

# ALIGNEMENT PLUS RAPIDE

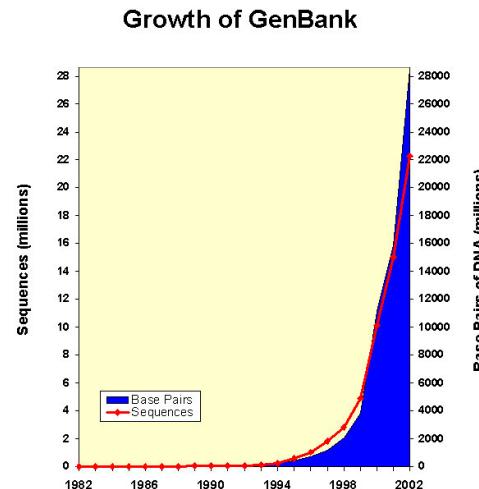
1. méthodes heuristiques : **hachage**, arbres de suffixe, **PD limitée** (taille totale de trous bornée)
2. **PD éparsé** (pour sous-séquence commune ou *chaînage* en alignement global heuristique)

# BANQUES DE SÉQUENCES

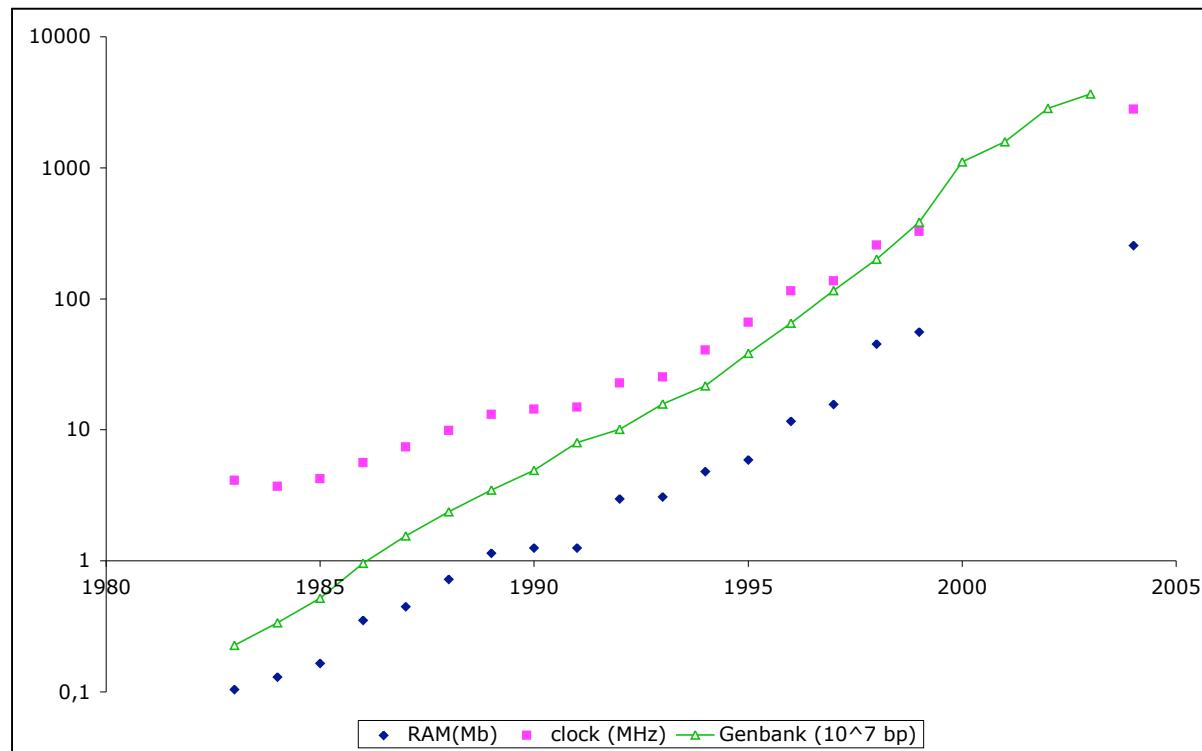
Bases de données de séquences : beaucoup d'information.

Exemple : **GenBank**

- 38 milliards de nucléotides ; 32.5 millions de séquences
- croissance exponentielle (taille doublée tous les 14 mois)



# NEED FOR SPEED



# BANQUES DE DONNÉES

NCBI : «National Center for Biotechnology Information» — États-Unis

Interface [[Entrez](#)] à plusieurs bases de données :

- séquences d'acides nucléiques
- séquences protéiques
- PubMed : publications
- structures
- taxonomie
- ...

# GENBANK

Séquences d'ADN : GenBank (É-U), DDBJ (Japon), EMBL (Europe)

GenBank «flatfile» : exemple (**HUMXIHB**) :

```
LOCUS      HUMXIHB          458 bp   mRNA    linear    PRI 14-JAN-1995
DEFINITION Human zeta hemoglobin mRNA, complete cds.
ACCESSION  M24173
VERSION    M24173.1 GI:340391
KEYWORDS   zeta-globulin.
SOURCE     Homo sapiens (human)
ORGANISM   Homo sapiens
                      Eukaryota; Metazoa; Chordata; Craniata; Vertebrata; Euteleostomi;
                      Mammalia; Eutheria; Primates; Catarrhini; Hominidae; Homo.
REFERENCE  1 (bases 1 to 458)
AUTHORS    Cohen-Solal,M.M., Authier,B., deRiel,J.K., Murnane,M.J. and
           Forget,B.G.
TITLE      Cloning and nucleotide sequence analysis of human embryonic
           zeta-globin cDNA
JOURNAL   DNA 1 (4), 355-363 (1982)
MEDLINE   83182021
PUBMED   6963223
COMMENT   Original source text: Human erythroleukemia cell line K562, cDNA to
           mRNA, clones 1 (1g7-8), 2 (4p7-7), and 3 (5a3-3).
```

# GENBANK - CHAMPS 1

## LOCUS

- 1–10 caractères alphanumériques ; jadis l'identificateur de la séquence (p.e. l'abréviation du gène), préservée pour compatibilité seulement.
- **longueur** et **type** de la séquence (DNA, mRNA, tRNA, rRNA)
- code de la **division** (p.e. PRI) et **date** de dernière modification.

DEFINITION «sommaire» de la séquence : espèce et le nom de la séq

ACCESSION nombre d'accession : clé dans la base de donnée. Identificateur unique parmi les BDs. Forme AA999999. L'**accno** est généré automatiquement lors de la soumission d'une séquence à la BD.

## GENBANK - CHAMPS 2

KEYWORDS et SOURCE : moins d'importance (pour nous)

VERSION donne <accno>.<version> et **gi** : identificateur de GenInfo. Ce sont des identificateurs des séquences (qui peut changer pour le même accno).

REFERENCE

## GENBANK — EXEMPLE CONT.

```
FEATURES          Location/Qualifiers
source            1..458
                  /organism="Homo sapiens"
                  /db_xref="taxon:9606"
                  /map="16p13.3"
gene              1..458
                  /gene="HBZ"
CDS               30..458
                  /gene="HBZ"
                  /note="zeta hemoglobin"
                  /codon_start=1
                  /protein_id="AAA61306.1"
                  /db_xref="GI:340392"
                  /db_xref="GDB:G00-119-302"
                  /translation="MSLTKTERTIