; Euarchontoglires; Glires; Rodentia; Sciurognathi;
OC Muridae; Murinae; Mus.
OX NCBI_TaxID=10090;
RN [1]
RP NUCLEOTIDE SEQUENCE.
RX MEDLINE=88262253; PubMed=2838789;
RA Chan A.M.-L., King H.W.S., Deakin E.A., Tempest P.R., Hilkens J.,
RA Kroezen V., Edwards D.R., Wills A.J., Brookes P., Cooper C.S.;
RT "Characterization of the mouse met proto-oncogene.";
RL Oncogene 2:593-599(1988).
RN [2]
RP NUCLEOTIDE SEQUENCE OF 1199-1270.
RX MEDLINE=90152381; PubMed=2482828; DOI=10.1016/0378-1119(89)90465-4;
RA Wilks A.F., Kurban R.R., Hovens C.M., Ralph S.J.;
RT "The application of the polymerase chain reaction to cloning members
RT of the protein tyrosine kinase family.";
RL Gene 85:67-74(1989).
RN [3]
RP NUCLEOTIDE SEQUENCE OF 924-935.
RX PubMed=8384622;
RA Weidner K.M., Sachs M., Birchmeier W.;
RT "The Met receptor tyrosine kinase transduces motility, proliferation,
RT and morphogenic signals of scatter factor/hepatocyte growth factor in
RT epithelial cells.";
RL J. Cell Biol. 121:145-154(1993).
CC -!- FUNCTION: Receptor for hepatocyte growth factor. Has a tyrosine-
CC protein kinase activity.
CC -!- CATALYTIC ACTIVITY: ATP + a protein tyrosine = ADP + a protein
CC tyrosine phosphate.
  
```

### Genbank

```

LOCUS SCU49845 5028 bp DNA linear PLN 21-JUN-1999
DEFINITION Saccharomyces cerevisiae TCP1-beta gene, partial cds; and Axl2p
(AXL2) and Rev7p (REV7) genes, complete cds.
ACCESSION U49845
VERSION U49845.1 GI:1293613
KEYWORDS .
SOURCE Saccharomyces cerevisiae (baker's yeast)
ORGANISM Saccharomyces cerevisiae
Eukaryota; Fungi; Ascomycota; Saccharomycotina; Saccharomycetes;
Saccharomycetales; Saccharomycetaceae; Saccharomyces.
REFERENCE 1 (bases 1 to 5028)
AUTHORS Torpey,L.E., Gibbs,P.E., Nelson,J. and Lawrence,C.W.
TITLE Cloning and sequence of REV7, a gene whose function is required for
DNA damage-induced mutagenesis in Saccharomyces cerevisiae
JOURNAL Yeast 10 (11), 1503-1509 (1994)
PUBMED 7871890
REFERENCE 2 (bases 1 to 5028)
AUTHORS Roemer,T., Madden,K., Chang,J. and Snyder,M.
TITLE Selection of axial growth sites in yeast requires Axl2p, a novel
plasma membrane glycoprotein
JOURNAL Genes Dev. 10 (7), 777-793 (1996)
PUBMED 8846915
REFERENCE 3 (bases 1 to 5028)
AUTHORS Roemer,T.
TITLE Direct Submission
JOURNAL Submitted (22-FEB-1996) Terry Roemer, Biology, Yale University, New
Haven, CT, USA
FEATURES
source Location/Qualifiers
1..5028
/organism="Saccharomyces cerevisiae"
/mol_type="genomic DNA"
/db_xref="taxon:4932"
/chromosome="IX"
/map="9"
---
  
```

## Banques nucléiques, format d' une entrée

- 3 parties :

Description générale de la  
séquence

« Features »

Description des objets  
biologiques présents sur la  
séquence

- Chaque ligne commence par un mot-clé
  - Deux lettres pour EMBL
  - Maximum 12 lettres pour Genbank et DDBJ
- Fin d' une entrée : //

### La séquence

```
ctccggcagc ccgaggatcat cctgctagac tcagacctgg atgaacccat agacttgccg      60
tcgggtcaaga gccgcagcga ggccggggag ccgccagct ccctccaggt gaagcccagag      120
acaccggcgt cggcggcggt ggcggtggcg gcggcagcgg caccaccac gacggcggag      180
```

## Exemple d'une entrée Genbank :

Identificateur de l'entrée dans la banque  
(nom de l'entrée, longueur (pb), molécule  
(ADN, ARN, ADNc), date)

Informations descriptives sur la séquence

Numéro d'accèsion de la séquence 

Un numéro d'accèsion/entrée + version  
Un Genbank Identifier par version de  
séquence

Mots clefs qui peuvent être associés à une  
fiche Genbank pour retrouver plus  
facilement une entrée dans la base

Organisme d'où provient la séquence

1ière ligne : nom scientifique de  
l'organisme

2ième ligne : Classification taxonomique

Attribue un numéro unique à chaque  
référence bibliographique liée à la  
séquence

Pour chaque référence, on retrouve la  
liste des auteurs, le titre de la publication  
et le journal

```

LOCUS      JX402632                16170 bp    DNA     linear   INV 22-AUG-2012
DEFINITION Crassostrea gigas protein kinase AMP-activated alpha-catalytic
            subunit gene, complete cds.
ACCESSION  JX402632
VERSION    JX402632.1  GI:401665878
KEYWORDS   .
SOURCE     Crassostrea gigas (Pacific oyster)
            ORGANISM  Crassostrea gigas
            Eukaryota; Metazoa; Lophotrochozoa; Mollusca; Bivalvia;
            Pteriomorphia; Ostreoida; Ostreoidea; Ostreidae; Crassostrea.
REFERENCE  1 (bases 1 to 16170)
            AUTHORS   Guevelou,E., Corporeau,C. and Huvet,A.
            TITLE     Regulation of truncated AMP-activated protein kinase alpha (AMPK
            alpha) in response to hypoxia in the muscle of Pacific oyster
            Crassostrea gigas
            JOURNAL    Unpublished
REFERENCE  2 (bases 1 to 16170)
            AUTHORS   Guevelou,E., Corporeau,C. and Huvet,A.
            TITLE     Direct Submission
            JOURNAL    Submitted (19-JUL-2012) Departement Ressources Biologiques et
            Environnement, IFREMER, Z.I. Pointe du Diable Technopole
            Brest-Iroise, Plouzane, Bretagne 29280, France
    
```

## Feature Table partagée entre Genbank/DDBJ/EMBL

Séquence complète décrite (commence tjrs à 1)

FEATURES

source

Location/Qualifiers

1..16170

/organism="Crassostrea gigas"

/mol\_type="genomic DNA"

/db\_xref="taxon:29159"

join(<1..100,771..912,1152..1245,2478..2622,2724..2811,3118..3187,3306..3354,3664..3769,4089..4194,4436..4550,5963..6027,7325..7369,10242..10281,10533..10619,10853..10923,11161..11226,11680..11839,13594..13626,15195..15233,16073.>16170)

/product="protein kinase AMP-activated alpha-catalytic subunit"

join(1..100,771..912,1152..1245,2478..2622,2724..2811,3118..3187,3306..3354,3664..3769,4089..4194,4436..4550,5963..6027,7325..7369,10242..10281,10533..10619,10853..10923,11161..11226,11680..11839,13594..13626,15195..15233,16073..16170)

/codon\_start=1

/product="protein kinase AMP-activated alpha-catalytic subunit"

/protein\_id="AFP95933.1"

/db\_xref="GI:401665879"

/translation="MAEKSSSSQNAQVKIGHYILGDTLGI GTFGVKIATHQLTNHKAVKILNRQKIKSLDVVSKI KREI QNLKLFRRPHI I KLY QVI STPTDI FVMVMEYVSGGLFDYI VKHGK LKEPEARFFQI I SGVDY CHRHMVVRDLKPENLLLDSSLNVKI ADGLSNMMHDGEFLRT SCGSPNY AAPEVI SGKLY AGPEVDI WSCGVI LY ALL CGTLPFD EHVPTLFRKI KSGI FAVPDYLNKEVVSLLCLMLQVDPLKRATI AQIRDHDWFQKDLPLYLFPSPQDQDASI VEMDVI REI CEKFGVTEYEVQRALLSNDPHDQLNI AYHLI VDNFLAGEVT DVELQEFYLASSPPPSFLLAKQSHI LGTPTPQEHASSPMRPHPERMPMKTTHTLEPVSSAKQLGAQAKKAKWHLGI RSQSKPLDI MHEVFRAMKTLDYEWKI VTPYVRVRRKNPVSGRFSKMSLQLY QVDQKSYLLDFKSLSNVEI HESMSSSSSLEGGRMPLPPSSCSLDLPVTDVLLMPESAST SESFCSNLDEKMDI DEEQPRQHQTLEFFEMCASITTLAR"

Description de la séquence complète :

Organisme, type moléculaire, référence(s) dans d'autres banques (ici description du taxon associé)

mRNA

**mRNA** : portions de la « source » qui sont transcrites en ARN messager

*/product* : annotation associée

CDS

**CDS** : portions de la « source » qui correspondent à la séquence codante

*/codon\_start* : 1, 2 ou 3 selon la phase ouverte de lecture

*/protein\_id* : lien vers la fiche de la protéine correspondante au CDS

*/db\_xref* : GI correspondant

*/translation* : séquence protéique correspondante au CDS

## Séquence complète de la base 1 à 16170

← ORIGIN

```

1 atggcggaga agtctctctc ctctcagaac gcacaagtca agattggaca ttacattttg
61 ggggataccc taggaatagg aacgtttggc aaagttaaaa gtaagtacaa gagaaattca
121 catgtattag gctgtaaacg acaagcatgg tcaagtccta agagataggc ccatgaacaa
181 tgaaagtagt ctgaagttca ttacccttta gccctatgaa tatacaacaa cagtgcctaa
241 ttctaaacag atcaatatag aatgaataag aatttggcgt gctttgaata tctcagggtga
301 atgaccacaa tcttgtacaa aggaatcaaa attaagcttt cactgcccca gtaagcactg
361 gttatgaatt acatgatctg tatttctaata gaagaaaata atagtggtgt attcaataag
421 tagatgactt acaatcttta aatttatatt taatgtgtaa aatgttacgt ggaatactac
481 aaatacaatt ggcgtggatc tgataatttt tgtgtataaa cctgtatgca tgtcgttaata
541 tgaattgcat caaaaagatt taaactttta aaccttttaa ccacattgtg atacatatat
601 tgtaagctac tggtagcaag gttatacttg ttaattaagc ttgattatat attaaaatct
661 tttgattttt aaagaaaaca tctttttttg gaaaaatctt ttttaccatca tatgaaataa
721 ctgtaatatt ttgcatgat atggatgaa acctcttcc tttttctcag ttgccacca
781 tcagctgacc aatcataagg tggcggtaaa gatcctcaac aggcagaaga tcaagagtct
841 cgatgtcgtc agtaaaatca agagagaaat tcagaatctc aagctttttc gtaccaccaca
901 cattatcaaa ctgtaagtca tggcatgcag gtagtcttta atggttaagg caatgaatga
961 caatttttca ttaaattaca acaatcagac gatgatgttt ataatgaaat gacccttata
1021 caatataaag tacatcaaac tttttatgaa ctgatatttt tatacttata gacctattgc
1081 ctgttttttt acttaccggt atacacctgt tacttgattg ctttgtttat ttggtttctc
1141 tgtttggaca ggtatcagggt gatcagtacc cccacagata tcttcatggt gatggagtat
1201 gtgtctgggg gagaattggt tgattacatt gtcaaacacg gcaaggtaact ctttatctc
1261 cttacttgct gctgaacaaa tgactttgac ctttgtatg tgcatacttc cttatactta
1321 ggccaaaaaa aattattcct gtttctgtt gcccgaccga cccatctttt taccctccga
1381 ccctaaaagt tttttgtca tgatggtggt gatcggtaac ttgccagaa tttctcaga
1441 aagagaagtg aagatgacca agtctctcga gttcataatc gtgtaaatta acctcactgg
1501 cgaaaagaat atagaaaatt aatctacaga catttttact gcataaatac accttgtggt
1561 gaataacttg cgactatctt acctcaggg gttataaata tgggtgatgc aacacattct
1621 gtatatggga aattacaaaa acaatgttta ttactttaaa tcttgatatt acagttagtc
1681 aataacctgt tattagttaa taactgcaat aaatgttaaa attatcataa aactgctttc
1741 tatattatct tgagaattaa acagatcctc tacataacgt acggtagtaa gtgggtcaaa
1801 gggttggact aataccctca atacatggaa gtacagagag tgatttaatt aatcatgttg
1861 atattgacat taagctaata caatacaata atatttatcc agaaaaggat aaatacattc
1921 atacacatag attaaatttt gcaataaata ttagttttta ttttaatta aaaaattaat
1981 ctctatttta tttttctttg cctgttgttt tctatacatt acatgatca acaatacaaa
2041 gacctttgga aattttaaat catctactta catactgaac actggaata tacatctctc

```

...

## Feature Table

### 5.1 Eukaryotic gene

```

source      1..1509
            /organism="Mus musculus"
            /strain="CD1"
            /mol_type="genomic DNA"
promoter    <1..9
            /gene="ubc42"
mRNA        join(10..567,789..1320)
            /gene="ubc42"
CDS         join(54..567,789..1254)
            /gene="ubc42"
            /product="ubiquitin conjugating enzyme"
            /function="cell division control"
            /translation="MVSSFLLAEYKNLIVNPSEHFKISVNEDNLTEGPPDTLY
            QKIDTVLLSVISLLNEPNPDSPANVDAAKSYRKYLYKEDLESYPMEKSLDECS
            AEDIEYFKNVPPVNLPPVPSDDYEDEEMEDGTYILTYDDEDEEEMDDE"
exon        10..567
            /gene="ubc42"
            /number=1
intron      568..788
            /gene="ubc42"
            /number=1
exon        789..1320
            /gene="ubc42"
            /number=2
polyA_signal 1310..1317
            /gene="ubc42"
    
```

Site de fixation de l'ARN polymérase

2 exons du CDS

3 gènes de l'opéron

Gène avec activité enzymatique

### 5.2 Bacterial operon

```

source      1..9430
            /organism="Lactococcus sp."
            /strain="MG1234"
            /mol_type="genomic DNA"
operon      160..6865
            /operon="gal"
-35_signal  160..165
            /operon="gal"
-10_signal  179..184
            /operon="gal"
CDS         405..1934
            /operon="gal"
            /gene="galA"
            /product="galactose permease"
            /function="galactose transporter"
CDS         2003..3001
            /operon="gal"
            /gene="galM"
            /product="aldose 1-epimerase"
            /EC_number="5.1.3.3"
            /function="mutarotase"
CDS         3235..4537
            /operon="gal"
            /gene="galK"
            /product="galactokinase"
            /EC_number="2.7.1.6"
mRNA        189..6865
            /operon="gal"
    
```

## Format Fasta

- Format standard de stockage des séquences nucléiques et protéiques
- En entrée de la plupart des outils de bioinformatique

Ligne de description commence toujours par un **>Identifiant Description**

Convention dans les banques généralistes :  
Genbank :

>gi|*numéro gi*|gb|*numéro d'accession*|locus

EMBL :

>gi|*numéro gi*|emb|*numéro d'accession*|locus

DDBJ :

>gi|*numéro gi*|dbj|*numéro d'accession*|locus

Local Sequence identifier :

>lcl|identifiant

```
>gi|401665878|gb|JX402632.1| Crassostrea gigas protein kinase AMP-activated
alpha-catalytic subunit gene, complete cds
ATGGCGGAGAAGT CCT CCT CCT CT CAGAACGCACAAGT CAAGATT GGACATT ACATTTT GGGGGAT ACCC
TAGGAAT AGGAACGTTT GGCAAAGTT AAAAGT AAGT ACAAGAGAAATT CACAT GT ATT AGGCT GT AAACG
ACAAGCAT GGT CAAGT CT CAAGAGAT AGGCCCAT GAACAAT GAAAGT AGT CT GAAGTT CATT ACCCTTT A
GCCCT AT GAAT AT ACAAACACAGT GCTT AATT CT AAACAGAT CAAT AT AGAAT GAAT AAGAATTT GCCGT
GCTTT GAAT AT CT CAGGT GAAT GACCACAAT CTT GT ACAAAGGAAT CAAAATT AAGCTTT CACT GCCCCA
GT AAGCACT GGT T AT GAATT ACAT GAT CT GT ATTT CT AAT GAAGAAAAT AAT AGT GT GGT ATT CAAT AAG
TAGAT GACTT ACAAT CTTT AAATTT AT ATTT AAT GT GT AAAAT GTT ACGT GGAAT ACT ACAAAT ACAATT
GGCGT GGAT CT GAT AATTTT GT GT AT AAACCT GT AT GCAT GT CGT AAT AT GAATT GCAT CAAAAAGATT
TAACTTTT AAACCTTTT AACCACTT GT GAT ACAT AT ATTT GT AAGCT ACT GT T AGCAAGGTT AT ACTT G
TT AATT AAGCTT GATT AT AT ATTT AAAAT CTTTT GATTTTT AAAGAAAACAT CCTTTTTT GGAAAAAT CTT
TTTT ACAT CAT AT GAAAT AACT GT AAT ATTTT GT CAT GAT AT GGT AT GAAACCCT CTT CCTTTTT CT CAG
TT GCCACCCAT CAGCT GACCAAT CAT AAGGT GGCGGT AAAGAT CCT CAACAGGCAGAAGAT CAAGAGT CT
CGAT GT CGT CAGT AAAAT CAAGAGAGAAATT CAGAAT CT CAAGCTTTTT CGT CACCCACACATT AT CAAA
CT GT AAGT CAT GGCAT GCAGGT AGT CTTT AAT GGT T AAGGCAAT GAAT GACAATTTTT CATT AAATT ACA
ACAAT CAGACGAT GAT GTTT AT AAT GAAAT GACCCTT AT ACAAT AT AAAGT ACAT CAAACT ATTT AT GAA
CT GAT ATTTTT AT ACTT AT AGACCT ATT GCCT GTTTTTT ACTT ACCGGT AT ACACCT GTT ACCT GATT G
CTTT GTTT ATTT GGT TT CT CT GTTT GGACAGGT AT CAGGT GAT CAGT ACCCCCACAGAT AT CTT CAT GGT
GAT GGAGT AT GT GT CT GGGGGAGAATT GTTT GATT ACATT GT CAAACACGGCAAGGT ACT CCTTT AT CT C
CTT ACTT GCT GCT GAACAAAT GACTTT GACCTTTT GT AT GT GCAT CATT CCTT AT ACTT AGGCCAAAAA
AATT ATT CCT GTTT CCT GTT GCCCGACCGACCCT AT CTTTT ACCCT CCGACCCT AAAAGTTTTTTT GT CA
T GAT GGT GGT GAT CGGT AACTT CGCCAGAATTT CCT CAGAAAGAGAAGT GAAGAT GACCAAGT CTT CT GA
GTT CAT AAT CGT GT AAAT AACT CACT GCGAAAGAAT GAT AGAAAATT AAT CT ACAGACATTTTT ACT
GCAT AAAT AT ACCTT GT GGT GAAT AACTT GCGACT AT CTT ACCTT CAGGGGT AT AAAT AT GGGT GAT GC
AACACATT CT GT AT ATTT GGAAATT AAAAAACAAT GTTT ATTT ACTTT AAAT CCT GAT ATT ACAGTT AGT C
AAT AACCT GTT ATT AGTT AAT AACT GCAAT AAAT GTT AAAATT AT CAT AAAACT GCTTT CT AT ATT AT CT
```

## Description générale de la séquence

ID AF226511 standard; genomic DNA; PRO; 948 BP.  
 AC AF226511;  
 SV AF226511.1  
 DT 15-MAR-2000 (Rel. 63, Created)  
 DT 04-JAN-2006 (Rel. 86, Last updated, Version 2)  
 DE Neisseria meningitidis strain 1000 membrane protein GNA1220 (gna1220) gene,  
 DE complete cds.  
 OS Neisseria meningitidis  
 OC Bacteria; Proteobacteria; Betaproteobacteria; Neisseriales; Neisseriaceae;  
 OC Neisseria.

RP 1-948  
 RX DOI; 10.1126/science.287.5459.1816.  
 RX PUBMED; 10710308.  
 RA Pizza M., Scarlato V., Massignani V., Giuliani M.M., Arico' B., ...  
 RT "Identification of vaccine candidates ... "  
 RL Science 287(5459):1816-1820(2000).  
 RL Submitted (19-JAN-2000) to the EMBL/GenBank/DDBJ databases.  
 RL IRIS Immunobiological Research Institute in Siena, Chiron SpA, Via  
 RL Fiorentina, 1, Siena 53100, Italy

## Banques nucléiques, les différentes lignes (1/2)

- ID : nom de l'entrée , ...
  - Unique (propre à une entrée)
  - Non permanent (peut changer au cours des versions)
- AC : numéro d'accession
  - parfois plusieurs pour une même entrée (fusion d'entrées)
  - Permanent (ne disparaît jamais de la banque)
- SV : version de la séquence (Acc.version)
- DT : date d'incorporation dans la banque et de dernière mise à jour
- DE : description du contenu de l'entrée

## Banques nucléiques, la ligne ID

ID entryname dataclass; molecule; division; sequencelength BP.

*Exemple: ID AB000263 standard; RNA; PRI; 368 BP.*

- **Entryname** : nom de l'entrée
  - *en général numéro d'accession*
- **Dataclass** : toujours le mot « standard »
- **Molecule** : type de la molécule de l'entrée
  - *DNA, RNA, circular DNA, ...*
- **Division** : essentiellement basé sur la taxonomie
  - *HUM (Human), MUS (Souris), MAM (Other Mammals), ...*
- **Taille** : en paires de bases

## Banques nucléiques, les différentes lignes (2/2)

- **KW** : liste de mots-clés (désuet)
- **OS** : organisme d'où provient la séquence (nom latin)
- **OC** : taxonomie (ou « artificial sequence »)
  - Exemple : *Eukaryota; Planta; Phycophyta; Euglenophyceae.*
- **OG** : localisation de séquences non nucléaires
  - Exemple : *Mito, Plasmid ...*
- **RA, RT, RN, RC, RX, RP, RL** : réf. bibliographiques
- **DR** : liaison avec d'autres banques de données
- **FH, FT** : caractéristiques d'une entrée (Features)
- **SQ** : séquence (termine par //)

## « Features » : Description des objets biologiques présents sur la séquence

FH	Key	Location/Qualifiers
FH		
FT	source	1..948
FT		/db_xref="taxon:487"
FT		/mol_type="genomic DNA"
FT		/note="serogroup: B"
FT		/organism="Neisseria meningitidis"
FT		/strain="1000"
FT	gene	1..948
FT		/gene="gna1220"
FT	CDS	1..948
FT		/codon_start=1
FT		/db_xref="GOA:Q9JPH5"
FT		/db_xref="InterPro:IPR001107"
FT		/db_xref="InterPro:IPR001972"
FT		/db_xref="UniProtKB/TrEMBL:Q9JPH5"
FT		/note="similar to stomatin-like proteins; Genome-derived Neisseria Antigen GNA1220"
FT		/transl_table=11
FT		/gene="gna1220"
FT		/product="membrane protein GNA1220"
FT		/protein_id="AAF42660.1"
FT		/translation="MEFFIILLVAVAVFGFKSFVVIPQQEVHVVERLGRFHRALTAGLN ILIPFIDRVAYRHSLSKEIPLDVPSQVCITRDNTQLTVDGIIYFQVTDPKLASYGSSNYI MAITQLAQTTLRSVIGRMELDKTFEERDEINSTVVSALDEAAGAWGVKVLRYEIKDLVP PQEILRSMQAQITAEREKRARIAESEGRKIEQINLASGQREAEIQQSEGEAQAAVNASN AEKIARINRAKGEAESLRLVAEANAEAIRQIAAALQTQGGADAVNLKIAEQYVAAFNNL AKESNTLIMPANVADIGSLISAGMKIIDSSKTAK"
XX		

## Banques nucléiques, Features

**But :** Mettre à disposition un vocabulaire étendu pour décrire les caractéristiques biologiques des séquences.

**Format :**

- **Key :** indique un groupe fonctionnel
  - Vocabulaire contrôlé, hiérarchique
- **Location :** instructions pour trouver l'objet sur la séquence de l'entrée
- **Qualifiers :** informations complémentaires
  - /qualifier= 'commentaires libres'

## Banques nucléiques, Key

- Mot-clé le plus général : misc\_feature
- Changements dans la séquence : misc\_difference, ...
- Régions répétées : repeat\_region, ...
- Régions des Ig : immunoglobulin\_related, ...
- Structures secondaires : misc\_structure
  - stem\_loop
  - D-loop
- Régions impliquées dans la recombinaison : misc\_recomb, ...

Manipulation des fichiers.

Utilisez des éditeurs de texte et pas des traitements de texte !!



Méfiez vous des formats!!



## PARTIE I : Phylogénie moléculaire

# LES ÉLÉMENTS D'UNE PHYLOGENIE

- Les caractères
- Le jeu de données
- Les banques et formats
- **Les alignements**
- Les arbres

L'alignement est **une étape cruciale** qui permet de choisir les sites qui seront utilisés dans les analyses phylogénétiques.

But : S'assurer que chacun des sites choisis est **homologue** :

- hérité d'un ancêtre commun par descendance directe

⇒ contient une information phylogénétique sur cette histoire évolutive.

L'alignement est **une étape cruciale** pour la phylogénie mais pas seulement.

---

Main applications of multiple sequence alignments

---

<i>Application</i>	<i>Procedure</i>
<b>Extrapolation</b>	A good multiple alignment can help convincing you that an uncharacterized sequence is really a member of a protein family.
<b>Phylogenetic analysis</b>	If you carefully chose the sequences to include in your multiple alignment, you can reconstruct the history of these proteins.
<b>Pattern Identification</b>	By discovering very conserved positions you can identify a region that is characteristic of a function (in proteins or in nucleic acid sequences).
<b>Domain identification</b>	It is possible to turn a multiple sequence alignment into a profile that describes a protein family or a protein domain. You can use this profile to scan databases for new members of the family.
<b>DNA regulatory elements</b>	You can turn a DNA multiple alignment of a binding site into a weight matrix and scan other DNA sequences for potential similar binding sites.
<b>Structure prediction</b>	A good multiple alignment can give you an almost perfect prediction of your protein secondary structure for proteins or RNA. Sometimes it can also help building a 3-D model.
<b>PCR analysis</b>	A good multiple alignment can help you identifying the less degenerated portions of a protein family
<b>nsSNP</b>	Identify the nsSNP that are the most likely to alter the function



## **Critères structurels**

Les résidus sont agencés de sorte que ceux qui jouent un rôle similaire se retrouvent dans la même colonne.

## **Critères évolutifs**

Les résidus sont agencés de sorte que ceux ayant le même ancêtre se retrouvent dans la même colonne.

## **Critères de similarité**

Les résidus similaires seront autant que possible dans la même colonne

Pour s'assurer de l'homologie d'un site:

- la structure primaire des séquences (ordre des nucléotides)
- la structure secondaire des séquences (gènes ribosomiques : tiges boucles)
- la séquence en acides aminés (gènes codant pour des protéines)

## Représentation

- Les résidus (nucléotides, acides-aminés) sont superposés de façon à maximiser la similarité 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
* * *           * * *       * * *   *
  
```

- Mutations :
  - Substitution (*mismatch*)
  - Insertion
  - Délétion
    - > Insertions ou délétions : indels (*gap*).

## Quel est bon ?

```

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
* * *      * *
  
```

**OU**

```

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

- Pour le biologiste, généralement, le bon alignement est celui qui représente le scénario évolutif le plus probable

## Exercice

- Calculer le pourcentage d'identité et le pourcentage de similarité entre ces deux séquences protéiques :

```

Query 1  MAPWMHLLTVLALLAVWGPNSVQVYSSQHLCGSNLVEALYMTC--RSGFYRPHDRRELED 58
          MA WM LL +LALLA+WGP+  Q + +QHLCGS+LVEALY+ C R FY P RRE ED
Sbjct 1  MALWMRLLPLLALLALWGPDPAQAFVNQHLCGSHLVEALYLVCGERGFFYTPKTRREAED 60

Query 59 LOVEQAEL--GLEAGGLQPSALEMILQKRGIVDQCCNNIC 96
          LQV Q EL  G  AG LQP ALE  LQKRGIV+QCC +IC
Sbjct 61 LQVGQVELGGGPGAGSLQPLALEGSLQKRGIVEQCCTSIC 100
  
```

## Exercice

- Calculer le pourcentage d'identité et le pourcentage de similarité entre ces deux séquences protéiques :

Score	Expect	Method	Identities	Positives	Gaps
106 bits(265)	1e-27	Compositional matrix adjust.	64/100(64%)	73/100(73%)	4/100(4%)
Query 1	MAPWMHLLTVLALLAVWGPNSVQVYSSQHLCGSNLVEALYMTC--RSGFYRPHDRRELED				58
Sbjct 1	MA WM LL +LALLA+WGP+ Q + +QHLCGS+LVEALY+ C R FY P RRE ED				60
Query 59	LQVEQAEL--GLEAGGLQPSALEMILQKRGIVDQCCNNIC		96		
Sbjct 61	LQV Q EL G AG LQP ALE LQKRGIV+QCC +IC		100		

Utilisation de % identité et similarité pas suffisant -> utilisation de score

## Score de similarité

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
*	*	*				*	*	*		*	*	*		*

$$\text{Score} = \sum_{\text{début}}^{\text{fin}} \text{pondération\_substitution} - \sum_{\text{début}}^{\text{fin}} \text{pénalité\_gap}$$

Exemple:

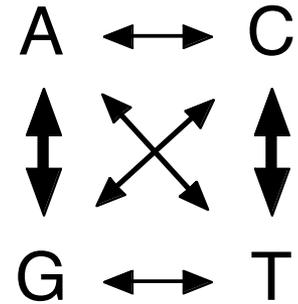
- identité = 1
- mismatch = 0
- gap = -1

$$\text{Score} = 10 - 4 = 6$$

## Modèles d'évolution

### ADN

- Transition:  $A \leftrightarrow G$      $T \leftrightarrow C$
- Transversions : autres substitutions
- $p(\text{transition}) > p(\text{transversion})$



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

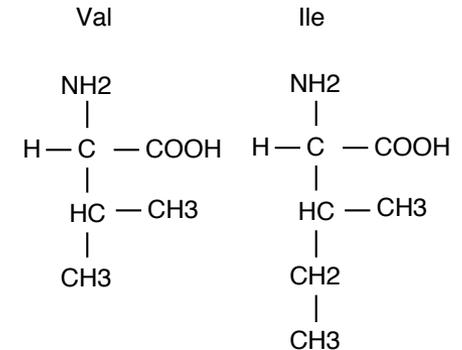
G T T A C G A  
 G T T G - G A  
 \* \* \* .        \* \*

## Modèles d'évolution

### Protéines

### Substitutions conservatrices

- Code génétique
  - Asp (GAC, GAU) ↔ Tyr (UAC, UAU) : 1 mutation
  - Asp (GAC, GAU) ↔ Cys (UGC, UGU) : 2 mutations
  - Asp (GAC, GAU) ↔ Trp (UGG) : 3 mutations
- Propriétés physico-chimiques des acides-aminés (acidité, hydrophobicité, encombrement stérique, etc.)
- Matrices de Dayhoff (PAM), BLOSUM: mesures des fréquences de substitutions dans des alignements de protéines homologues
  - PAM 60, PAM 120, PAM 250 (extrapolations à partir de PAM 15)
  - BLOSUM 80, BLOSUM 62, BLOSUM 40 (basé sur des alignements de blocs)



## Pondération des gaps

TGATATCGCCA

TGAT---TCCA

\* \* \* \*

\* \* \*

TGATATCGCCA

TGAT-T--CCA

\* \* \* \*

\*

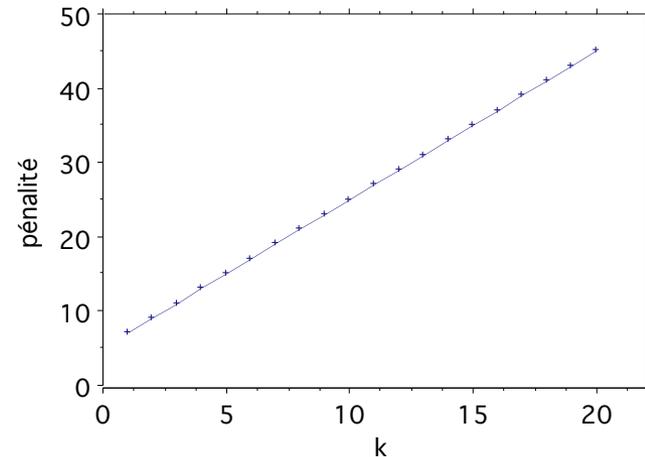
\* \* \*

- Gap de longueur  $k$ : Pénalités linéaires:

$$w = \delta_o + \delta_e k$$

$\delta_o$  : pénalité pour l'ouverture d'un gap

$\delta_e$  : pénalité pour l'extension d'un gap

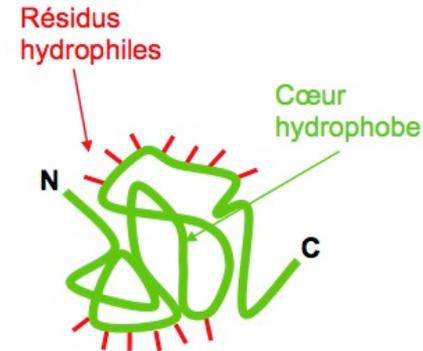
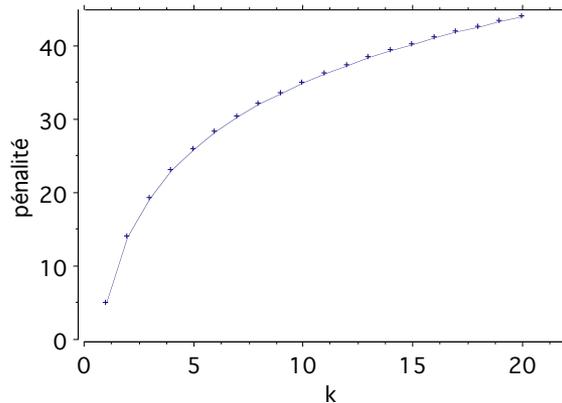


## Pondération des gaps

Estimation des paramètres sur des alignements "vrais" (par exemple basés sur l'alignement de structures connues)

Gap de longueur  $k$ :

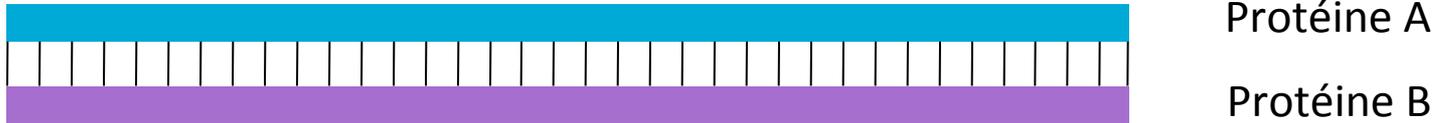
- Pénalités logarithmiques:  $w = \delta_o + \delta_e \log(k)$



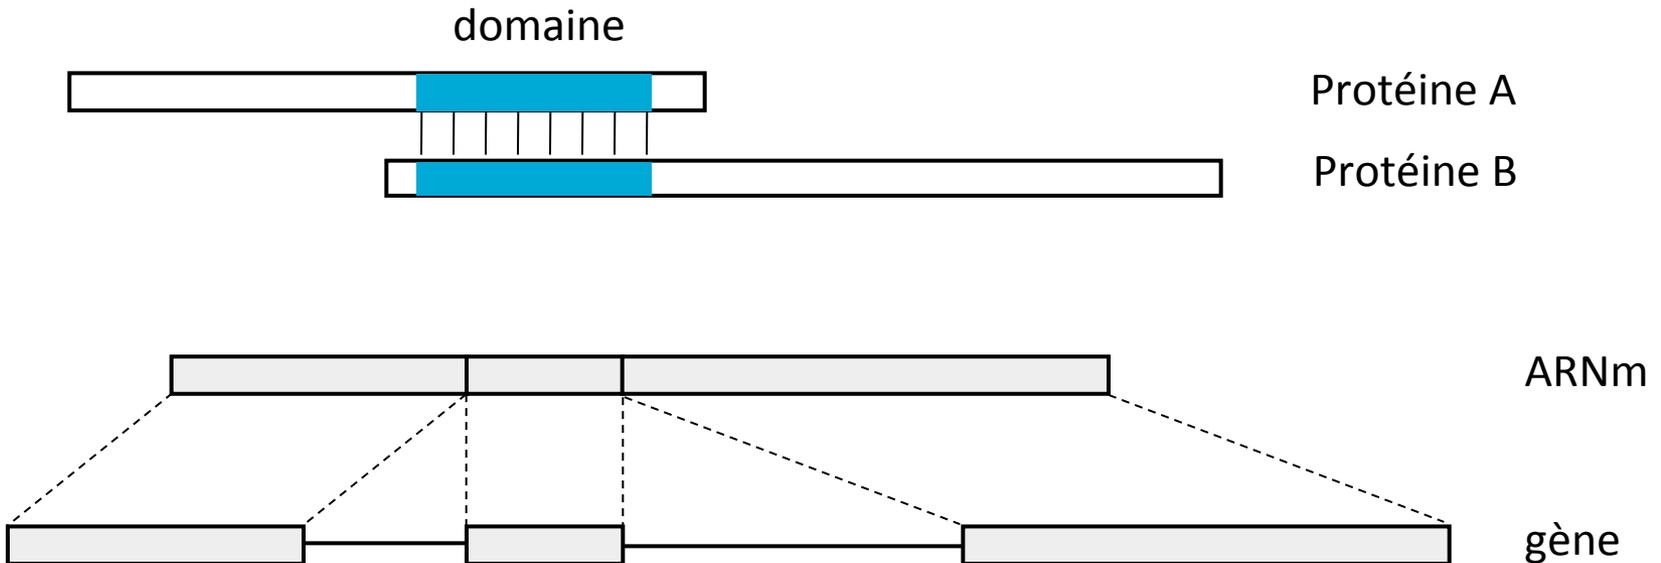
- $w = f(\log(k), \log(\text{PAM}), \text{résidus}, \text{structure})$ 
  - *PAM: la probabilité d'un gap augmente avec la distance évolutive*
  - *Résidus, structure: la probabilité d'un gap est plus forte dans une boucle (hydrophile) que dans le cœur hydrophobe des protéines*

## Local vs. Global

- Alignement global (Needlman & Wunsch, 1970)

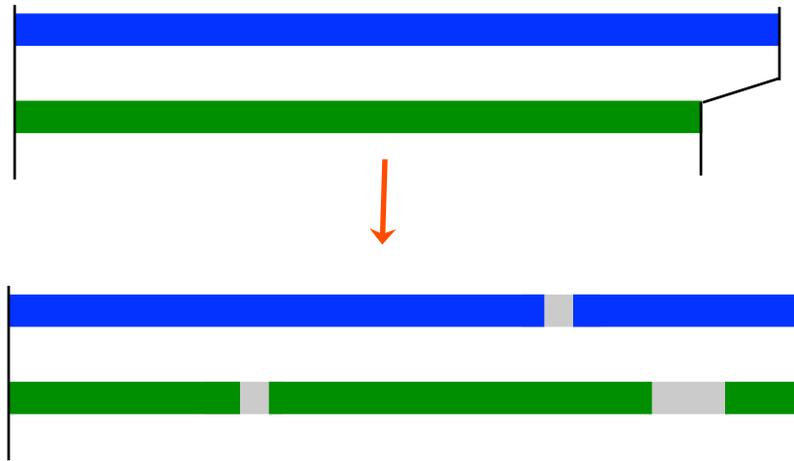


- Alignement local (Smith & Waterman, 1981 ; FASTA, 1988 ; BLAST, 1990)



## Local vs. Global

Alignement de 2 séquences sur la totalité de leur longueur

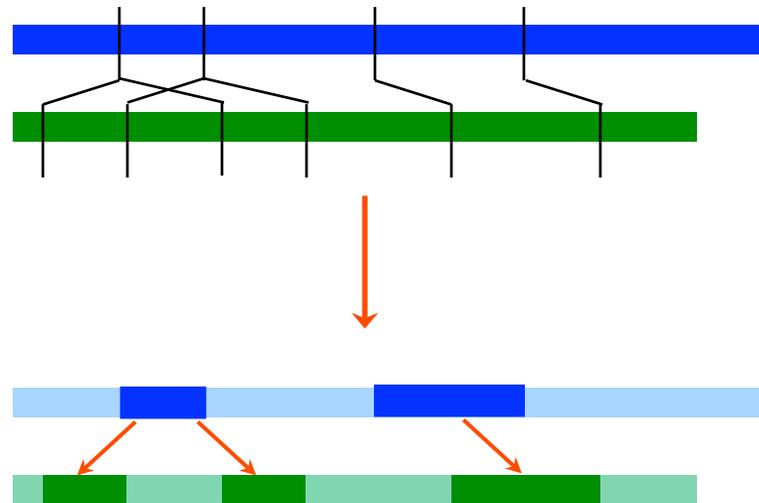


Déterminer le degré de similarité de 2 séquences

Logiciels : ALIGN, LALIGN, Needle

## Local vs. Global

Alignement sur des segments de séquences



Comparer une séquence inconnue avec une banque de séquences

**FASTA (Fast Alignment Search Tool)**  
**BLAST (Basic Local Alignment Search Tool)**

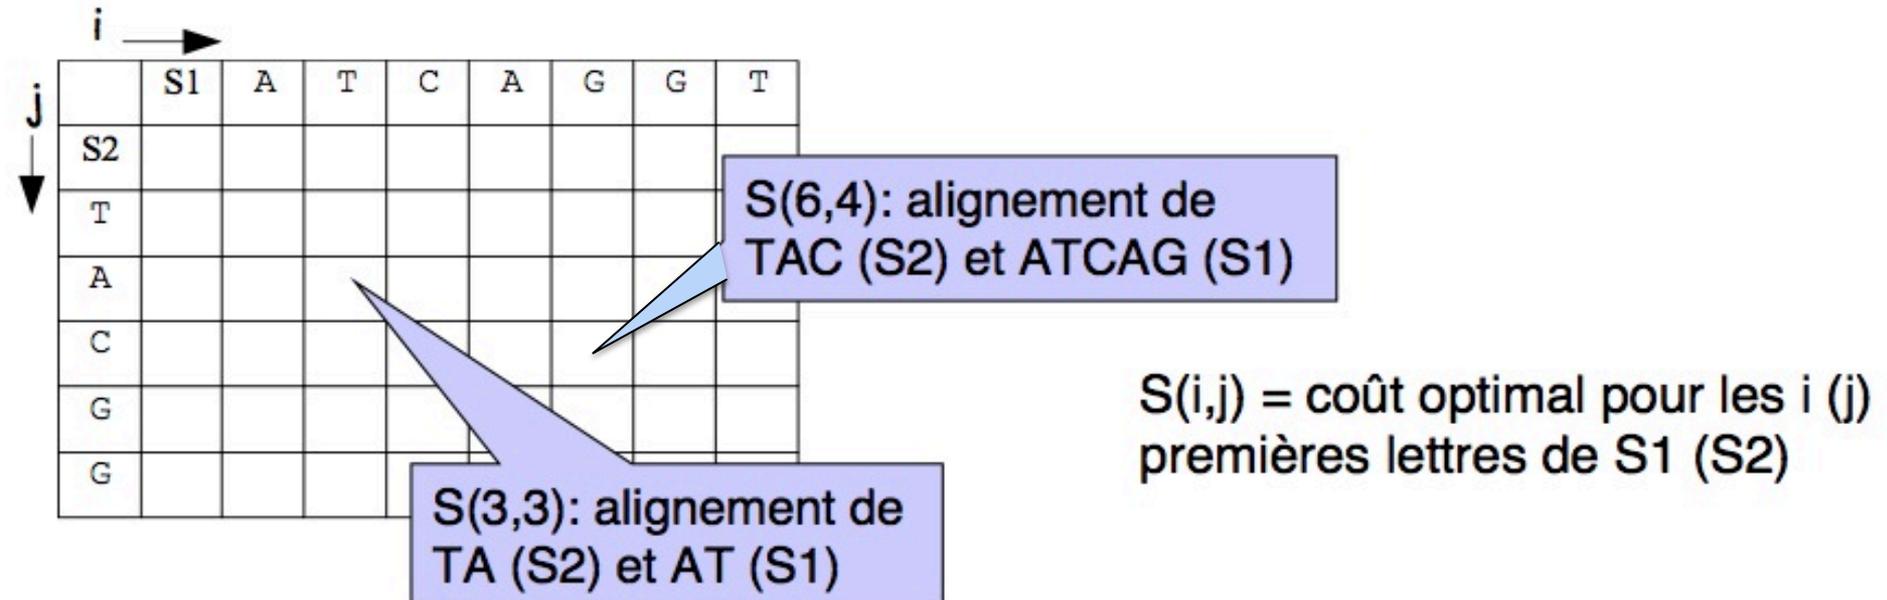
# L'alignement : deux séquences

Similarité entre deux séquences

=> Alignement par paire: programmation dynamique

Principe = combinaison des solutions de sous-problèmes

1. **Construction d'une matrice initiale (dimension (n,m))**
2. Remplissage de la matrice
3. Recherche du chemin de score maximum



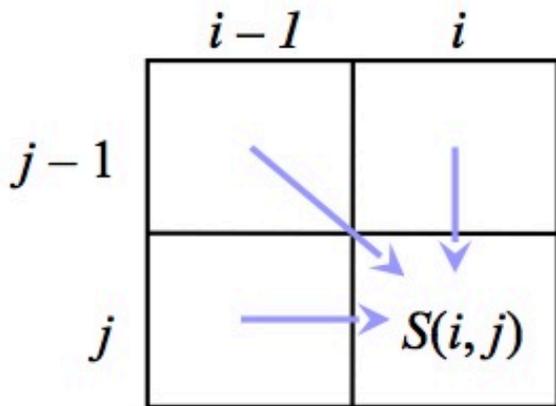
# L'alignement : deux séquences

Similarité entre deux séquences

=> Alignement par paire: programmation dynamique

Principe = combinaison des solutions de sous-problèmes

1. Construction d'une matrice initiale (dimension (n,m))
2. **Remplissage de la matrice**
3. Recherche du chemin de score maximum



$$S(i, j) = \max \left( \begin{array}{l} S(i-1, j) + \delta(a_i, -), \\ S(i-1, j-1) + \delta(a_i, b_j), \\ S(i, j-1) + \delta(-, b_j) \\ [ 0 ] \end{array} \right)$$

$$[ S(i, j) < 0 \Rightarrow S(i, j) = 0 ]$$

# L'alignement : deux séquences

Fonction de récurrence :

**Sim(i,j)** : score optimal entre Seq1(1..i) et Seq2(1..j)

Formule de récurrence :

- **Sim(0,0) = 0**
- **→ Sim(0,j) = Sim(0,j-1) + Indel**
- **↓ Sim(i,0) = Sim(i-1,0) + Indel**
- **↘ : Sim(i,j) = max [**

	j-1	j
i-1		
i		?

**Sim(i-1,j-1) + Corresp.ou Substi.**

**(Corresp. si Seq1(i) = Seq2(j) sinon Substi.)**

**Sim(i-1,j) + Indel**

**Sim(i,j-1) + Indel**

**]**

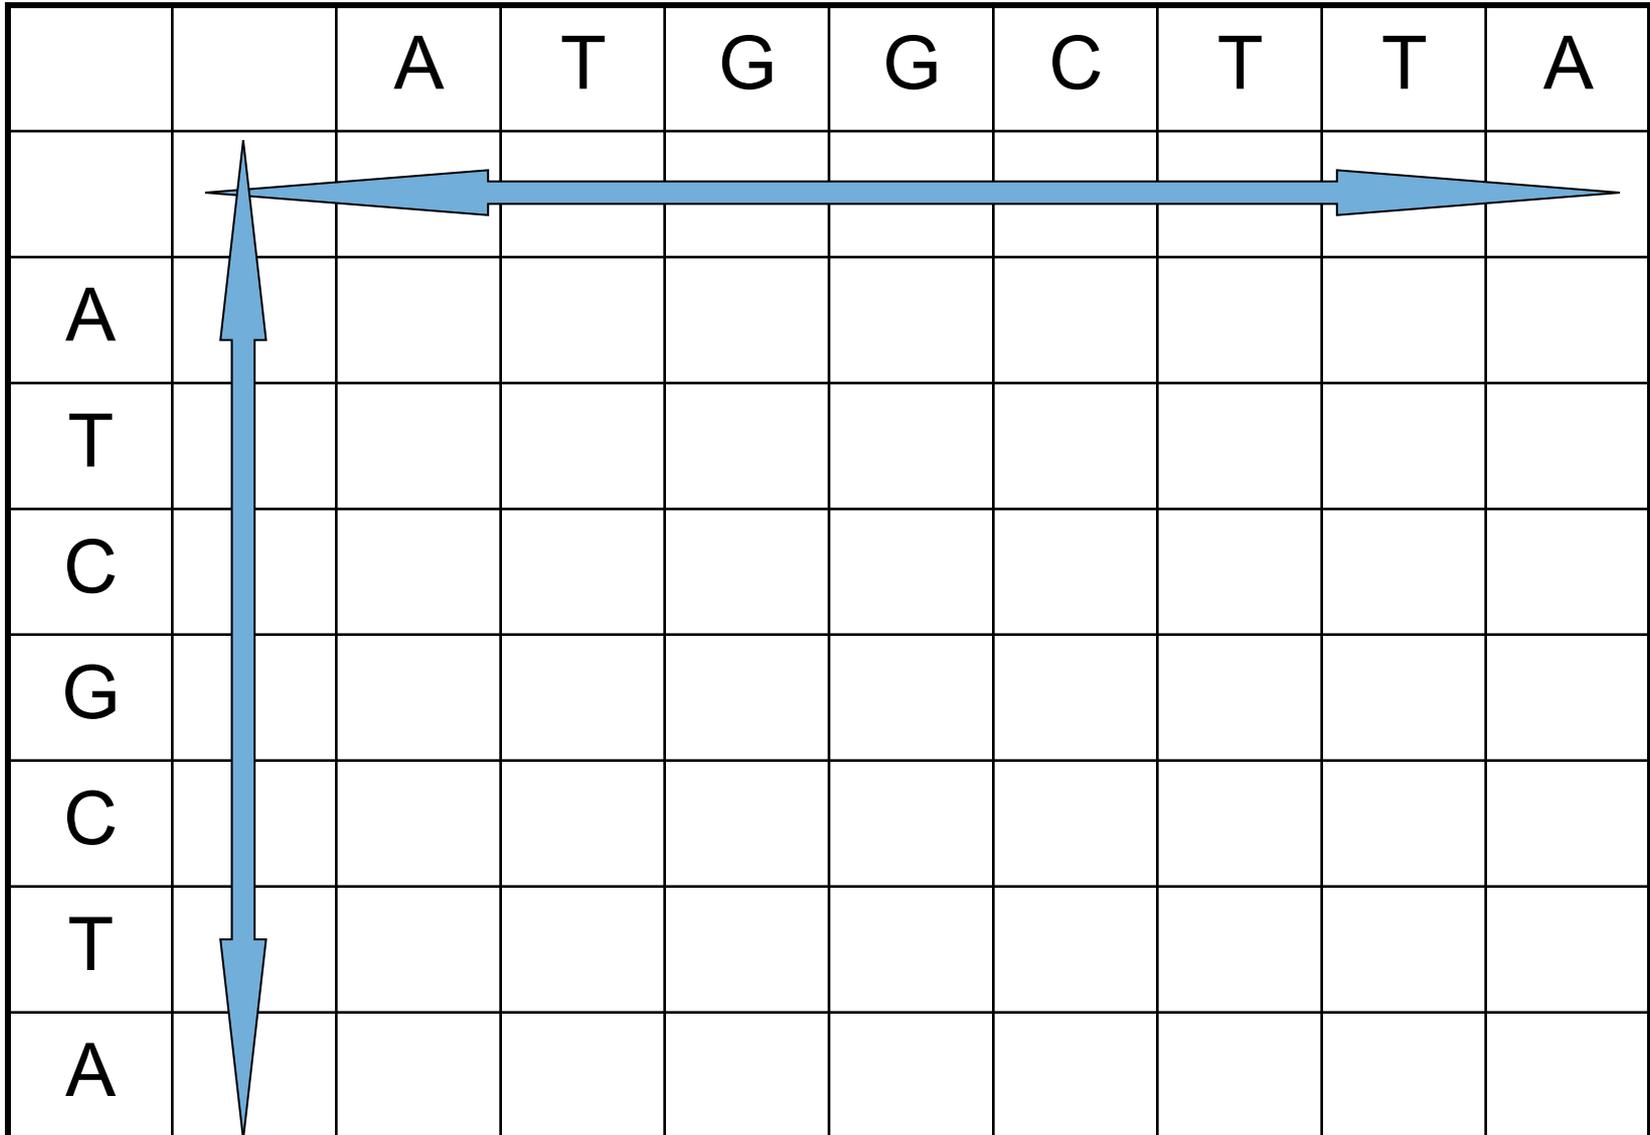
Exemple : on veut aligner 2 séquences

- ATGGCTTA et ATCGCTA

Calcul du score :

- Identité (ou concordance) : 0
- Substitution : -1
- INDEL : -3

# L'alignement : deux séquences



# L'alignement : deux séquences

		A	T	G	G	C	T	T	A
	0								
A									
T									
C									
G									
C									
T									
A									

**Sim(0,0) = 0**

# L'alignement : deux séquences

		A	T	G	G	C	T	T	A
	0	-3	-6	-9	-12	-15	-18	-21	-24
A	-3								
T	-6								
C	-9								
G	-12								
C	-15								
T	-18								
A	-21								

→  $\text{Sim}(0,j) = \text{Sim}(0,j-1) + \text{Indel}$   
 ↓  $\text{Sim}(i,0) = \text{Sim}(i-1,0) + \text{Indel}$

# L'alignement : deux séquences

		A	T	G	G	C	T	T	A
	0	-3	-6	-9	-12	-15	-18	-21	-24
A	-3	?							
T	-6								
C	-9								
G	-12								
C	-15								
T	-18								
A	-21								

↘:  $\text{Sim}(i,j) = \max [$

$\text{Sim}(i-1,j-1) + \text{Corresp.ou Substi.}$   
**(Corresp. si  $\text{Seq1}(i) = \text{Seq2}(j)$  sinon Substi.)**

$\text{Sim}(i-1,j) + \text{Indel}$

$\text{Sim}(i,j-1) + \text{Indel}$

$]$

# L'alignement : deux séquences

		A	T	G	G	C	T	T	A
	0	-3	-6	-9	-12	-15	-18	-21	-24
A	-3	?							
T	-6								
C	-9								
G	-12								
C	-15								
T	-18								
A	-21								

↓ :  $\text{Sim}(i-1, j) + \text{Indel} = -3 - 3 = -6$   
→ :  $\text{Sim}(i, j-1) + \text{Indel} = -3 - 3 = -6$   
↘ :  $\text{Sim}(i-1, j-1) + \text{Corresp. ou Substi.}$   
 (Corresp. si  $\text{Seq1}(i) = \text{Seq2}(j)$  sinon Substi.)  
 $= 0 + 0$  (puisque  $A = A$ )  $= 0$   
 Max  $[-6, -6, 0]$   
 Le max : 0



# L'alignement : deux séquences

		A	T	G	G	C	T	T	A
	0	-3	-6	-9	-12	-15	-18	-21	-24
A	-3	0	?						
T	-6								
C	-9								
G	-12								
C	-15								
T	-18								
A	-21								

 :  $\text{Sim}(i-1,j) + \text{Indel} = -6 - 3 = -9$   
 :  $\text{Sim}(i,j-1) + \text{Indel} = 0 - 3 = -3$   
 :  $\text{Sim}(i-1,j-1) + \text{Corresp. ou Substi.}$   
 (Corresp. si  $\text{Seq1}(i) = \text{Seq2}(j)$  sinon Substi.)  
 =  $-3 - 1$  (puisque  $T \neq A$ ) =  $-4$

Le max : -3



# L'alignement : deux séquences

		A	T	G	G	C	T	T	A
	0	-3	-6	-9	-12	-15	-18	-21	-24
A	-3	0	-3	-6	-9	-12	-15	-18	-21
T	-6	-3	0	-3	-6	-9	-12	-15	-18
C	-9	-6	-4	-1	-4	-6	-9	-12	-15
G	-12	-9	-7	-4	-1	-4	-7	-10	-13
C	-15	-12	-10	-7	-4	-1	-4	-7	-10
T	-18	-15	-13	-10	-7	-4	-1	-4	-7
A	-21	-18	-16	-13	-10	-7	-4	-2	-4

# L'alignement : deux séquences

Principe = combinaison des solutions de sous-problèmes

1. Construction d'une matrice initiale (dimension (n,m))
2. Remplissage de la matrice
3. Recherche du chemin de score maximum

Identité (ou concordance) : 0

Substitution : -1

INDEL : -3

2 Alignements possibles :

ATGGCTTA

ATCGC-TA

ATGGCTTA

ATCGCT-A

**SCORE = -4**

		A	T	G	G	C	T	T	A
	0	-3	-6	-9	-12	-15	-18	-21	-24
A	-3	0	-3	-6	-9	-12	-15	-18	-21
T	-6	-3	0	-3	-6	-9	-12	-15	-18
C	-9	-6	-4	-1	-4	-6	-9	-12	-15
G	-12	-9	-7	-4	-1	-4	-7	-10	-13
C	-15	-12	-10	-7	-4	-1	-4	-7	-10
T	-18	-15	-13	-10	-7	-4	-1	-4	-7
A	-21	-18	-16	-13	-10	-7	-4	-2	-4

## Algorithme de programmation dynamique

Alignement global: Needleman & Wunsch (1970)

- Trouver le meilleur alignement sur toute leur longueur
- Utilisé pour des séquences très similaires et ~ de même longueur

Alignement local: Smith & Waterman (1981)

- Chercher les régions les plus similaires dans les 2 séquences
- Permet de trouver des sous-séquences ayant des relations biologiques
- Plus adapté pour des séquences avec un faible degré de similarité ou de tailles différentes

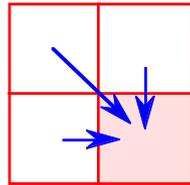
Heuristiques :

- FASTA - BLAST

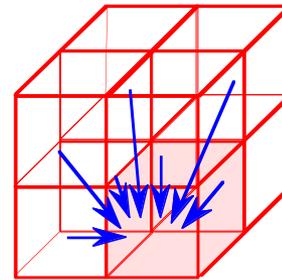
- Alignements multiples plus informatifs que les alignements de 2 séquences
- Alignement = point de départ pour les analyses phylogénétiques => qualité de l'alignement très important
- Alignement multiple global : alignement 2 à 2 est étendu pour inclure 3 seq. ou plus
  - Logiciels : CLUSTALW, MUSCLE, MAFFT, T-COFFEE, DIALIGN, PRANK, . . .
- Alignement multiple local : recherche de domaines/régions conservés
  - Logiciels : BLOCKS Web site, eMOTIF, GIBBS, HMMER, . . .

## Programmation dynamique

- La généralisation de l'algorithme N&W au traitement simultané de plus de deux séquences est théoriquement possible mais **inexploitable** en pratique.



Alignement de deux séquences : trois choix



Alignement de trois séquences : sept choix

- Pour un alignement de  $n$  séquences le nombre de chemins possibles pour chaque case est de  $2^n - 1$ .
- On a une croissance **exponentielle** du temps de calcul et de l'espace mémoire requis en fonction du nombre de séquences.
  - ⇒ Utilisation de méthodes **heuristiques**.

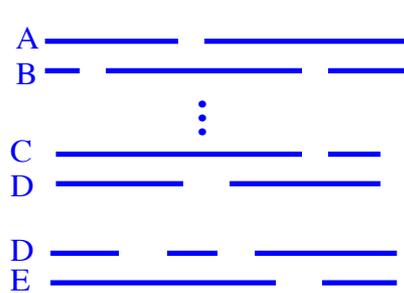
## Programmation dynamique

- Utilisation d'heuristiques : approximation de l'alignement optimal
- Méthodes d'alignement global:
  - Approche progressif (ex : CLUSTALW)
  - Amélioration de l'approche progressive : raffinement itératif, notion de consistance (ex : MUSCLE, MAFFT, PROBCONS, T-COFFEE)
  - Autres approches d'alignement multiple : structurelle (ex : STAMP), itérative (ex : HMMER, SAGA), principe « diviser pour régner » (ex : DCA), utilisation d'informations externes (ex : PRALINE, Espresso)
- Propriétés des méthodes progressives
  - Rapide
  - Besoin de peu de mémoire
  - Bonnes performances avec des séquences conservées

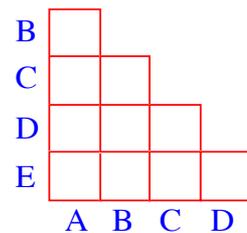
## Alignement progressif

- Approche consistant à construire **itérativement** l'alignement multiple en groupant des alignements de paires de séquences.
- Ce genre de méthodes comporte trois étapes :
  - L'alignement des paires de séquences.
  - Le groupement des séquences.
  - Le groupement des alignements (alignement progressif).
- **CLUSTAL** (Higgins, Sharp 1988, Thompson *et al.*, 1994), l'un des programmes d'alignements multiples le plus utilisé à l'heure actuelle utilise cette approche.
- MULTALIN, PILEUP, T-Coffee

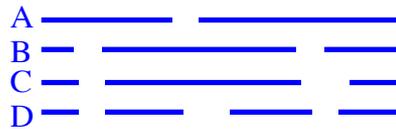
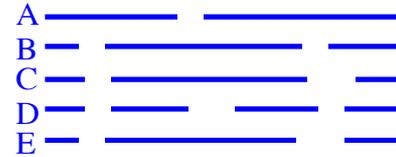
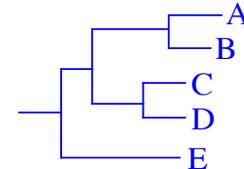
## Alignement progressif



Calcul de la matrice de distances



Construction de l'arbre guide



Groupement des alignements

Alignement des séquences ou des groupes de séquences en suivant l'ordre déterminé par l'arbre guide

## Pénalités en fonction de la position

CLUSTAL introduit des pondérations qui sont dépendantes de la **position** des gaps.

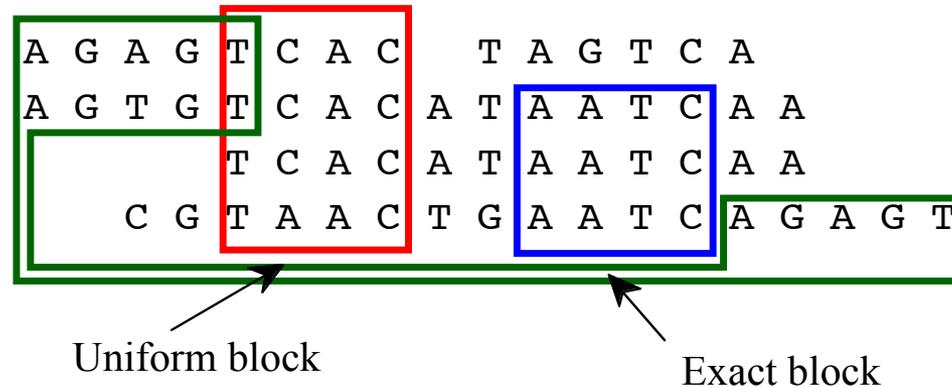
- Diminution de la pénalité à l' **emplacement** de gaps préexistants.
- Augmentation de la pénalité **au voisinage** (8 résidus) de gaps préexistants.
- Réduction de la pénalité au niveau de régions contenant des suites d' acides aminés **hydrophiles** ( $\geq 5$  résidus).
- Modification spécifiques en fonction des **acides aminés** présents (*e.g.*, la pénalité est plus faible avec Gly, Asn, Pro).

Ces pondérations sont prises en compte au moment du groupement des alignements.

## Dialign

Morgenstern et al. 1996 PNAS 93:12098

- Recherche de blocs similaires ( $\neq$  exact) sans gap entre les séquences



- Sélection de la meilleure combinaison possible de blocs similaires (uniformes ou non) consistents : heuristique (Abdeddaim 1997)
- Alignement ancré sur les blocs
- Plus lent que alignement progressif, mais meilleur alignement quand les séquences contiennent de grands indels; ne cherche pas à aligner des régions non-alignables

## Amélioration des alignements progressifs

- Alignement progressif
- Lors des alignements intermédiaire, prise en compte de tous les alignements deux à deux (globaux et locaux)
- Possibilité d'incorporer d'autres informations (structure, etc.)

## Amélioration des alignements progressifs

Les schémas de score utilisés par les algorithmes d'alignements par paires sont un élément très influent dans l'algorithme progressif :

- méthodes basées sur les matrices (ClustalW, Muscle, Kalign, . . . )
- méthodes basées sur la consistance (T-Coffee, MAFFT, ProbCons, . . . )

Contraintes de consistance:

- prises en compte de combinaisons consistantes de séquences

**SeqA GARFIELD THE LAST FAT CAT**

**SeqB GARFIELD THE FAST CAT**

**SeqC GARFIELD THE VERY FAST CAT**

**SeqD THE FAT CAT**

## Amélioration des alignements progressifs

### Alignements par paire

<b>SeqA</b> GARFIELD THE LAST FAT <b>CAT</b>	<b>SeqB</b> GARFIELD THE ---- FAST <b>CAT</b>
<b>SeqB</b> GARFIELD THE FAST <b>CAT</b> ---	<b>SeqC</b> GARFIELD THE VERY FAST <b>CAT</b>
<b>SeqA</b> GARFIELD THE LAST FA-T <b>CAT</b>	<b>SeqB</b> GARFIELD THE FAST <b>CAT</b>
<b>SeqC</b> GARFIELD THE VERY FAST <b>CAT</b>	<b>SeqD</b> -----THE FA-T <b>CAT</b>
<b>SeqA</b> GARFIELD THE LAST FAT <b>CAT</b>	<b>SeqC</b> GARFIELD THE VERY FAST <b>CAT</b>
<b>SeqD</b> -----THE ---- FAT <b>CAT</b>	<b>SeqD</b> -----THE ---- FA-T <b>CAT</b>

### Alignement progressif

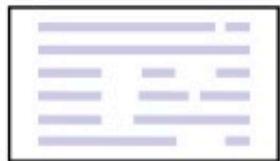
	<b>SeqA</b> GARFIELD THE LAST FAT <b>CAT</b>	<p>Alignement A-B retenu:</p>																								
	<b>SeqB</b> GARFIELD THE FAST <b>CAT</b>																									
	<b>SeqC</b> GARFIELD THE VERY FAST <b>CAT</b>																									
	<b>SeqD</b> THE FAT <b>CAT</b>																									
		<table border="0"> <tr> <td><b>SeqA</b></td> <td>GARFIELD</td> <td>THE</td> <td>LAST</td> <td>FA-T</td> <td><b>CAT</b></td> </tr> <tr> <td><b>SeqB</b></td> <td>GARFIELD</td> <td>THE</td> <td>FAST</td> <td>----</td> <td><b>CAT</b></td> </tr> <tr> <td><b>SeqC</b></td> <td>GARFIELD</td> <td>THE</td> <td>LAST</td> <td>FAST</td> <td><b>CAT</b></td> </tr> <tr> <td><b>SeqB</b></td> <td>-----</td> <td>THE</td> <td>----</td> <td>FA-T</td> <td><b>CAT</b></td> </tr> </table>	<b>SeqA</b>	GARFIELD	THE	LAST	FA-T	<b>CAT</b>	<b>SeqB</b>	GARFIELD	THE	FAST	----	<b>CAT</b>	<b>SeqC</b>	GARFIELD	THE	LAST	FAST	<b>CAT</b>	<b>SeqB</b>	-----	THE	----	FA-T	<b>CAT</b>
<b>SeqA</b>	GARFIELD	THE	LAST	FA-T	<b>CAT</b>																					
<b>SeqB</b>	GARFIELD	THE	FAST	----	<b>CAT</b>																					
<b>SeqC</b>	GARFIELD	THE	LAST	FAST	<b>CAT</b>																					
<b>SeqB</b>	-----	THE	----	FA-T	<b>CAT</b>																					

## Amélioration des alignements progressifs

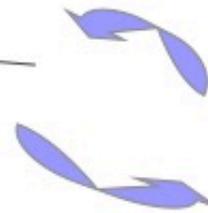
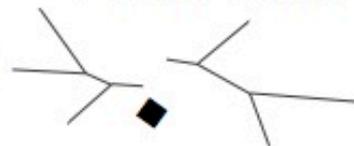
### Le raffinement itératif

- Pb majeur de l'alignement progressif = une erreur faite au début de l'alignement ne peut être corrigée par la suite  
=> étape de raffinement ajoutée (construction itérative de l'arbre guide, division de l'arbre guide en sous-arbre, ...)
- Objectif = améliorer le score d'alignement global en réalignant des sous-groupes de séquences de manière répétée puis en alignant ces sous-groupes dans l'alignement global de toutes les séquences

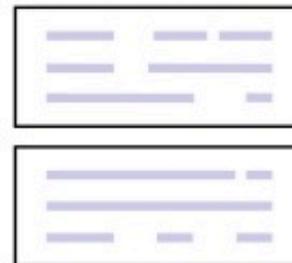
Alignement 1 ( $S_1$ )




2 sous-arbres



Alignements  
des deux  
sous-arbres

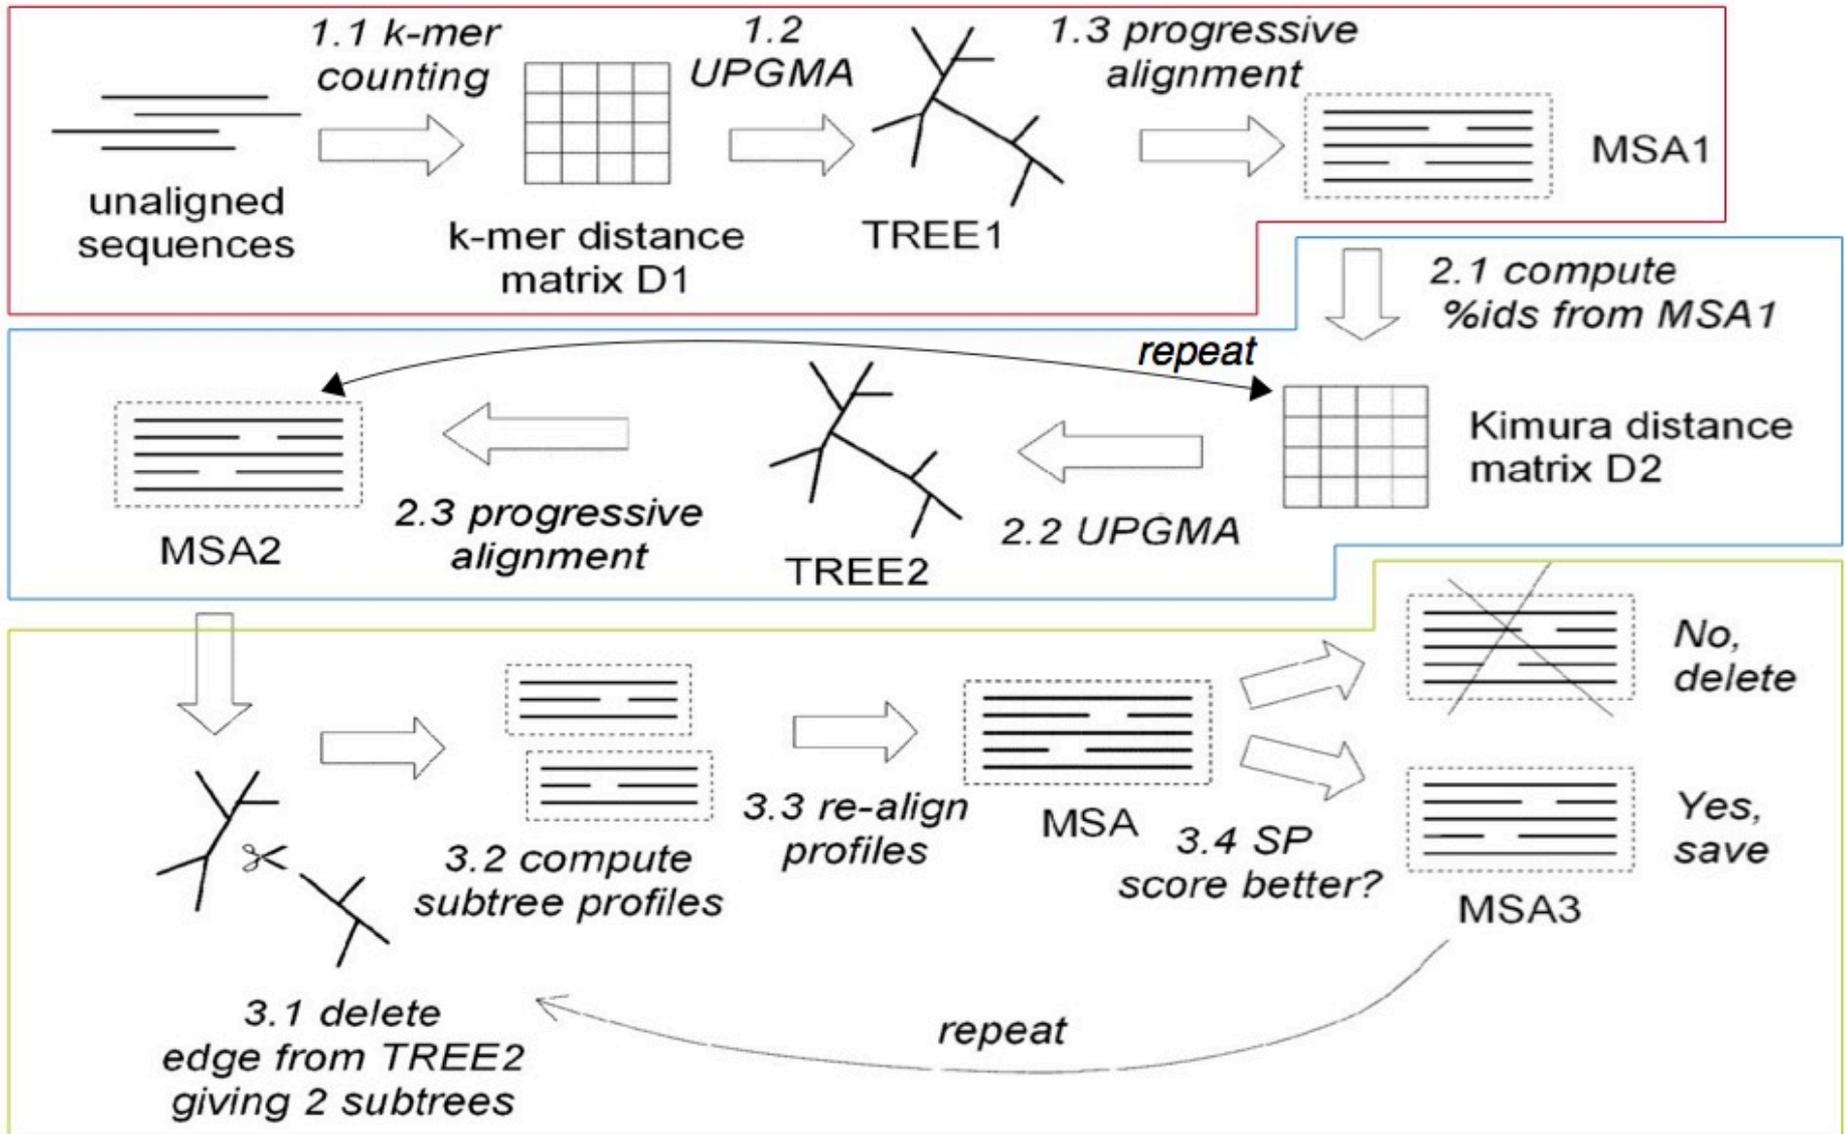


Alignement 2 ( $S_2$ )



# L'alignement multiple

Amélioration des alignements progressifs : exemple MUSCLE



## Amélioration des alignements progressifs

Ex MAFFT

Même principe que MUSCLE

- Etape d'alignement par paire : utilisation de l'algorithme Transformée de Fourier rapide (FFT) et d'un algorithme de programmation dynamique
- 3 types de versions de MAFFT
  - Méthode progressive (I)
  - Méthode de raffinements itératif utilisant le score WSP (weighted sum-of-pairs) (II)
  - Méthode de raffinements itératif utilisant le score WSP et des scores bases sur la consistance (III)
- Méthodes pour construire les alignements par paire
  - Algorithme FFT (I et II)
  - Algorithme d'alignement global de Needleman et Wunsch (III)
  - Algorithme d'alignement local de Smith et Waterman (III)

Published online March 23, 2006

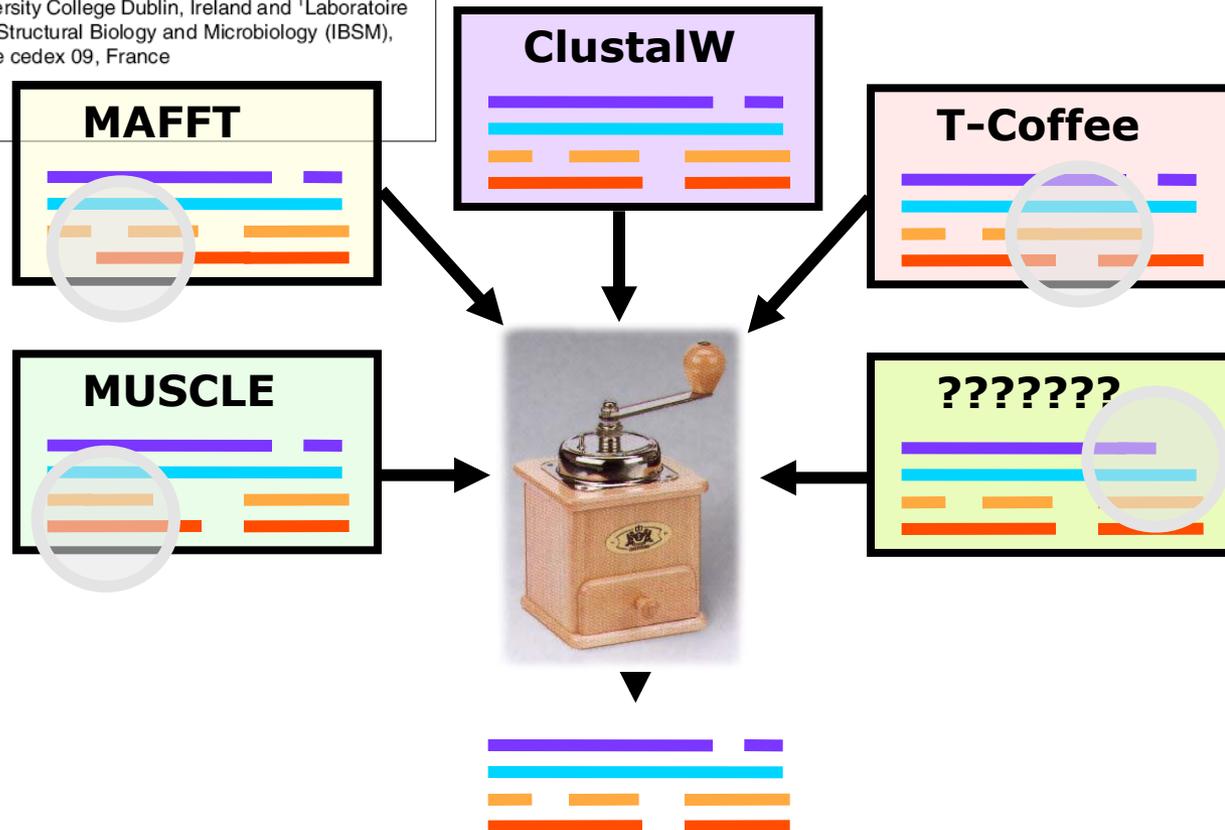
1692-1699 *Nucleic Acids Research*, 2006, Vol. 34, No. 6  
doi:10.1093/nar/gkl091

## M-Coffee: combining multiple sequence alignment methods with T-Coffee

Iain M. Wallace, Orla O'Sullivan, Desmond G. Higgins and Cedric Notredame<sup>1,\*</sup>

The Conway Institute of Biomolecular and Biomedical Research, University College Dublin, Ireland and <sup>1</sup>Laboratoire Information Génomique et Structurale, CNRS UPR2589, Institute for Structural Biology and Microbiology (IBSM), Parc Scientifique de Luminy, 163 Avenue de Luminy, 13288, Marseille cedex 09, France

Received January 19, 2006; Revised February 7, 2006; Accepted March 7, 2006



## Nettoyage de l'alignement

- Alignement pouvant contenir des grandes zones de gap
- Séquences de longueurs différentes
- ....

Nettoyage de l'alignement pour avoir un alignement de meilleur qualité  
 = suppression des régions non informatives, mal conservées

-> Subjectivité du nettoyage manuel

Logiciels: Trimal, Gblocks, ...



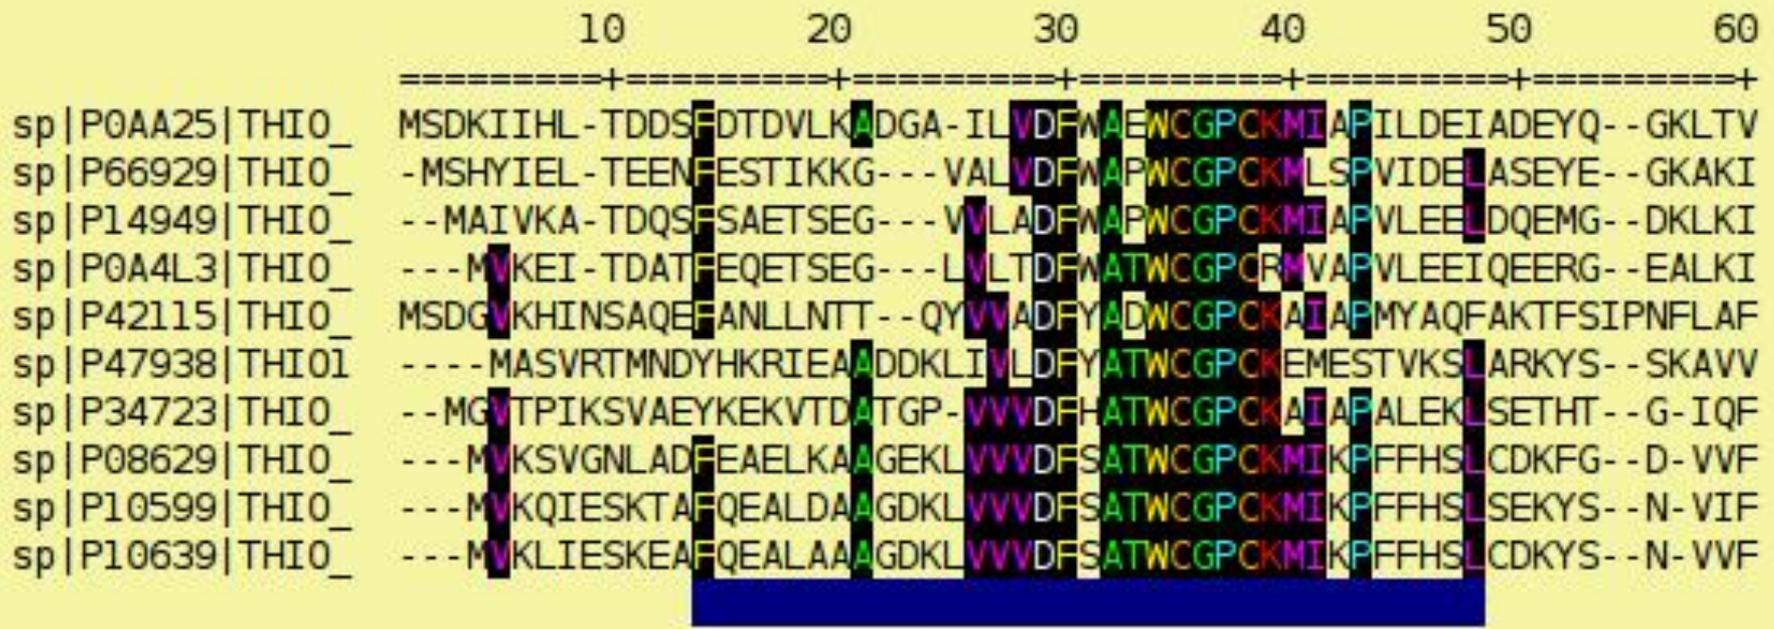
## Gblocks 0.91b Results

Processed file: **gblocks**

Number of sequences: **10**

Alignment assumed to be: **Protein**

New number of positions: **60** (selected positions are underlined in blue)



sp|P10639|THIO\_ LEVDVDDCQDVAAADCEVKKCMPTFQFYKKGQKVGGE-----FSGA-NNEKLEASITEYA---

130

=====+

sp|P0AA25|THIO\_ -----  
sp|P66929|THIO\_ -----  
sp|P14949|THIO\_ -----  
sp|P0A4L3|THIO\_ -----  
sp|P42115|THIO\_ KEKAAAAGSS  
sp|P47938|THIO\_ -----  
sp|P34723|THIO\_ -----  
sp|P08629|THIO\_ -----  
sp|P10599|THIO\_ -----  
sp|P10639|THIO\_ -----

### Parameters used

Minimum Number Of Sequences For A Conserved Position: 6  
Minimum Number Of Sequences For A Flanking Position: 8  
Maximum Number Of Contiguous Nonconserved Positions: 8  
Minimum Length Of A Block: 5  
Allowed Gap Positions: With Half  
Use Similarity Matrices: Yes

### Flank positions of the 2 selected block(s)

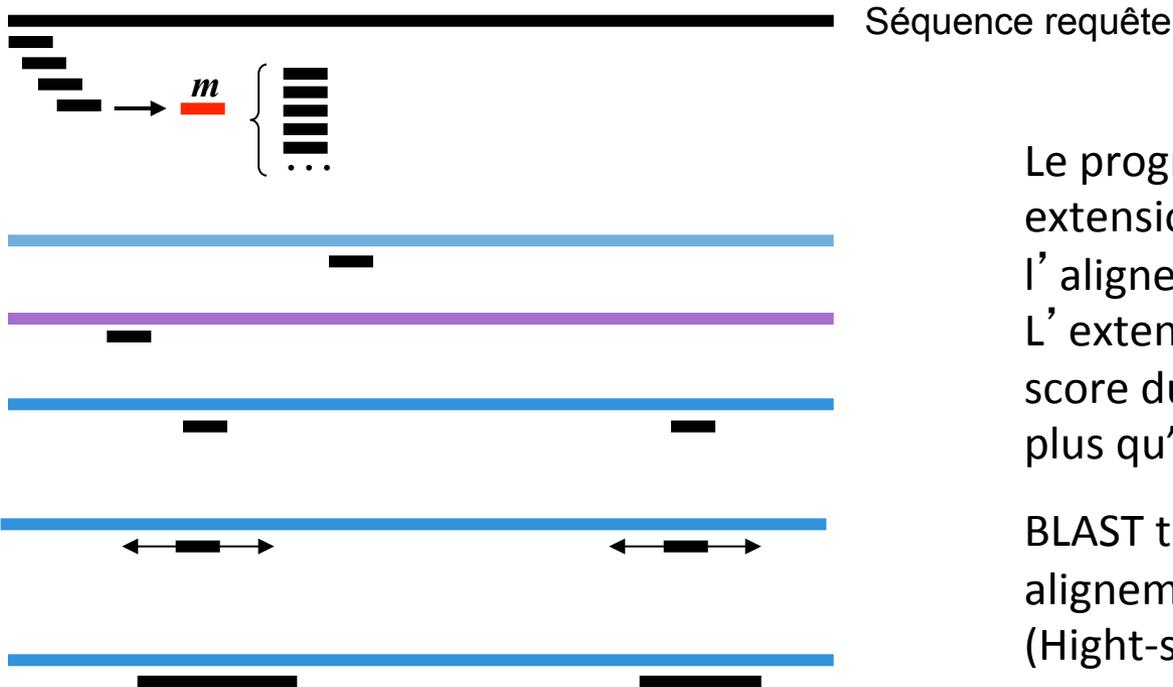
Flanks: [14 48] [65 89]

New number of positions in gblocks-gb: **60** (46% of the original 130 positions)

- BLAST = Basic Local Alignment Search Tool
- **Objectif** : retrouver, dans une banque de référence, une ou des séquences homologues à ma séquence en entrée
- Vocabulaire de Blast :
  - **Query** : la séquence requête
  - **Subject** : la séquence dans la banque de référence
  - **Hit** : séquence de la banque similaire à la query
  - **HPS** (High Scoring Pairs) : résultats de blasts : meilleurs alignements locaux par paires pour le hit
  - **Score S** : Détermine le degré de ressemblance entre deux séquences (basé sur la matrice utilisée et sur les pénalités de gaps). Plus le score est élevé, plus les séquences sont proches
  - **Bit-Score S'** : score normalisé (permet de comparer différents résultats de blast entre eux)

## BLAST : Basic Local Alignment Search Tool (Altschul *et al*, 1990)

- Détermination d'une longueur de mot :  $w = 2$  ou 3 acides aminés pour les protéines , 11 pour les nucléotides ;
- Hachage de la séquence « requête » en mot de taille  $w$



- Recherche de mots (oligonucléotides/oligopeptides) partagés entre la **query** et la séquence de la banque :
  - Taille par défaut des mots : ADN : 11 /Protéines : 3
  - Pour les protéines, blast recherche à la fois les mots exacts mais aussi les mots synonymes (voisins)

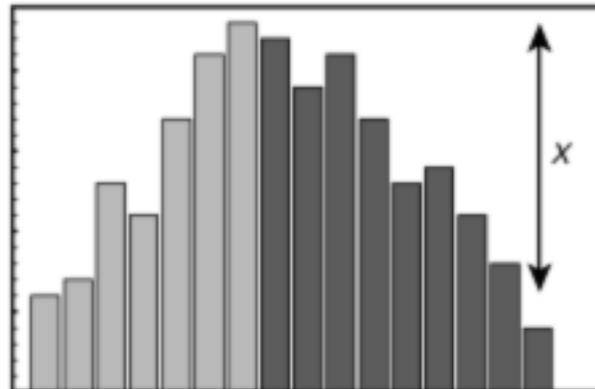


- Quand un mot est trouvé : blast essaie d'étendre le **hit** en ajoutant des paires de bases/acides aminés. L'alignement grandissant obtient un **score** :
  - Score nucléotides calculé selon la matrice de substitution (par défaut : +1/-3)
  - Score protéines calculé selon la matrice BLOSUM62 par défaut

- Si le score s'écarte de trop (seuil défini par défaut, *zone X figure*) du score le plus haut établi pour l'alignement, blast arrête d'étendre l'alignement. Cette procédure d'extension est répétée à l'autre extrémité de l'alignement.
- On obtient alors un alignement sans gap, appelé **HSP** (High Scoring Pair) qui est conservé si sa e-value est en dessous du seuil défini.

Extending a word hit into an HSP:

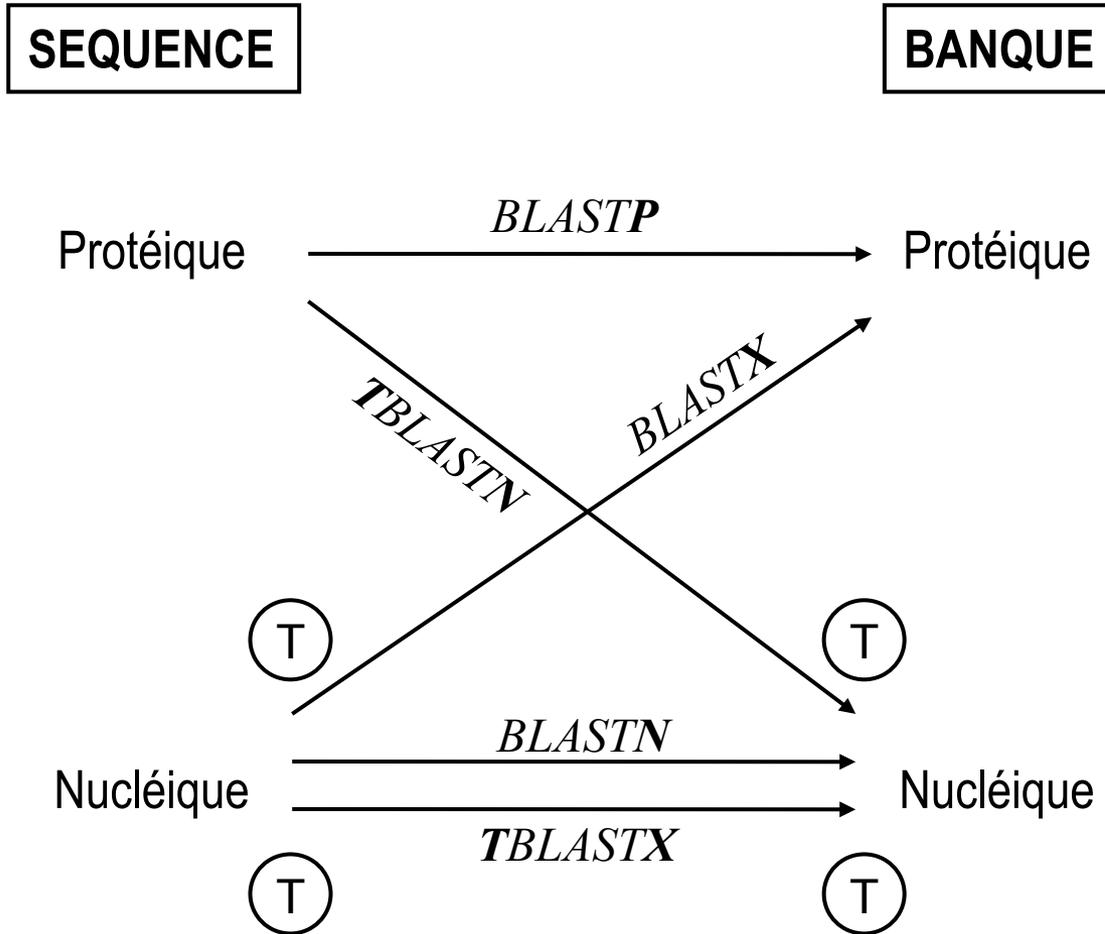
Query sequence: EGDCVFDGMI **GSD**QGS L  
 E C+ +G **G+D** GS+  
 Database sequence: EAGCLQNGQR**GTD**VGSV



G S D Q G S L R P D G F D V R C D  
 G T D V G S V M D E I P N D F E C  
 6 1 6-2 6 4 2-1-3 2-4-4 1-3-3-4-5



Extension de l'alignement vers la droite



- E-value

–  $E = Y Z K e^{-\lambda S}$

- s = score authentique
- Y = longueur de la séquence
- Z = taille de la banque
- K et  $\lambda$  = constante

- E = Probabilité d'observer au hasard ce score à travers la banque de séquences considérée.



**faux-positifs:** on a un alignement, mais les séquences ne sont pas homologues

On considère que :

E-Value	Conclusion
< e-100	match exact (même gène, même espèce)
e-100...e-50	gènes quasiment identiques (allèles, mutations, espèces voisines)
e-50...0.1	relation plus lointaines
> 0.1	séquences en général inintéressantes

E-value = nombre d'alignements attendus par hasard ayant un score supérieur au score obtenu dans la banque considérée

- Plus la valeur est faible, plus l'alignement est fiable
- Dépend du nombre total de résidus contenus dans la banque
- Ces valeurs ne sont pas comparables entre deux banques

Le score HSP =  $\Sigma$  bonus pour appariement

- $\Sigma$  malus pour mésappariement
- $\Sigma$  malus pour ouverture d'un gap
- $\Sigma$  malus pour extension d'un gap

Une faible valeur de la E value indique que le résultat n'est pas du au hasard

Sequences producing significant alignments:

		Score (bits)	E Value
<a href="#">swissprot:CTRB_HUMAN</a>	Chymotrypsinogen B precursor (EC 3.4.21.1).	<u>433</u>	e-121
<a href="#">swissprot:CTR2_CANFA</a>	Chymotrypsinogen 2 precursor (EC 3.4.21.1).	<u>386</u>	e-107
<a href="#">swissprot:CTRB_RAT</a>	Chymotrypsinogen B precursor (EC 3.4.21.1).	<u>383</u>	e-106
<a href="#">swissprot:CTRB_BOVIN</a>	Chymotrypsinogen B (EC 3.4.21.1).	<u>348</u>	4e-96
<a href="#">swissprot:CTRA_BOVIN</a>	Chymotrypsinogen A (EC 3.4.21.1).	<u>330</u>	1e-90
<a href="#">swissprot:CTRA_GADMO</a>	Chymotrypsin A precursor (EC 3.4.21.1).	<u>286</u>	2e-77

Un score élevé, ou mieux une série de scores élevés, indique une relation (homologie ou famille de gènes)

Deux fragments du génome d'*Escherichia coli* :

>fragment1 : 1100 bp - from 779751 bp to 780850 bp

>fragment2 : 400 bp - from 2518951 bp to 2519350 bp

Réaliser l'alignement global et local de ces 2 fragments,  
en utilisant respectivement

- Stretcher (<http://emboss.bioinformatics.nl/cgi-bin/emboss/stretcher>) global
- Matcher (<http://emboss.bioinformatics.nl/cgi-bin/emboss/matcher>) local.

Donnez les résultats de vos 2 alignements. Que pouvez-vous déduire ?

Vous pouvez visualiser les alignements avec le logiciel seaview.

Rmq : pour le logiciel Matcher : vous devrez modifier quelques paramètres dans "*Additional section*" puis "*Number of alternative matches*" : choisir la valeur 5 (le logiciel cherchera les 5 meilleurs alignements possibles).

PARTIE I : Phylogénie moléculaire

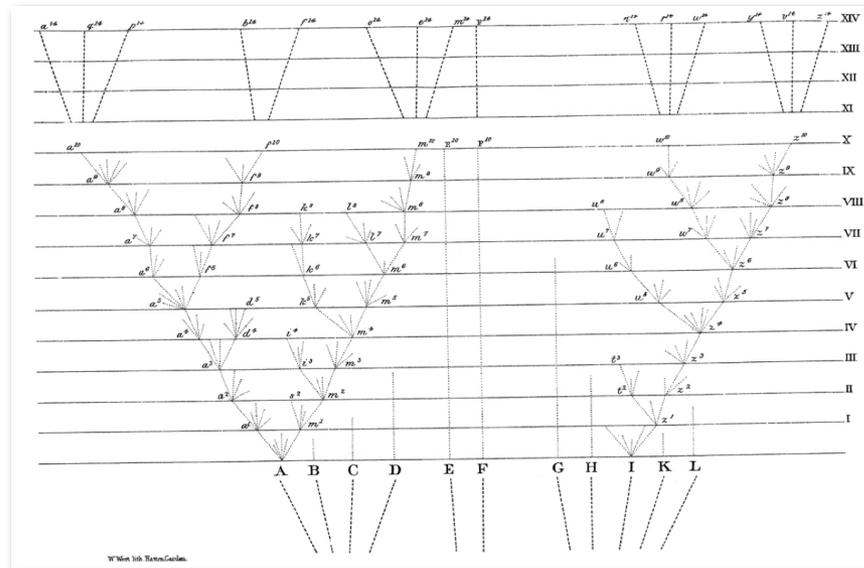
# LES ÉLÉMENTS D'UNE PHYLOGENIE

- Les caractères
- Le jeu de données
- Les banques et formats
- Les alignements
- **Les arbres**

## Les premières représentations



Lamarck, 1809



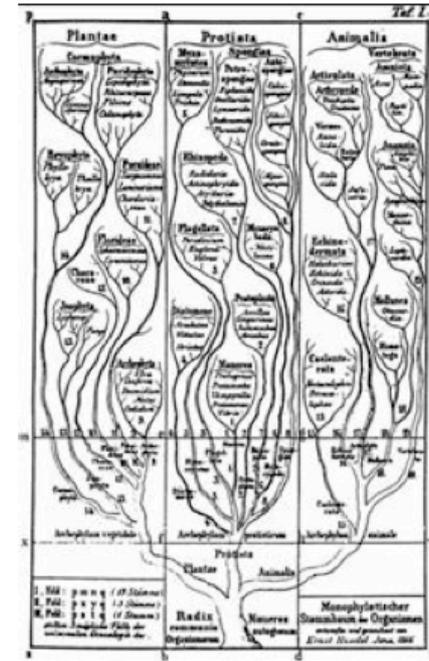
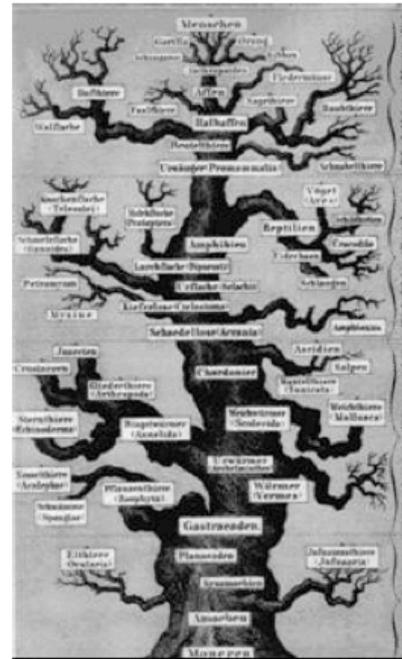
Darwin, 1859

Sens de lecture



Haeckel, 1860

*Volonté de représenter le développement paléontologique des organismes par analogie avec l'ontogénie ou histoire du développement individuel*

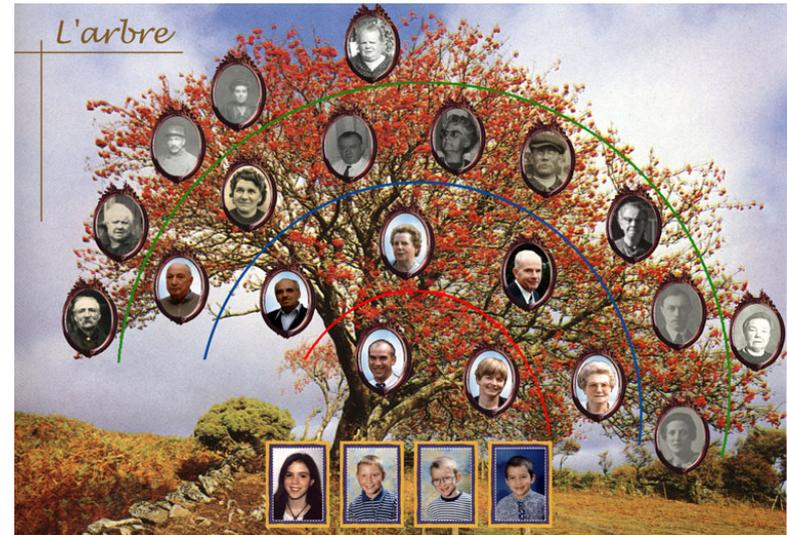
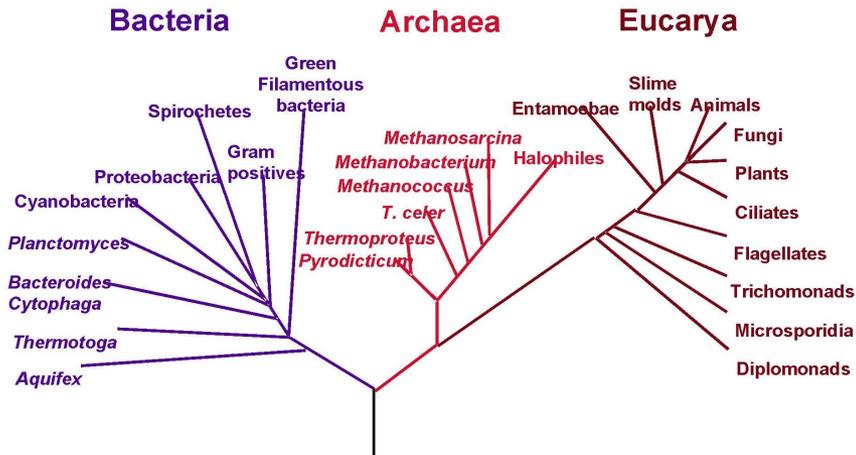


Sens de lecture

**Ontogénèse** : développement progressif d'un être vivant de sa conception à sa mort  
**Phylogénèse** : caractérise le développement d'une espèce.

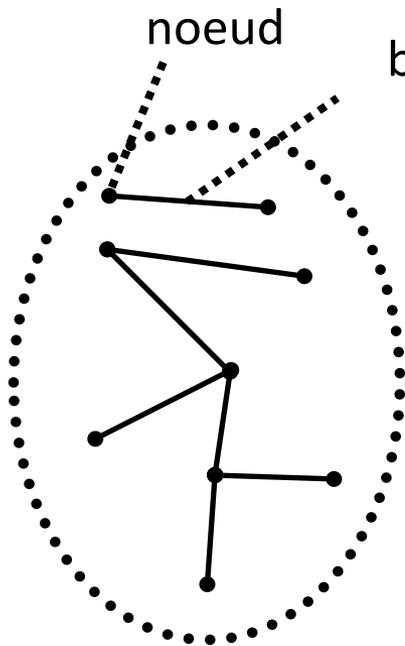
Différences entre un arbre phylogénétique et un arbre généalogique.

## Phylogenetic Tree of Life

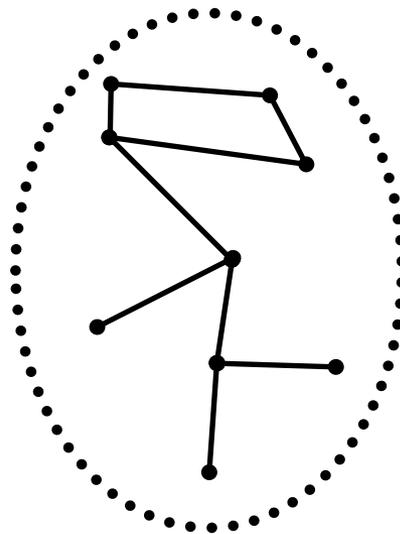


1. il est construit à partir de groupes, d'espèces, et non d'individus,
2. il exprime les relations de parenté et non de descendance ; c'est-à-dire que l'identification des ascendants importe moins que la parenté relative de deux espèces contemporaines,
3. il infère le passé et en ce sens se pose comme hypothèse.

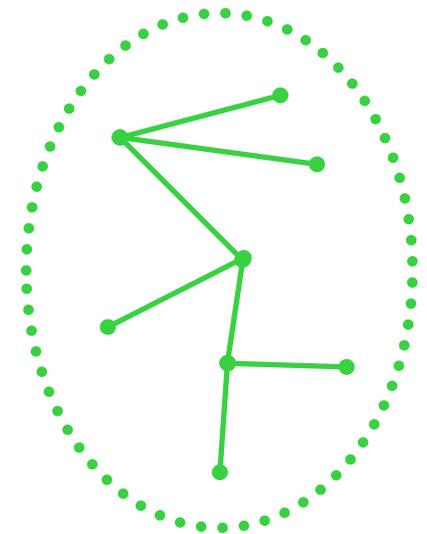
- Les relations évolutives sont représentées en créant une structure arborescente appelée phylogénie ou **arbre** qui illustre les relations entre les espèces (ou les séquences).
- Arbre = réseau connexe non cyclique



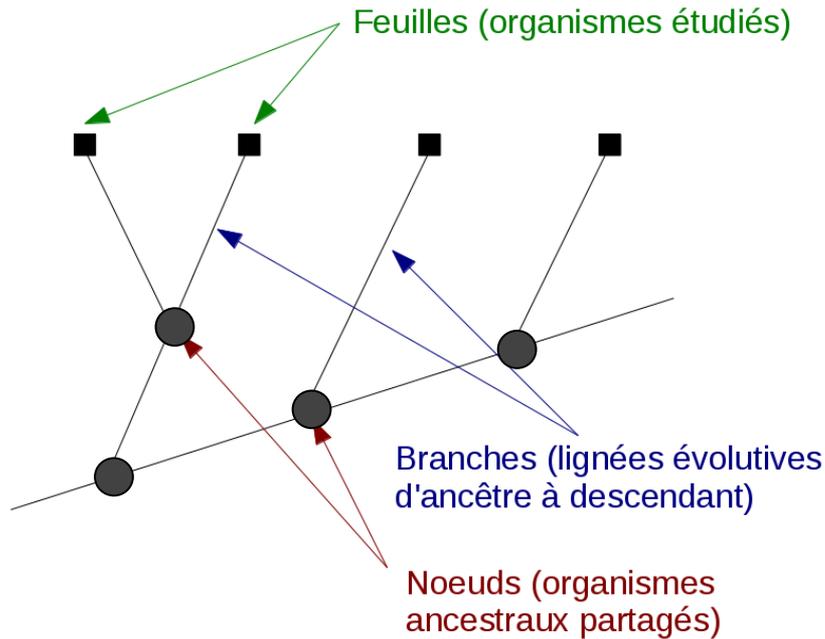
Réseau non connexe non cyclique



Réseau connexe cyclique



Réseau connexe non cyclique



- HTU : Hypothetical Taxonomic Unit
- OTU : Operational Taxonomic Unit

Branches représentent l'évolution moléculaire

Internes : reliant 2 noeuds

Externes : noeud à feuille

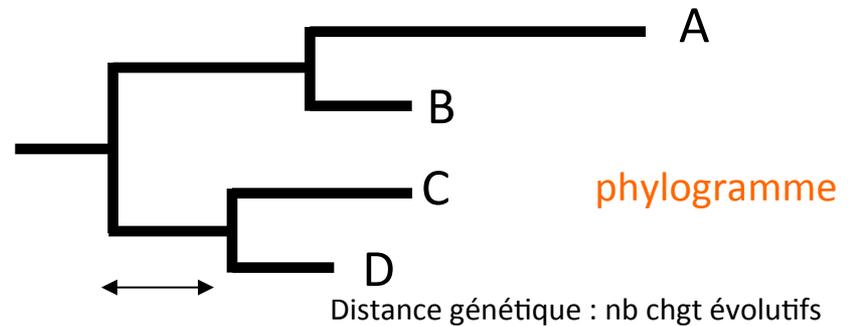
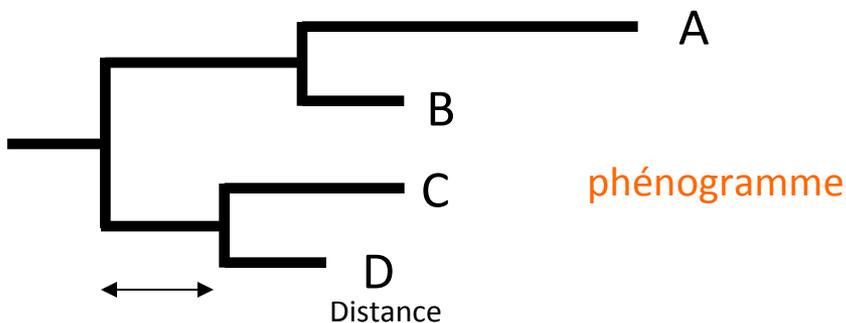
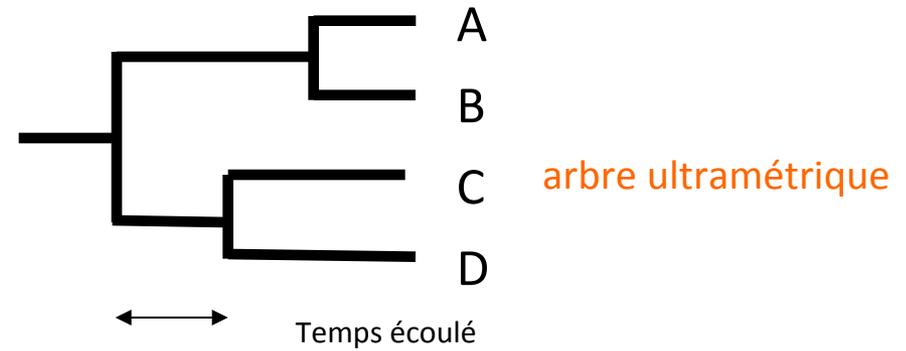
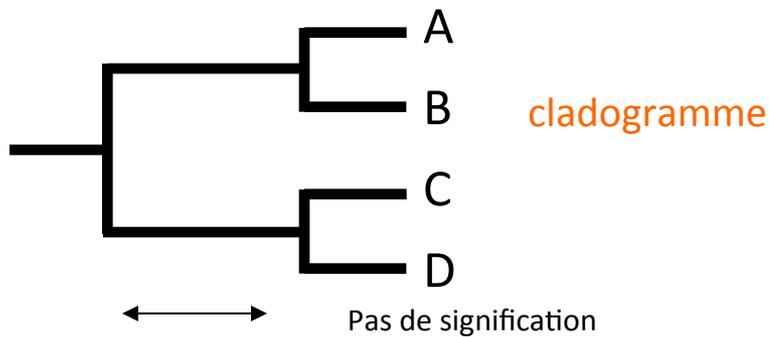
Longueur de branche :

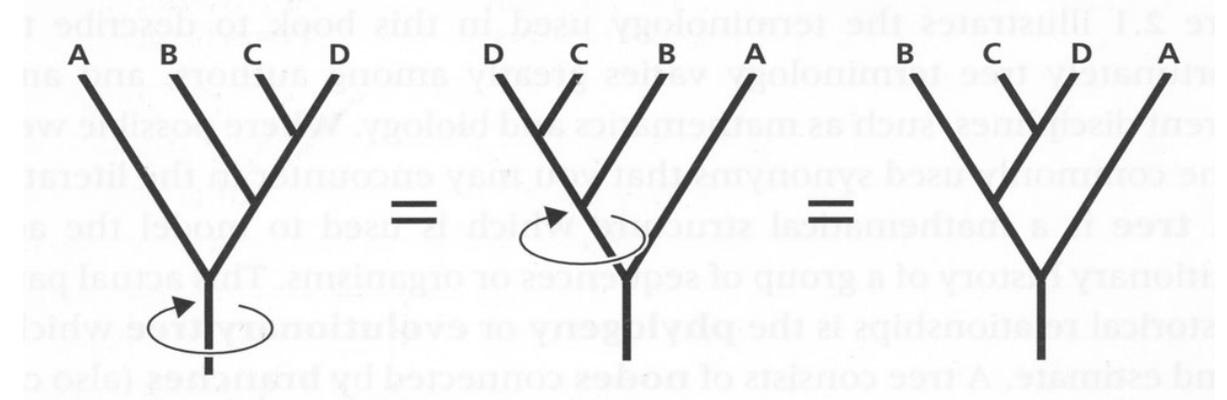
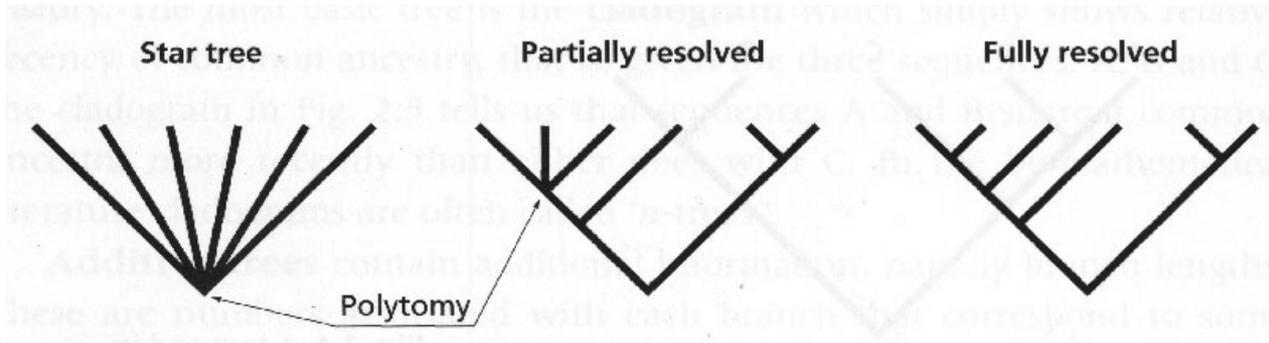
Nombre moyen de remplacements d'un résidu par un autre sur chaque site de la molécule étudiée le long de cette branche (unité : nb de substitutions/site)

La longueur de branche est proportionnelle à l'éloignement en terme d'évolution entre les séquences et leur ancêtre

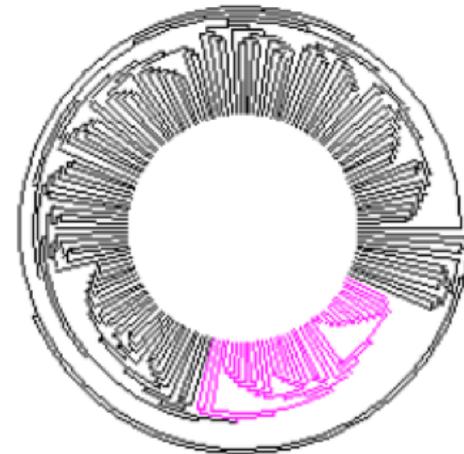
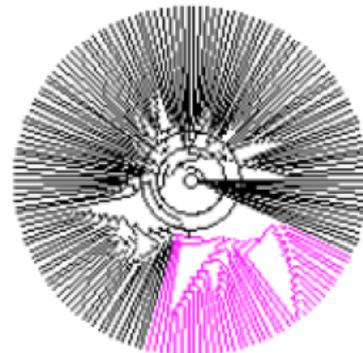
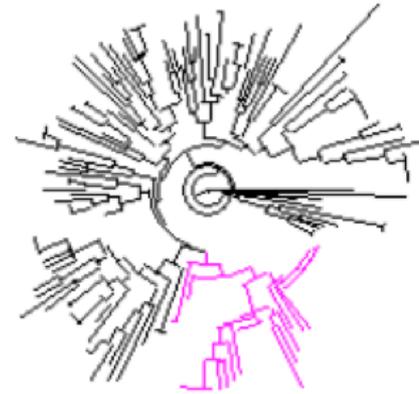
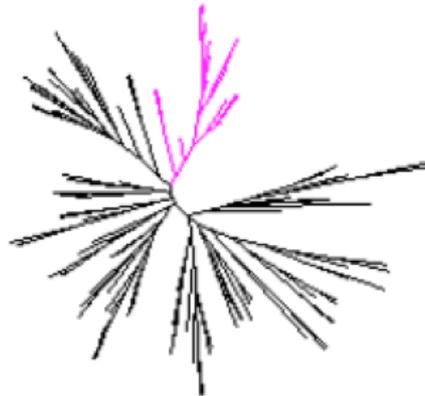
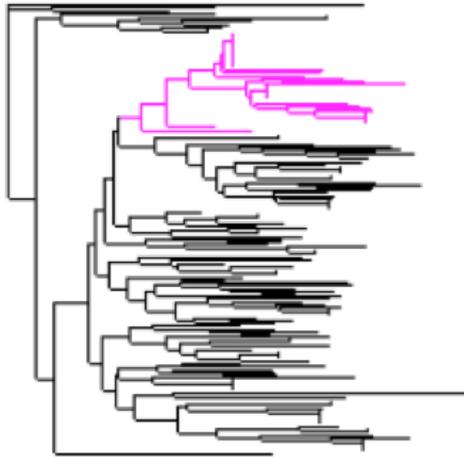
Les méthodes **cladistiques et phénétique** construisent un arbre (**dendrogramme**)

- **cladogramme** - un dendrogramme exprimant les relations phylogénétiques entre taxa et construit à partir de l'analyse cladistique;
- **phénogramme** - un dendrogramme obtenu par méthodes de distance où les relations entre taxa expriment des degrés de similitude globale;
- **phylogramme** - un dendrogramme dont la longueur des branches est proportionnelle au nombre de changements évolutifs.



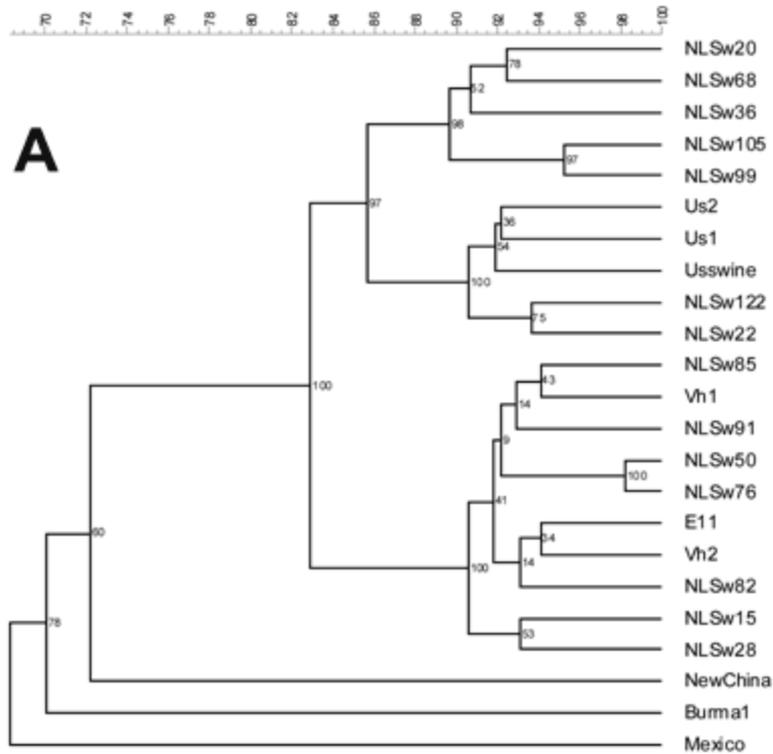


Trois différentes représentations de la même topologie d'arbre



Différentes représentations de la même topologie d'arbre

# Les arbres : enracinement



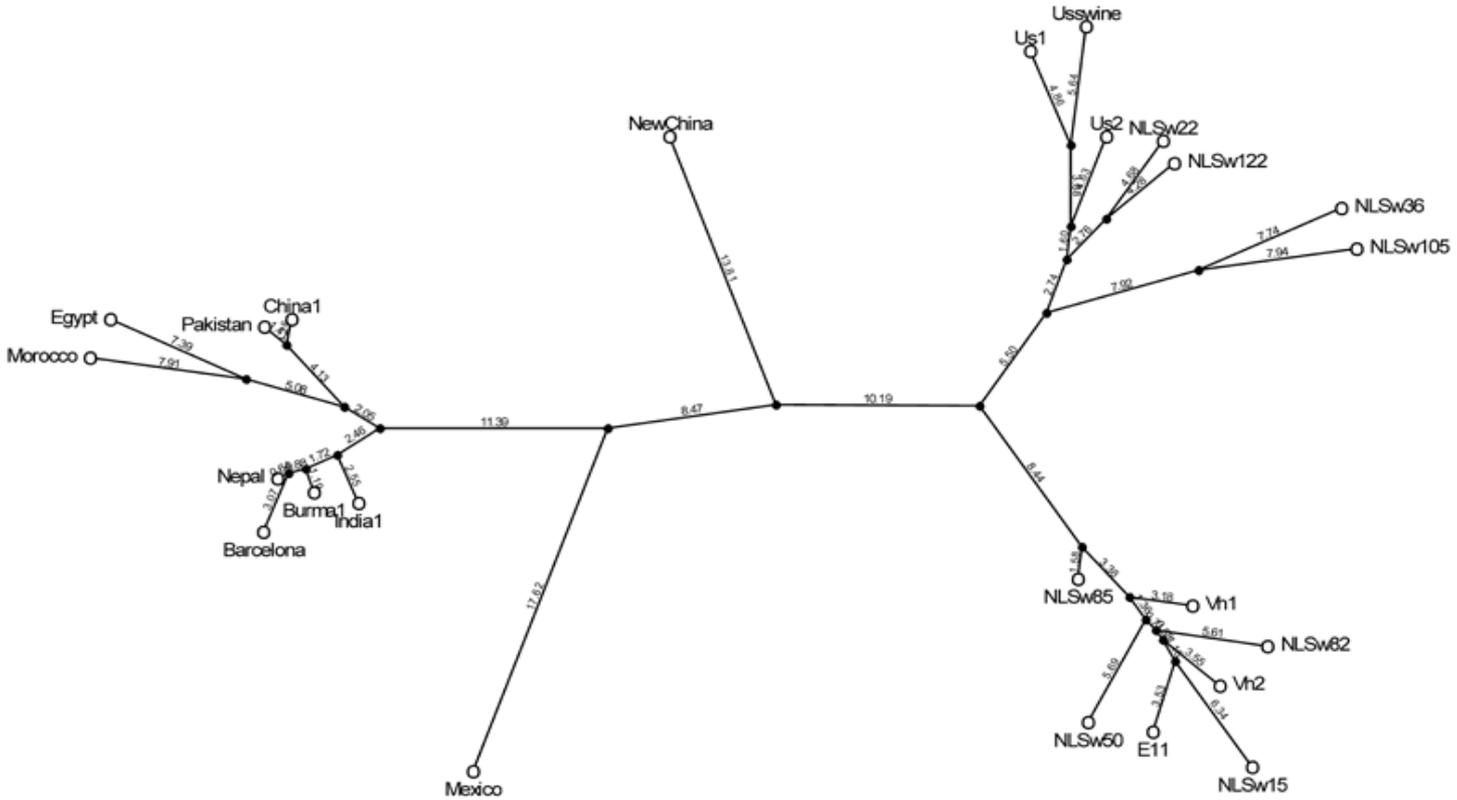
Ancien  Recent

Un arbre raciné à un nœud (la racine) qui représente un événement dans le temps plus ancien que n'importe quel autre nœud dans l'arbre.

Un arbre raciné a une direction (les nœuds peuvent être ordonnés en termes "d'anciens" ou "récents").

Dans un arbre raciné la distance entre deux nœuds est représentée le long de l'axe du temps.

# Les arbres : enracinement



Dans un arbre non raciné il n'y a pas de direction.  
 Nous ne savons pas si un nœud est plus ancien qu'un autre.

La distance le long des branches représente directement la distance entre les nœuds.

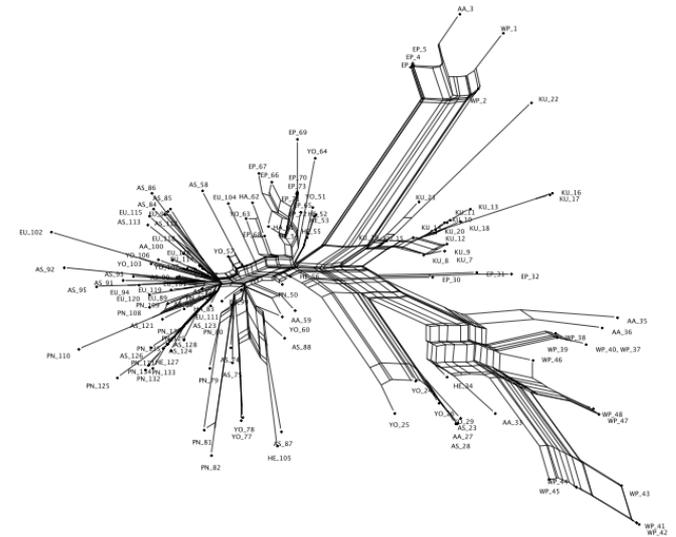
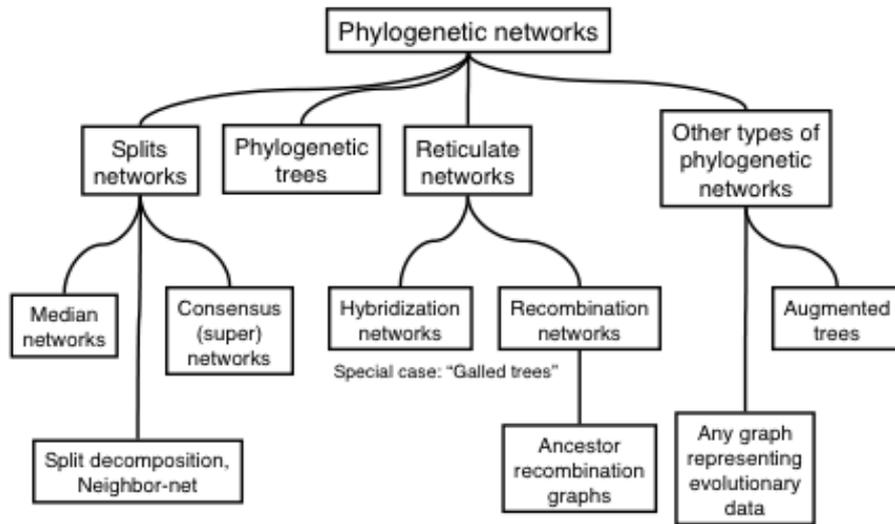
Une stratégie couramment utilisée pour «raciner un arbre» est d'inclure les espèces « outgroupe » dans l'analyse

Ces espèces sont connus pour être plus lointaines que les espèces d'intérêt.

Bien que l'arbre inféré pour toutes les espèces soit sans racines, **la racine est censée être située le long de la branche** qui mène à « l' outgroupe » afin que l'arbre de l'espèce ingroup soit enraciné.

Cette stratégie est appelée enracinement « outgroupe ».

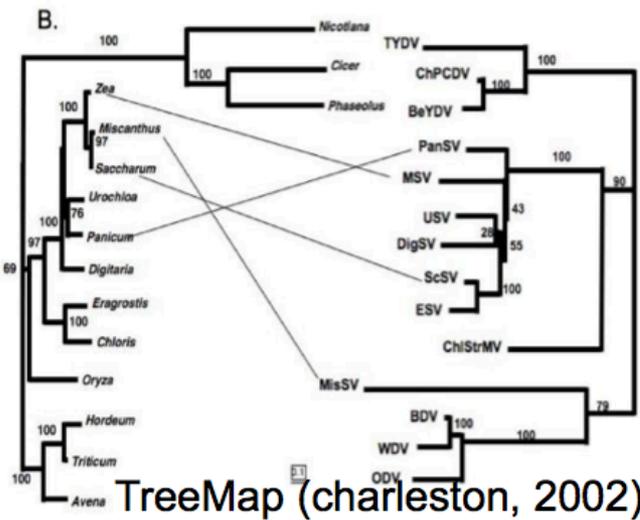
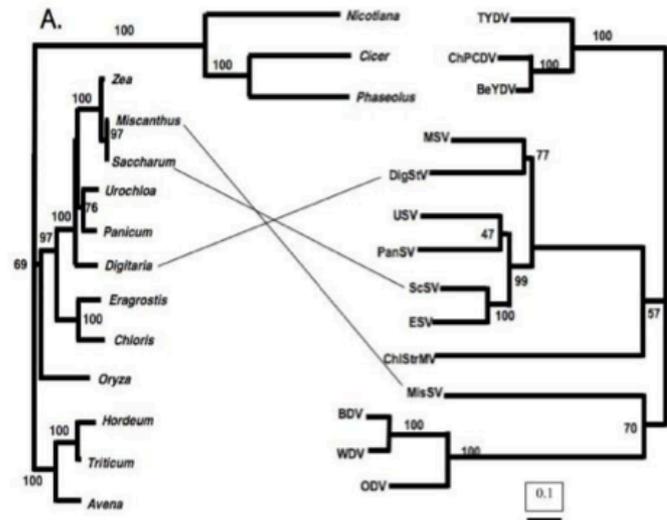
Il existe d' autres représentation : les réseaux phylogénétiques



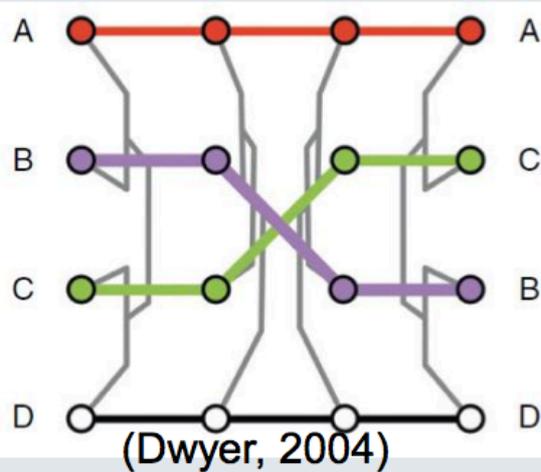
- permettent de rendre comptes des évènements évolutifs : les transferts latéraux, les recombinaisons, les duplications
- de représenter des arbres consensus

« Tanglegram » hôtes/parasites

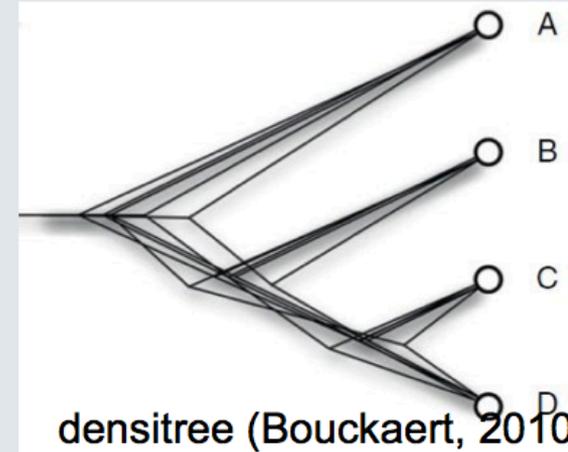
« uncertainty » (tree topology and branch length)



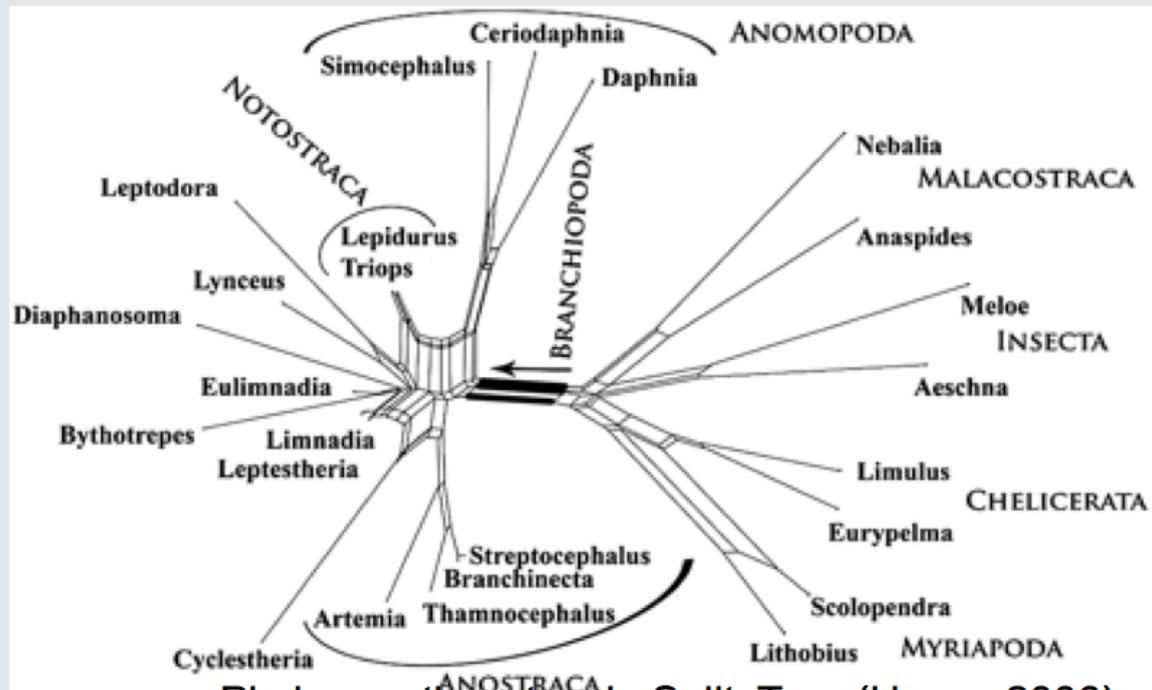
TreeMap (charleston, 2002)



(Dwyer, 2004)

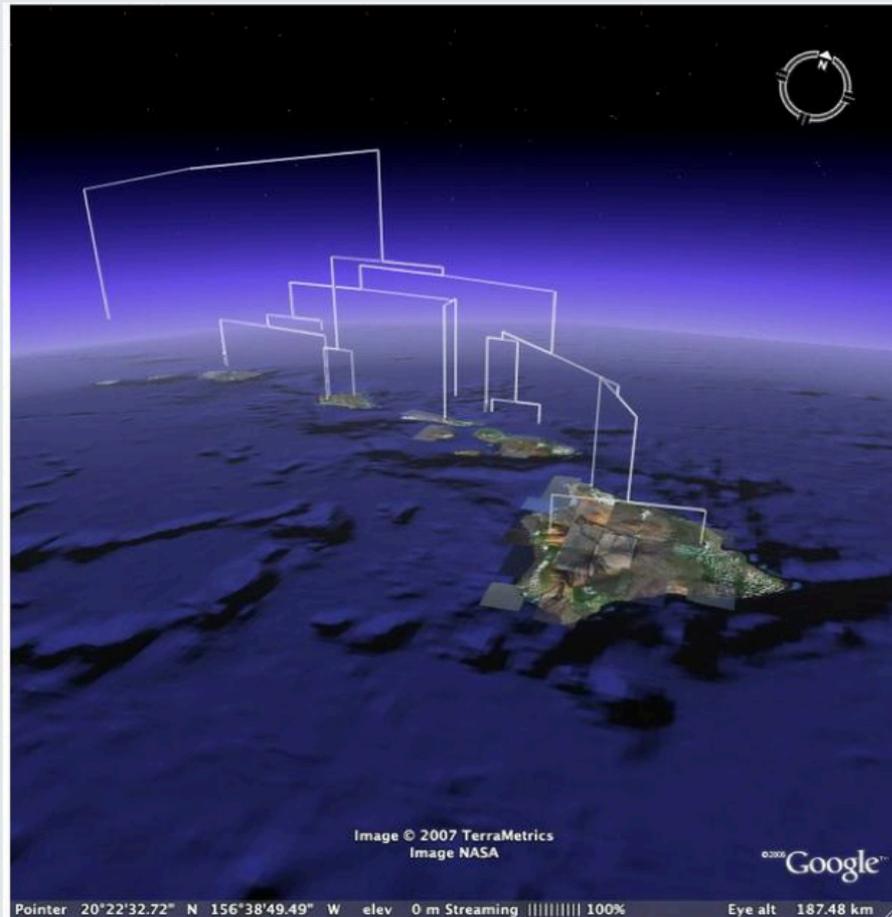


densitree (Bouckaert, 2010)



Phylogenetic network, SplitsTree (Huson 2006)

## Géophylogénies

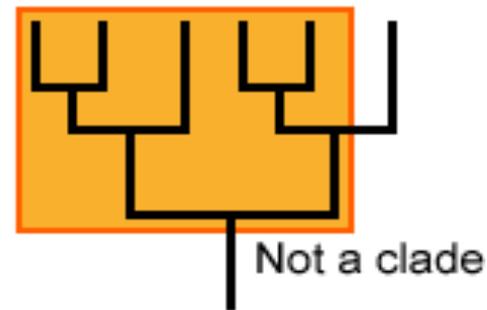
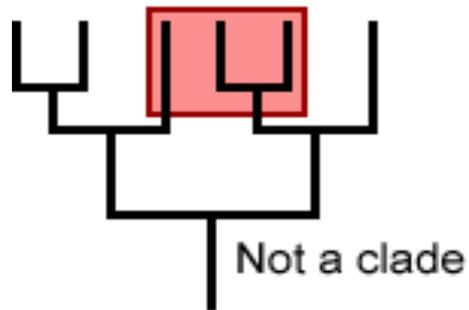
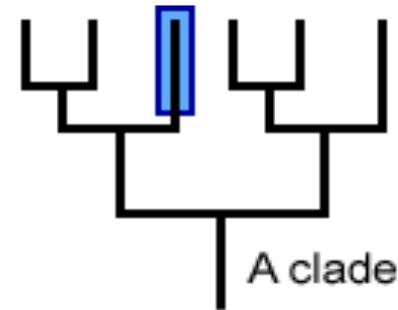
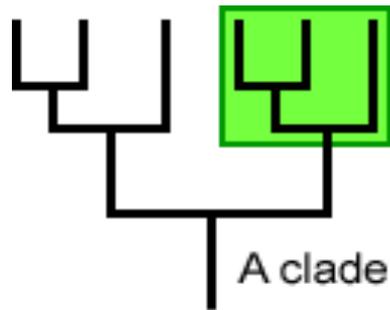


Google Earth



GenGIS (Parks 2009)

- **Clade** : groupe monophylétique d'organismes vivants : c'est-à-dire qui inclut un ancêtre commun et tous ses descendants.



Un groupe **monophylétique** contient l' ancêtre commun et **tous** ses descendants

*Hominoidea*  
singes

Gibbon

Orang-outan

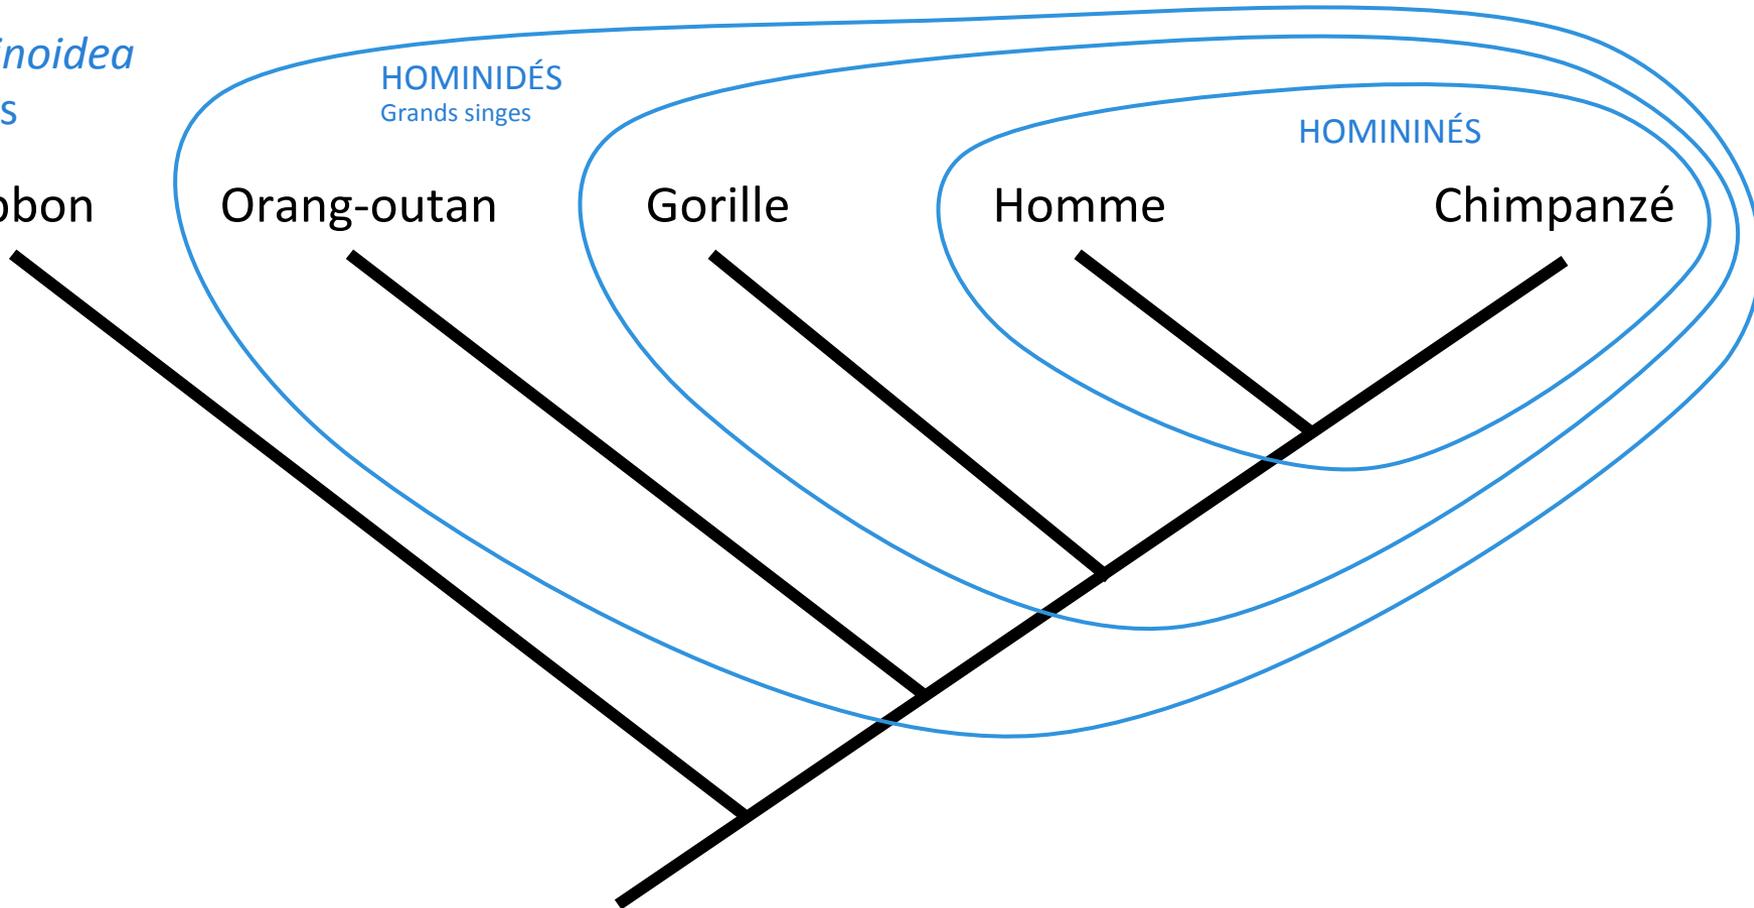
Gorille

Homme

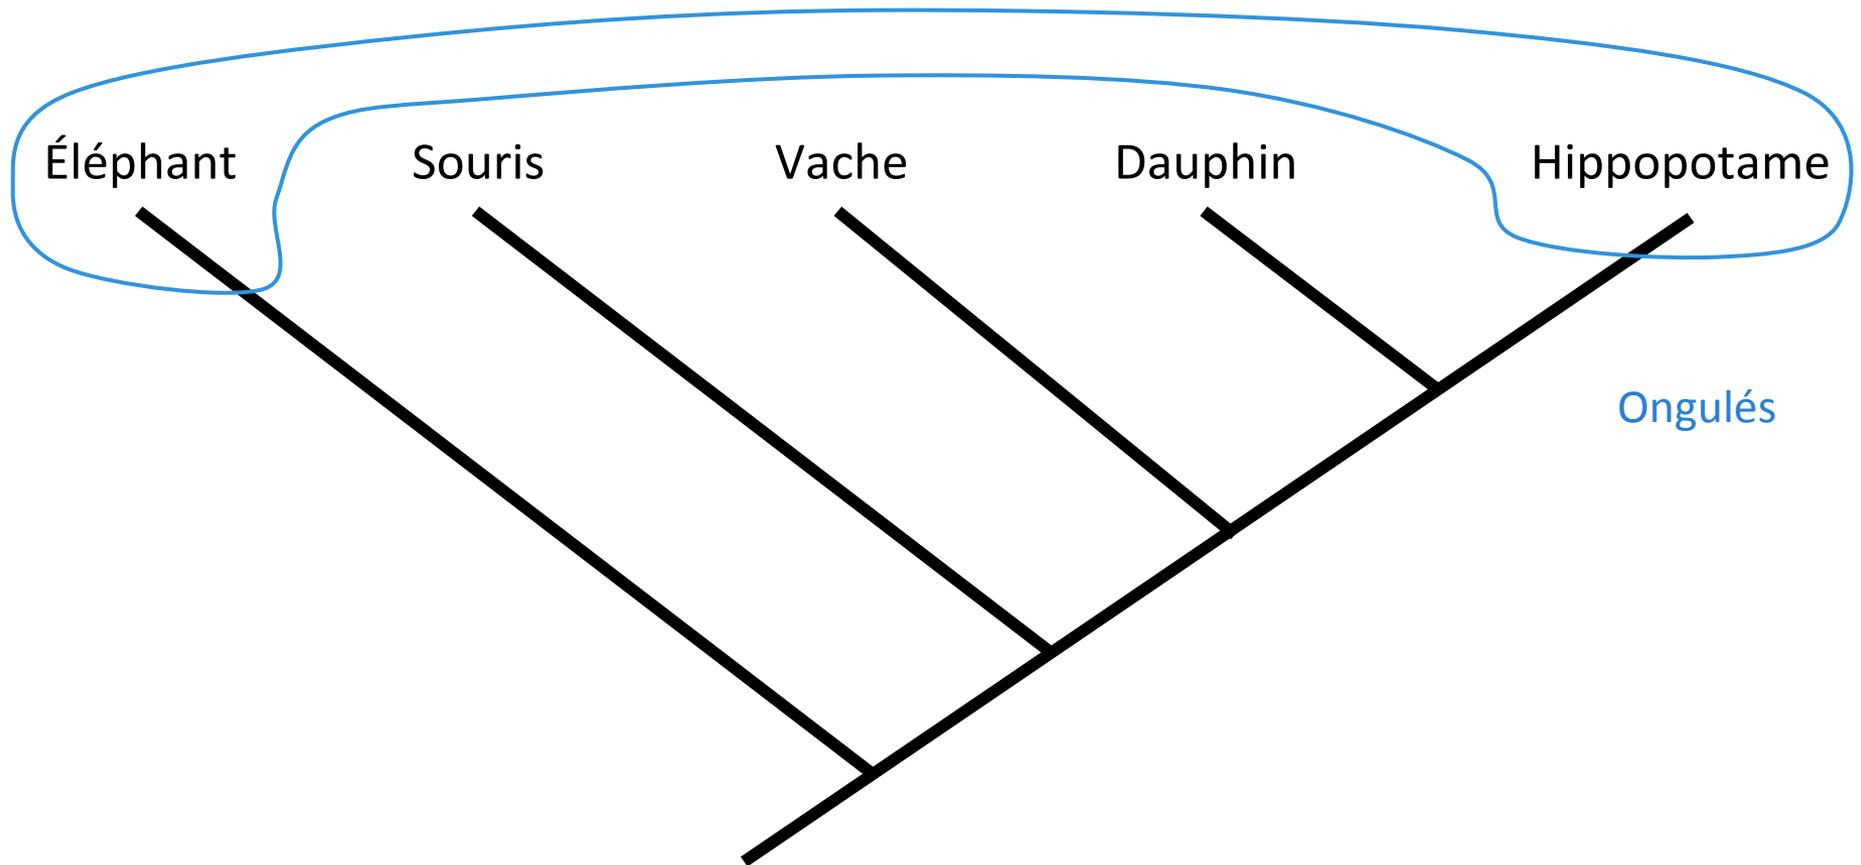
Chimpanzé

HOMINIDÉS  
Grands singes

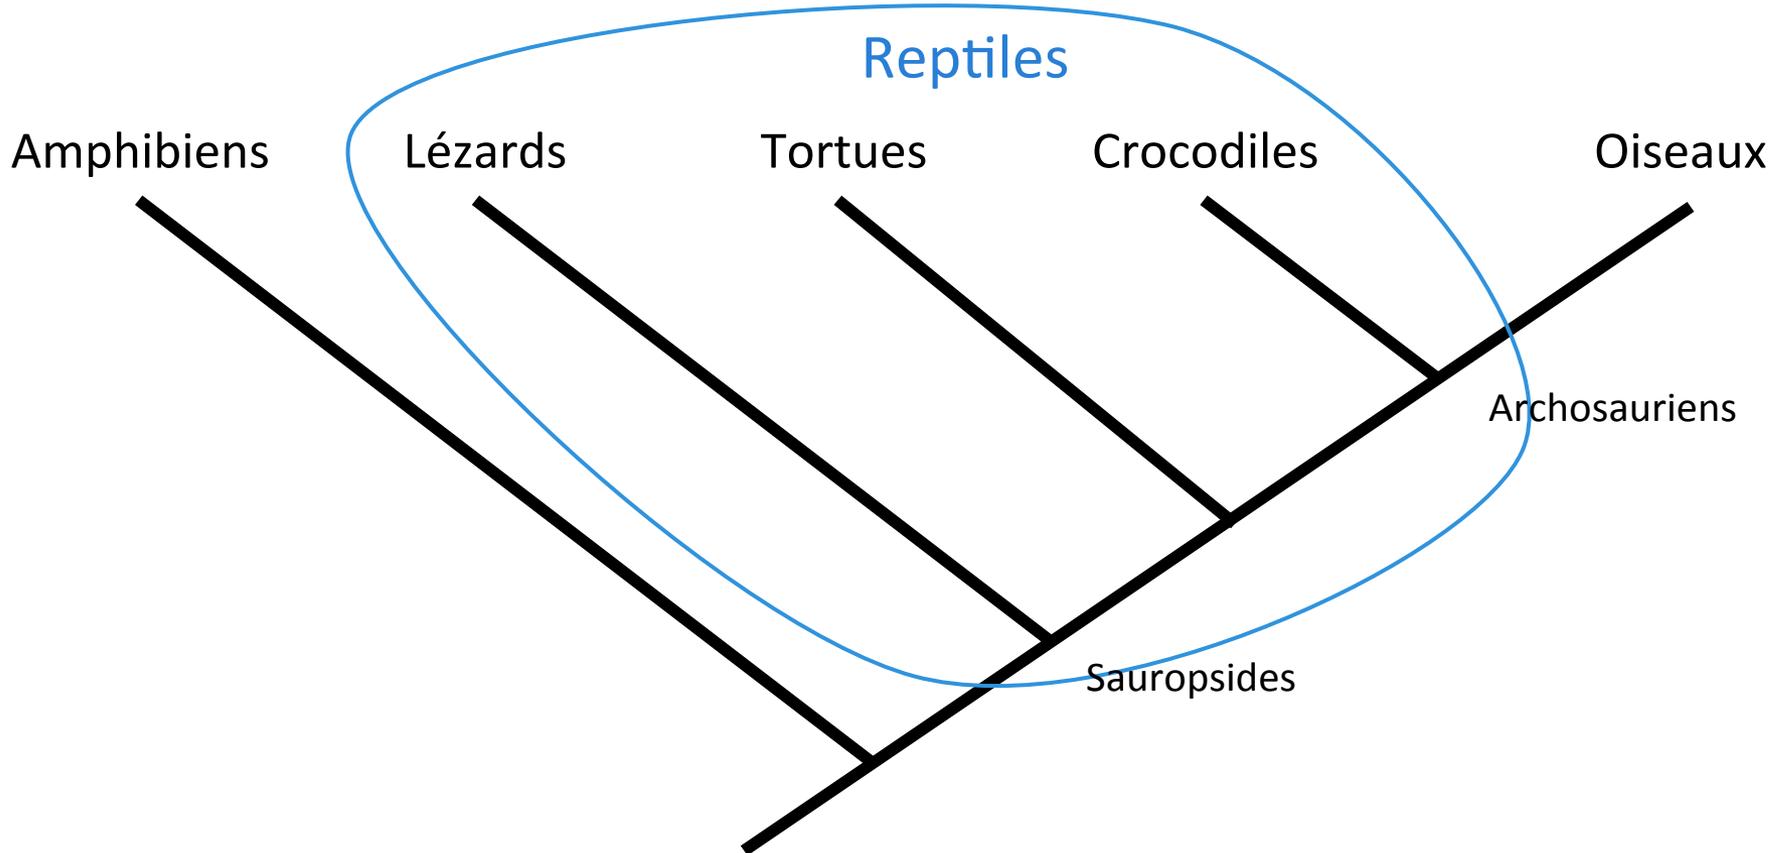
HOMININÉS



Un groupe **polyphylétique** ne contient pas l'ancêtre commun

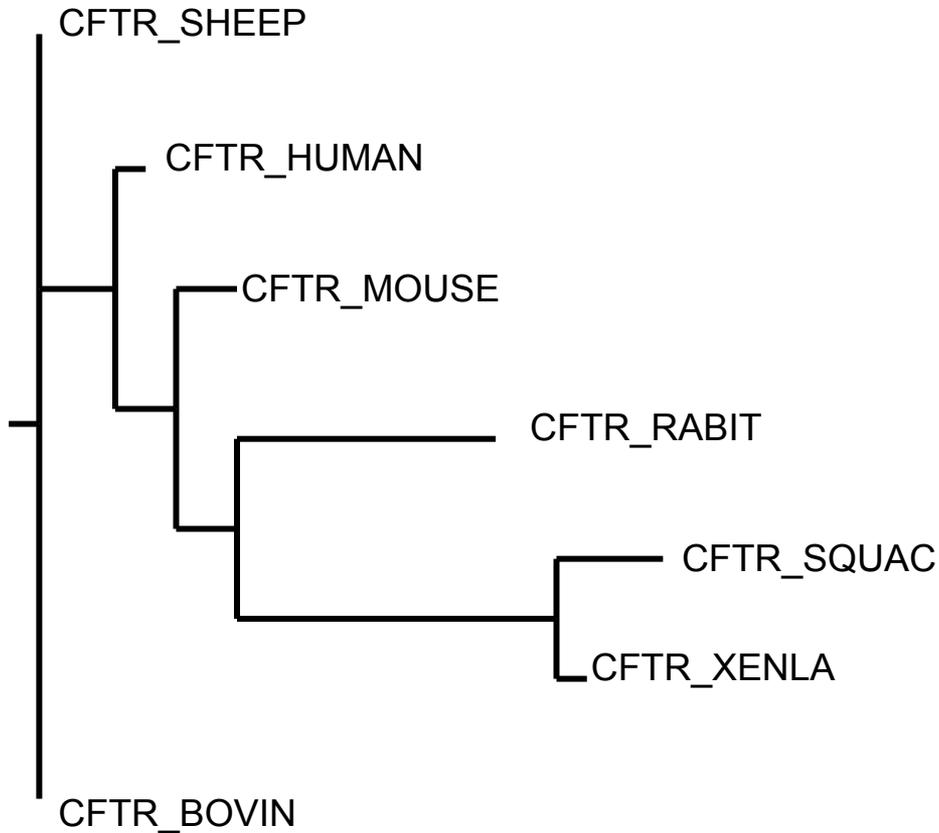


Un groupe **paraphylétique** contient l' ancêtre commun et seulement certains de ses descendants



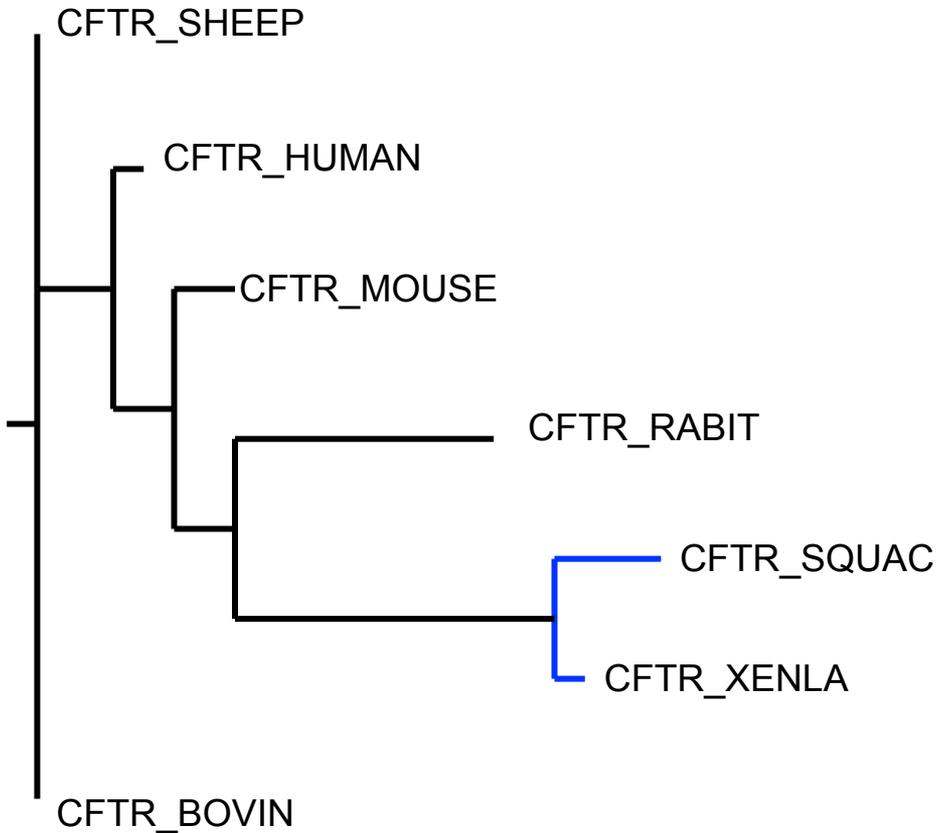
## Newick Tree Format

(CFTR\_SHEEP:0.01457,(CFTR\_HUMAN:0.16153,(CFTR\_MOUSE:0.70599,(CFTR\_RABIT:2.76042,(CFTR\_SQUAC:1.27192,CFTR\_XENLA:0.28818):3.42183):0.77076):0.65873)0.73937,CFTR\_BOVIN:0.00953);



## Newick Tree Format

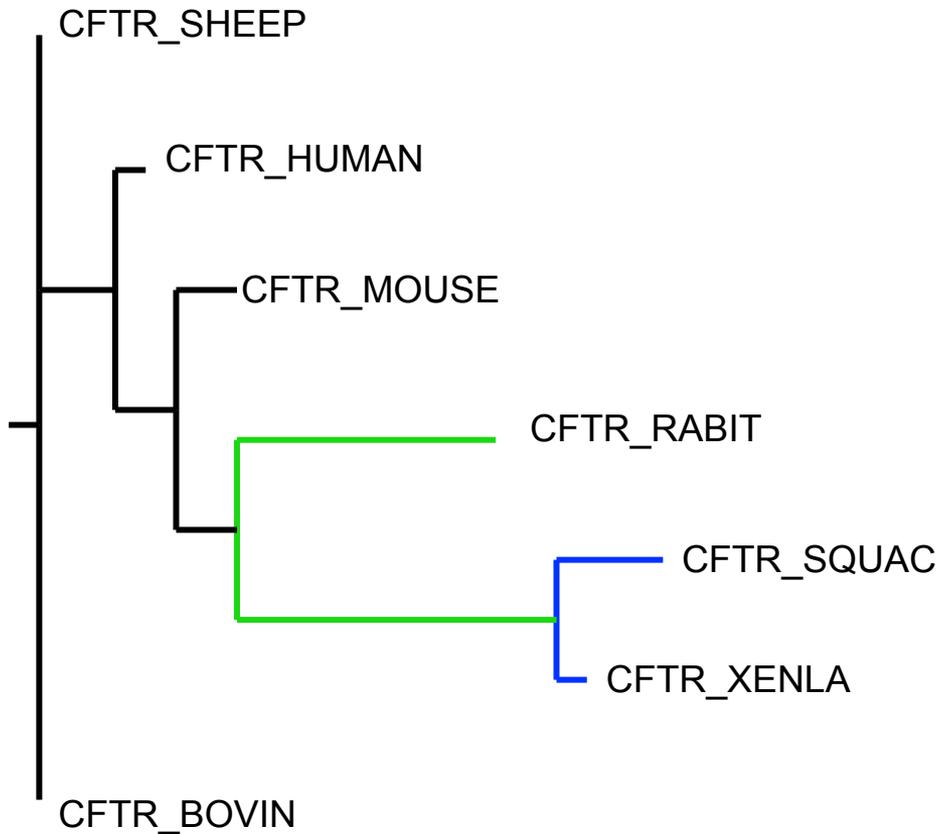
(CFTR\_SHEEP:0.01457,(CFTR\_HUMAN:0.16153,(CFTR\_MOUSE:0.70599,(CFTR\_RABIT:2.76042,(CFTR\_SQUAC:1.27192,CFTR\_XENLA:0.28818):3.42183):0.77076):0.65873)0.73937,CFTR\_BOVIN:0.00953);



(CFTR\_SQUAC:1.27192,  
CFTR\_XENLA:0.28818)

## Newick Tree Format

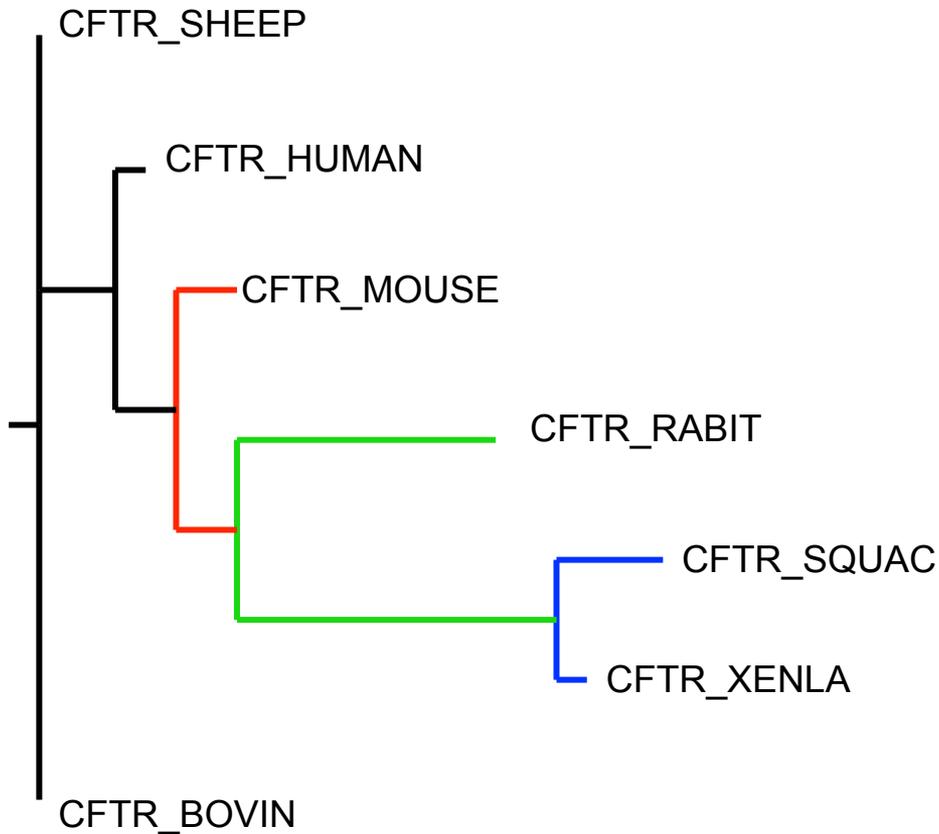
(CFTR\_SHEEP:0.01457,(CFTR\_HUMAN:0.16153,(CFTR\_MOUSE:0.70599,(CFTR\_RABIT:2.76042,(CFTR\_SQUAC:1.27192,CFTR\_XENLA:0.28818):3.42183):0.77076):0.65873)0.73937,CFTR\_BOVIN:0.00953);



(CFTR\_RABIT:2.76042,  
(CFTR\_SQUAC:1.27192,  
CFTR\_XENLA:0.28818)  
:3.42183)

## Newick Tree Format

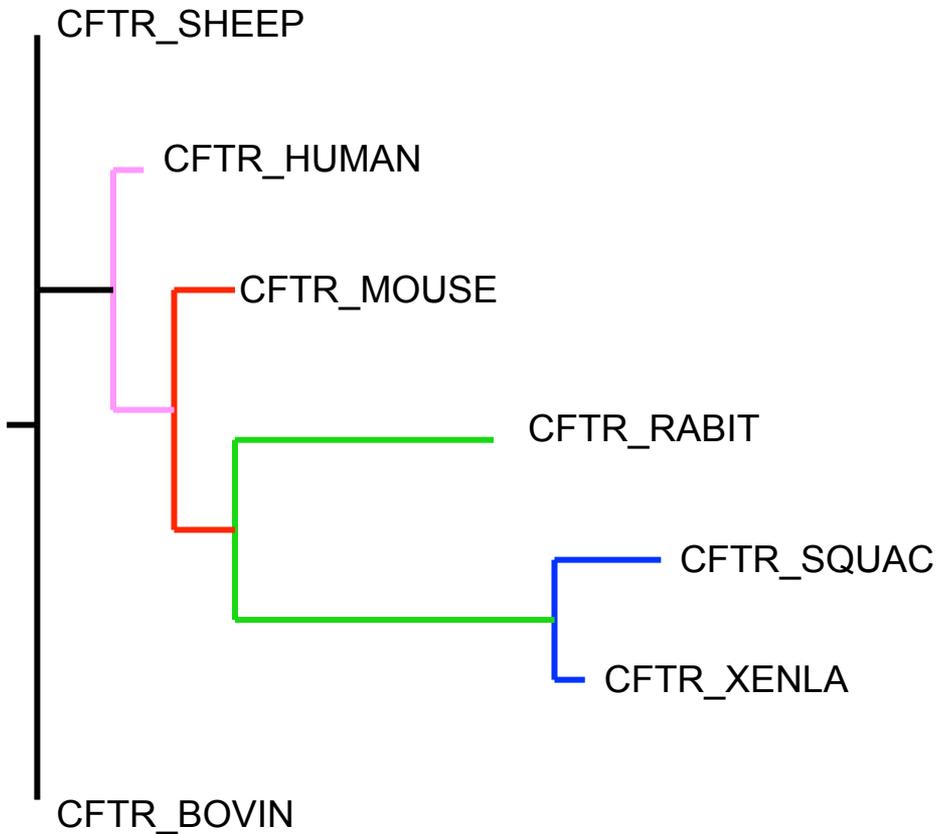
(CFTR\_SHEEP:0.01457,(CFTR\_HUMAN:0.16153,(CFTR\_MOUSE:0.70599,(CFTR\_RABIT:2.76042,(CFTR\_SQUAC:1.27192,CFTR\_XENLA:0.28818):3.42183):0.77076):0.65873)0.73937,CFTR\_BOVIN:0.00953);



(CFTR\_MOUSE:0.70599,  
(CFTR\_RABIT:2.76042,  
(CFTR\_SQUAC:1.27192,  
CFTR\_XENLA:0.28818)  
:3.42183)  
:0.77076)

## Newick Tree Format

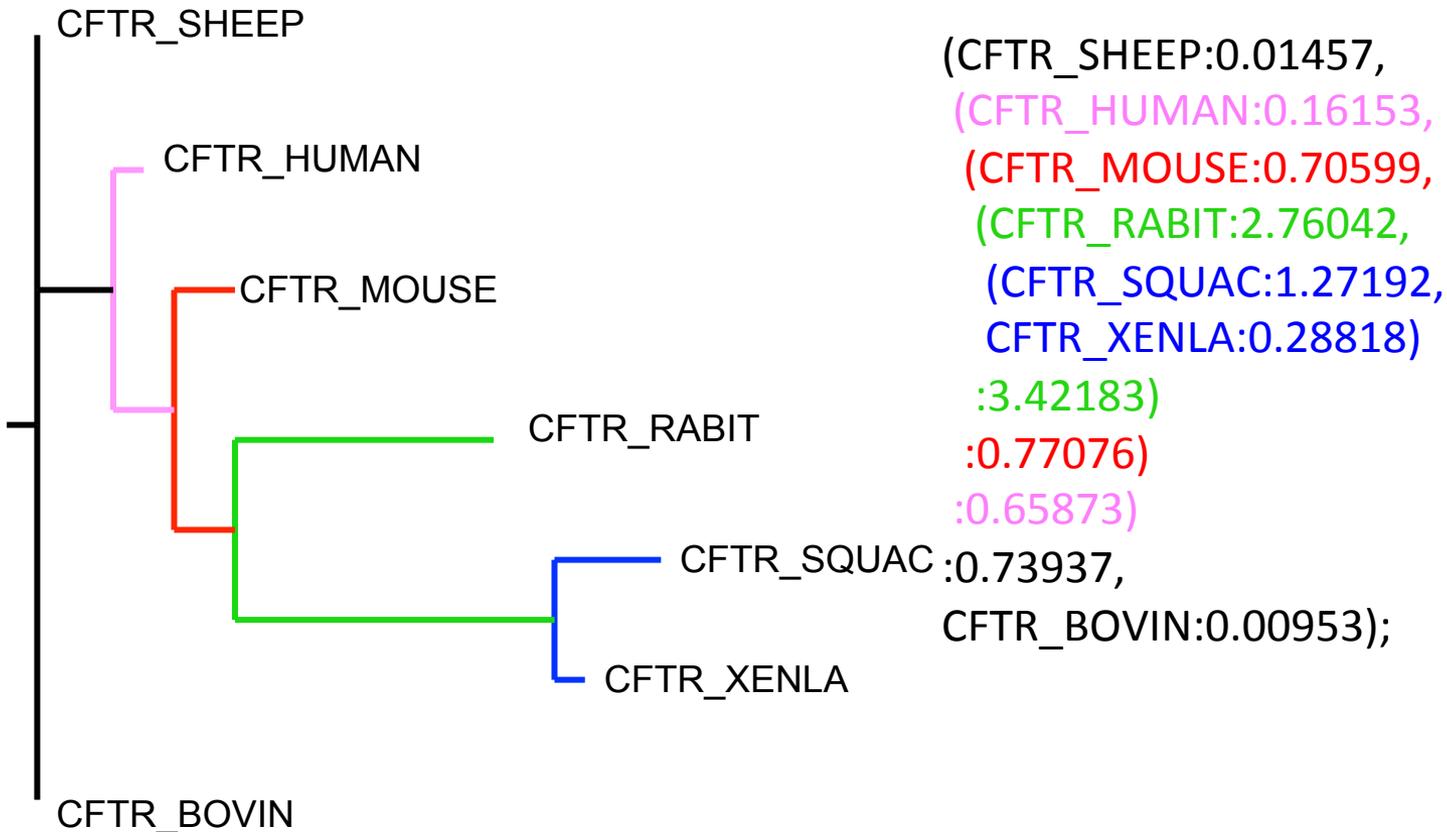
```
(CFTR_SHEEP:0.01457,(CFTR_HUMAN:0.16153,(CFTR_MOUSE:0.70599,(CFTR_RABIT:2.76042,(CFTR_SQUAC:1.27192,CFTR_XENLA:0.28818):3.42183):0.77076):0.65873)0.73937,CFTR_BOVIN:0.00953);
```



```
(CFTR_HUMAN:0.16153,
(CFTR_MOUSE:0.70599,
(CFTR_RABIT:2.76042,
(CFTR_SQUAC:1.27192,
CFTR_XENLA:0.28818)
:3.42183)
:0.77076)
:0.65873)
```

## Newick Tree Format

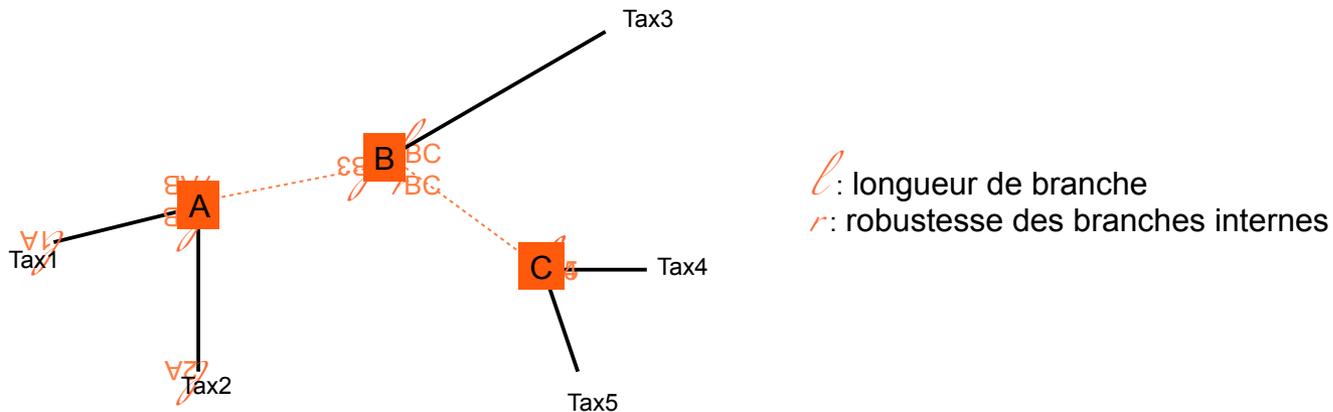
```
(CFTR_SHEEP:0.01457,(CFTR_HUMAN:0.16153,(CFTR_MOUSE:0.70599,(CFTR_RABIT:2.76042,(CFTR_SQUAC:1.27192,CFTR_XENLA:0.28818):3.42183):0.77076):0.65873)0.73937,CFTR_BOVIN:0.00953);
```



- Format standard d'écriture des arbres :

- . Les feuilles issues d'un même nœud sont groupées entre parenthèses
- . Les feuilles et groupes de feuilles sont séparés par des virgules
- . On termine toujours l'arbre par un point virgule

Ex : ((Tax1:  $l_A$ , Tax2:  $l_A$ )  $r_{AB}$ :  $l_{AB}$ , Tax3:  $l_B$ , (Tax4:  $l_C$ , Tax5:  $l_C$ )  $r_{BC}$ :  $l_{BC}$ ) ;

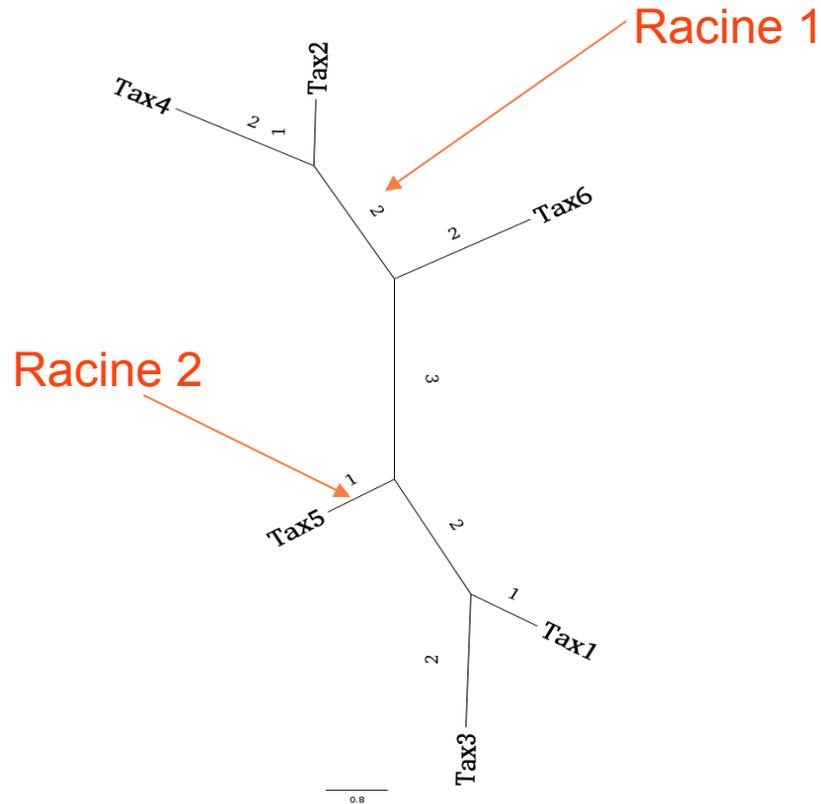


- Dessiner l'arbre suivant :

.((Tax1:1, Tax3:2):2, Tax5:1, ((Tax4:2, Tax2:1):2, Tax6:2):3);

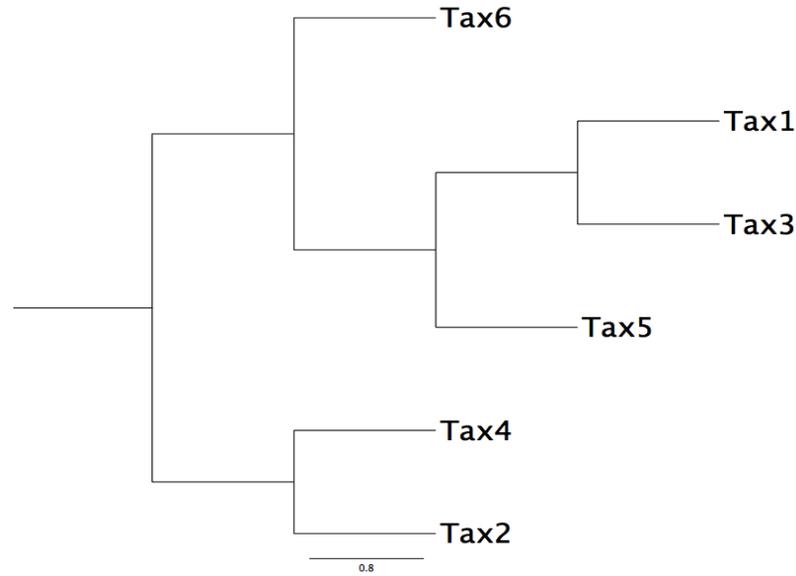
- Dessiner l'arbre suivant :

$((\text{Tax1:1}, \text{Tax3:2}):2, \text{Tax5:1}, ((\text{Tax4:2}, \text{Tax2:1}):2, \text{Tax6:2}):3);$

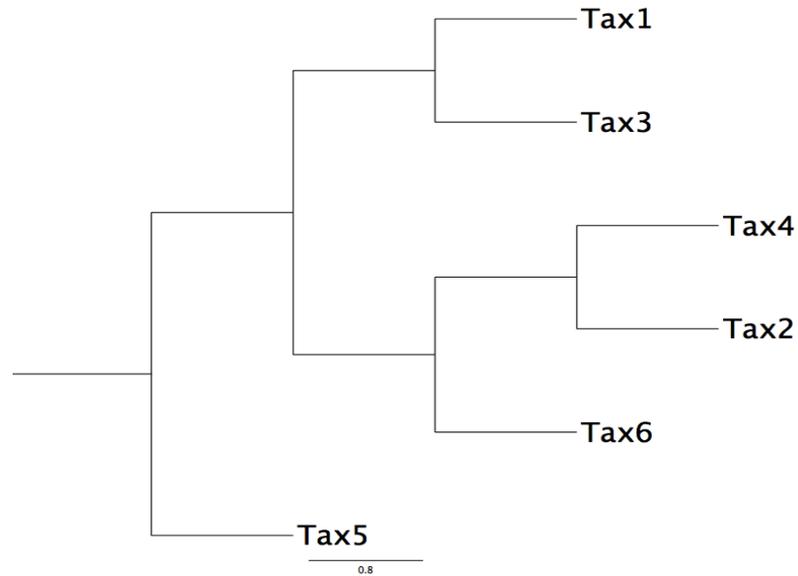


Dessiner les arbres racinés correspondants pour la Racine 1 puis pour la Racine 2

•Racine1



•Racine2



## Le format NHX (New Hampshire eXtended)

<http://www.phylosoft.org/NHX>

NHX introduit des balises pour associer divers champs de données à un noeud d'un arbre phylogénétique

- noeuds internes et externes peuvent être étiquetés
- l'ordre des balises n'est pas important
- la longueur de toutes les données basées sur des chaînes de caractères est illimitée (par exemple nom, espèces)

```
(((ADH2:0.1[&&NHX:S=human:E=1.1.1.1], ADH1:0.11[&&NHX:S=human:E=1.1.1.1]):
0.05[&&NHX:S=Primates:E=1.1.1.1:D=Y: B=100], ADHY:
0.1[&&NHX:S=nematode:E=1.1.1.1],ADHX:0.12[&&NHX:S=insect:E=1.1.1.1] ):
0.1[&&NHX:S=Metazoa:E=1.1.1.1:D=N],
(ADH4:0.09[&&NHX:S=yeast:E=1.1.1.1],ADH3:0.13[&&NHX:S=yeast:E=1.1.1.1],
ADH2:0.12[&&NHX:S=yeast:E=1.1.1.1],ADH1:0.11[&&NHX:S=yeast:E=1.1.1.1]):0.1
[&&NHX:S=Fungi])[&&NHX:E=1.1.1.1:D=N];
```

## Le format Nexus

Suffix .nxs .nex

Paup, MrBayes, Mesquite, MacClade

```
#NEXUS
BEGIN TAXA;
    Dimensions NTax=4;
    TaxLabels fish frog snake
mouse;
END;

BEGIN CHARACTERS;
    Dimensions NChar=20;
    Format DataType=DNA;
    Matrix
fish   ACATA GAGGG TACCT CTAAG
frog   ACATA GAGGG TACCT CTAAG
snake  ACATA GAGGG TACCT CTAAG
mouse  ACATA GAGGG TACCT CTAAG
END;

BEGIN TREES;
    Tree best=(fish, (frog,
(snake, mouse)));
END;;
```

## Le format PhyloXML

Han, Mira V.; Zmasek, Christian M. (2009).

phyloXML: XML for evolutionary biology and comparative genomics" BMC Bioinformatics (United Kingdom: BioMed Central) 10: 356

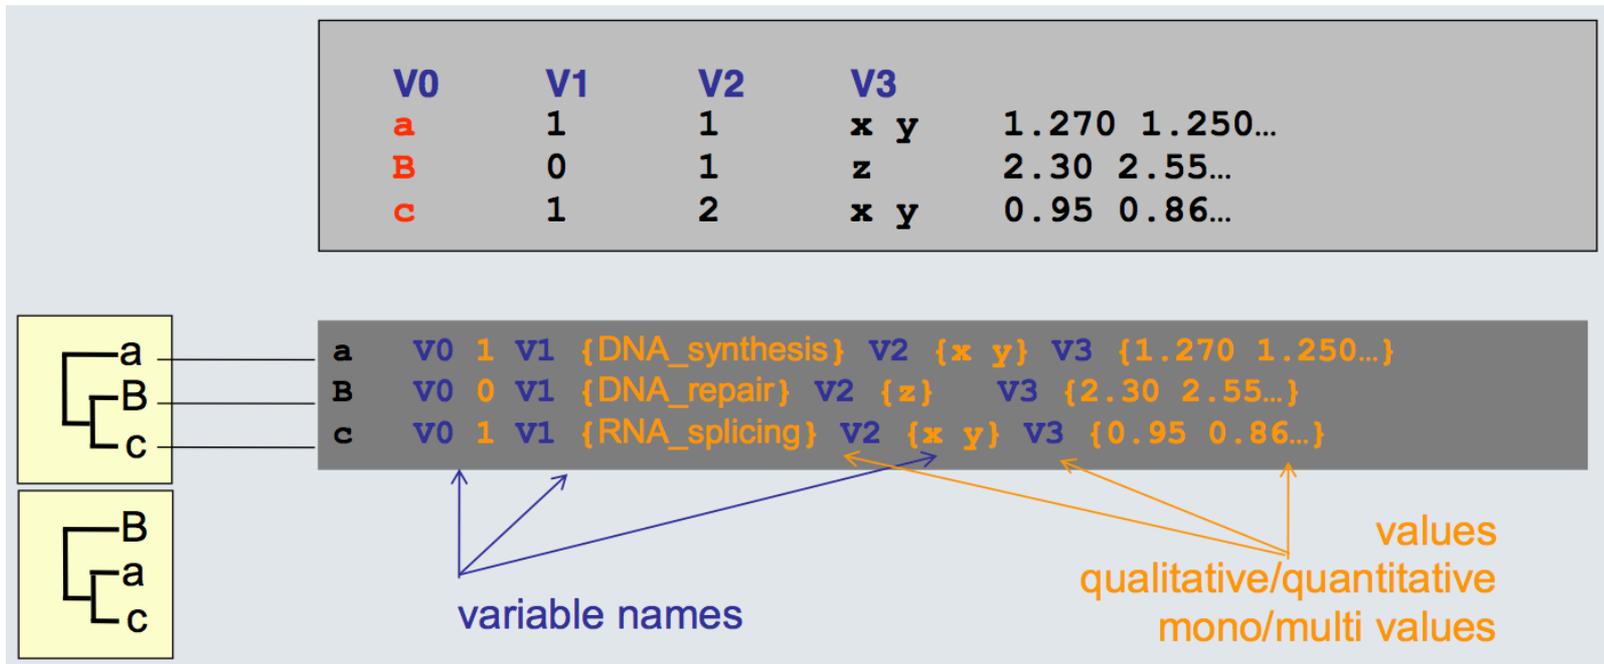
PhyloXML est un langage XML pour l'analyse, l'échange et le stockage des arbres phylogénétiques (ou des réseaux) et les données associées. La structure de phyloXML est décrit par XML Schema Definition (XSD) langue.

```
<phyloxml xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance" xsi:schemaLocation="http://www.phyloxml.org http://www.phyloxml.org/1.10/phyloxml.xsd" xmlns="http://www.phyloxml.org">
<phylogeny rooted="true">
<name>example from Prof. Joe Felsenstein's book "Inferring Phylogenies"</name> <description>MrBayes based on MAFFT alignment</description>
<clade>
  <clade branch_length="0.06">
    <confidence type="probability">0.88</confidence>
    <clade branch_length="0.102">
      <name>A</name>
    </clade>
  <clade branch_length="0.23"> <name>B</name>
</clade>
</clade>
  <clade branch_length="0.4">
    <name>C</name>
  </clade>
</clade>
</phylogeny>
</phyloxml>
```

## Le format TreeDyn

Fichiers d'annotation externes avec le nom des feuilles (unique) pour faire la liaison avec des couples de variables/valeurs.

Cette organisation présente l'avantage d'être indépendante mais totalement compatible avec le standard "Newick".



# LES MÉTHODES DE CONSTRUCTION D' ARBRES

Il existe 3 approches :

L'approche cladistique cherche en particulier à déterminer les caractères propres à une branche, qui « signent » un apparentement.

L'approche phénétique, une classification basée uniquement sur des mesures de distance entre taxons (évaluées par exemple en comptant les différences de séquences d'ADN) sans chercher à faire une interprétation phylogénétique.

L'approche probabiliste qui construit des arbres phylogénétiques en utilisant des modèles d'évolution des caractères (le plus souvent moléculaires, mais pas obligatoirement).

CGATATAAAAGAAAACCA
AGAAAAGAAAAGAAAACAA
CGATATAAAAGAACACCACA
AGAAAAGAAAAGAAAACAAA
CGATATAAGAGAACACCACA
AGAAAAGAAAAGAAAACAACA
CGATATAAGAGAACACCATA

		Types de données	
		Distances	Sites
Méthodes de construction	Cluster	UPGMA Neighbour Joining	
	Recherche de Critères optimaux	Evolution Minimum Moindres carrés	Parcimonie Maximum Bayésien Maximum vraisemblance

## Phénétique vs Cladistique

L'approche phénétique (taxonomie numérique) se veut complètement objective. C'est une approche très quantitative dans laquelle tous les traits (qu'ils soient homologues ou non) sont traités également.

Cette méthode se révèle peu pertinente lorsqu'on l'applique aux **caractères morphologiques** en raison des **analogies : convergence évolutives**.

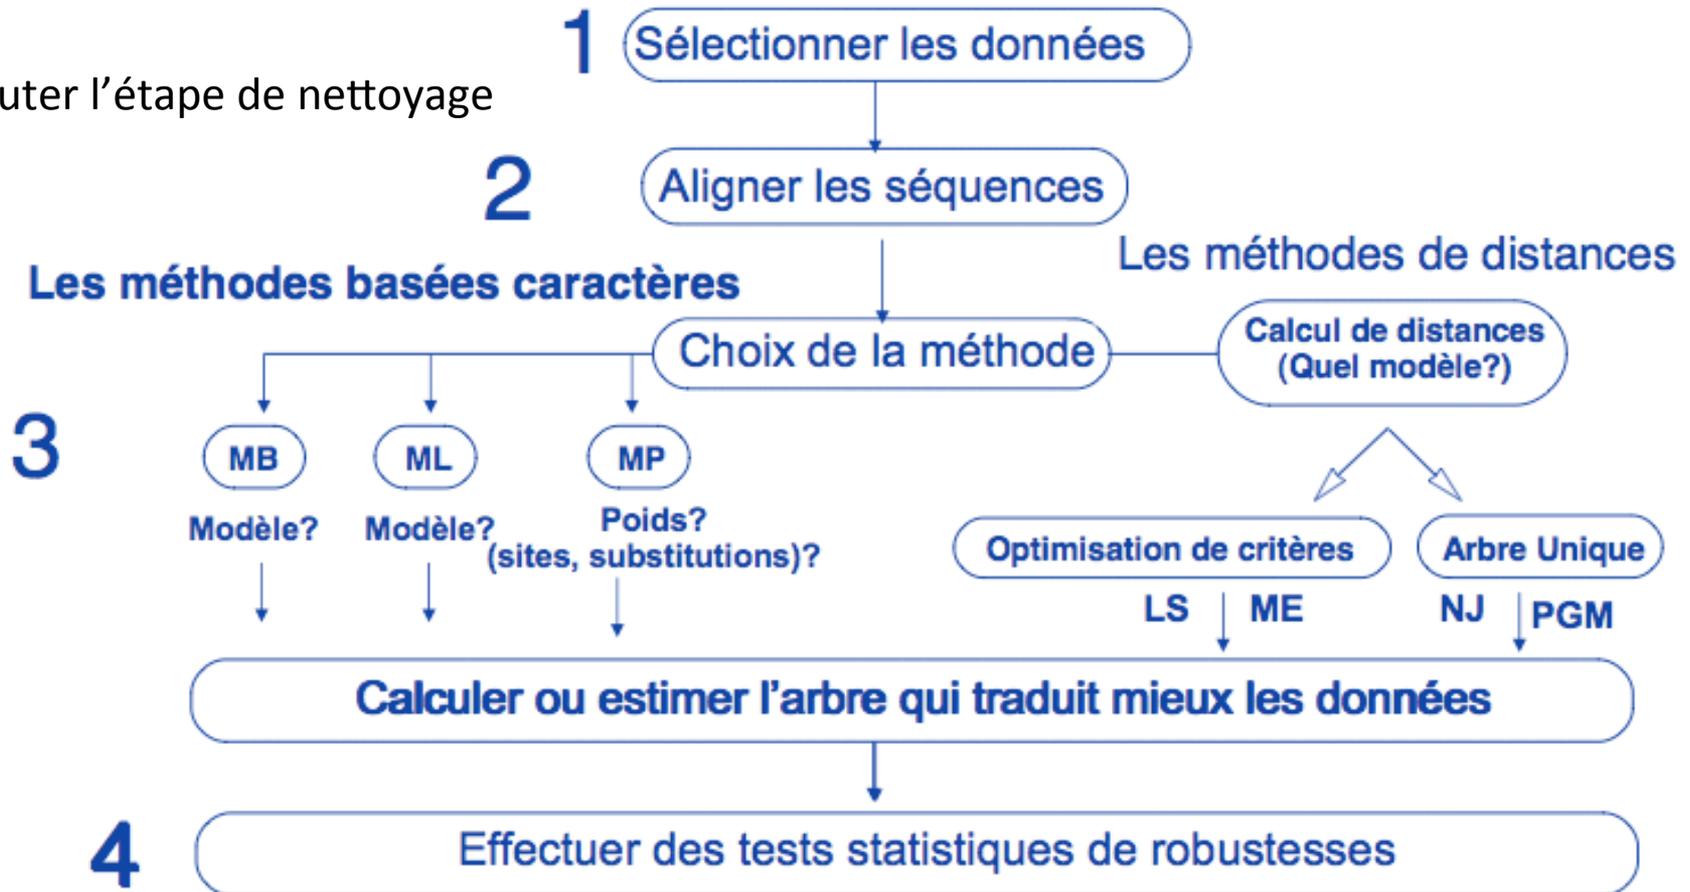
Elle s'applique préférentiellement sur des caractères moléculaires où le nombre de caractères pris en compte est important

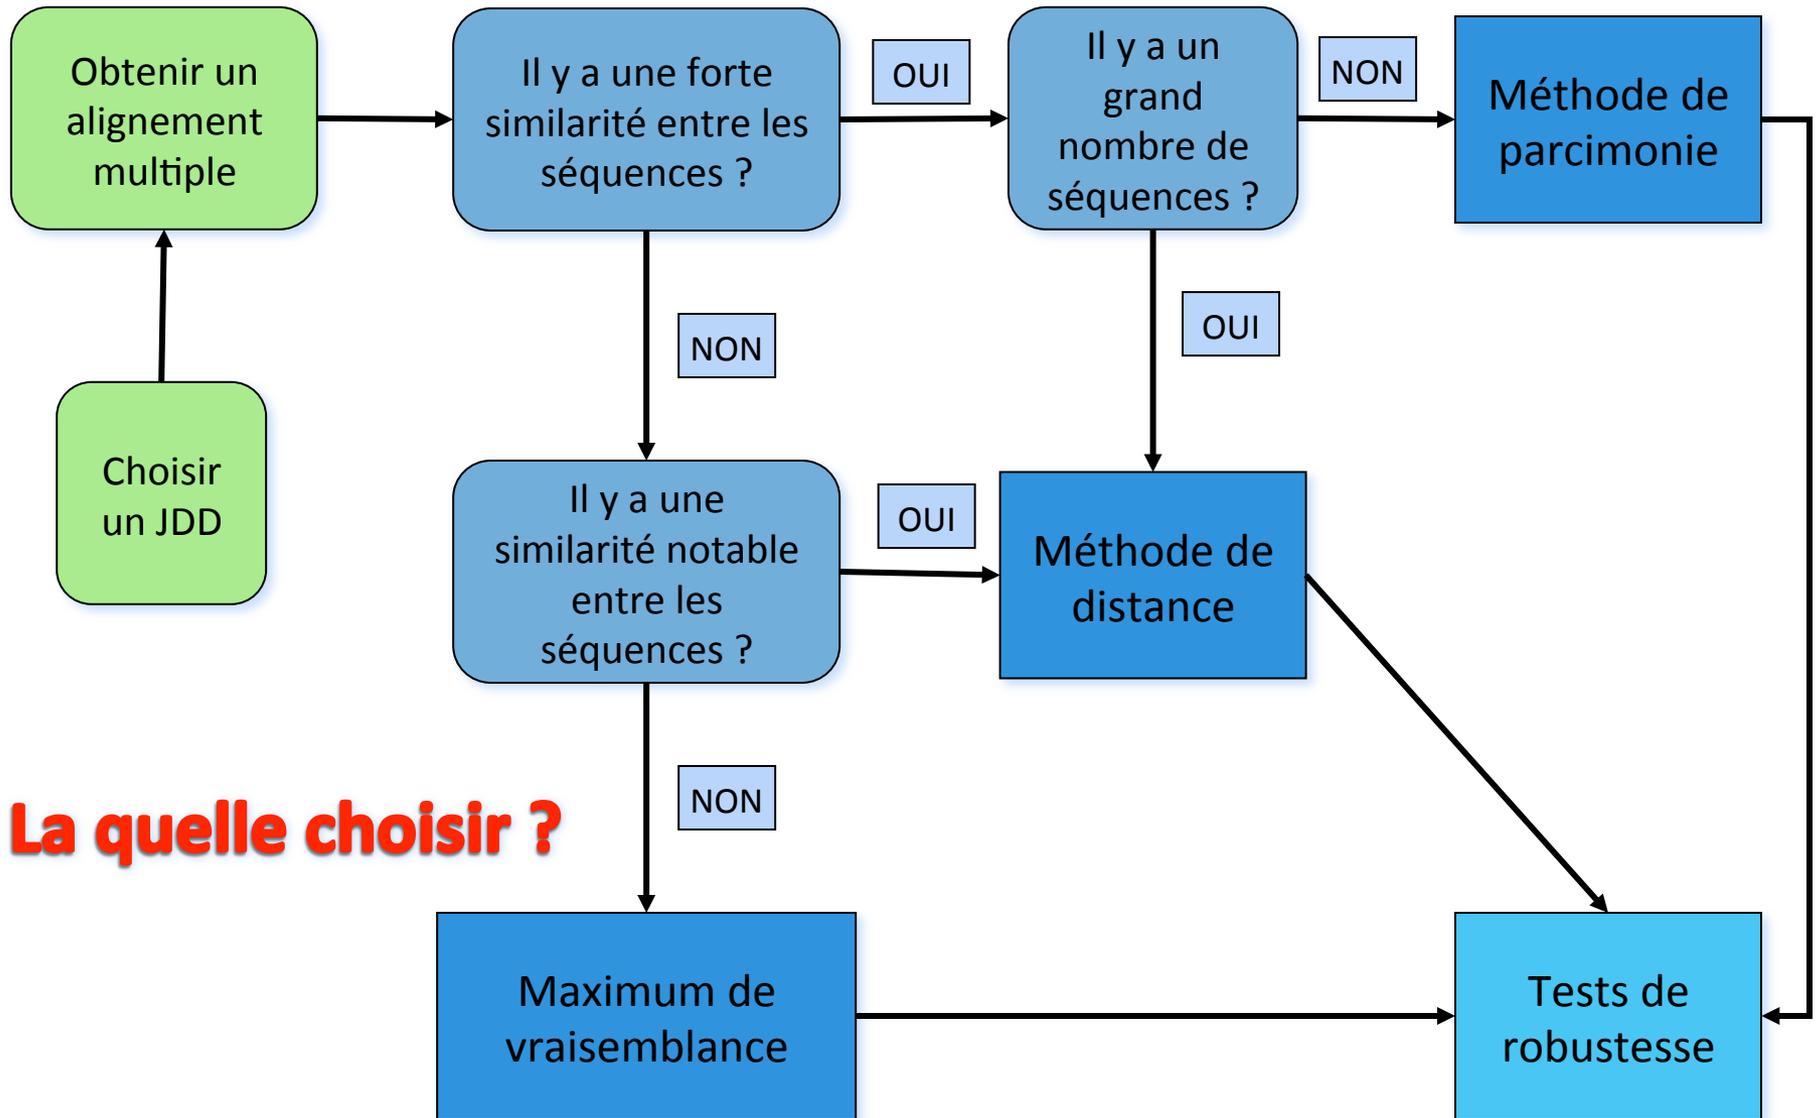
La cladistique hiérarchise les caractères comparés. Ne sont en fait regroupés dans un même taxon que les êtres vivants qui partagent des caractères **homologues** : partage d'une ascendance commune.

Les homologies sont en fait vues comme des innovations évolutives partagées : **synapomorphies**

## Méthodologie

Ajouter l'étape de nettoyage





**La quelle choisir ?**

bayésien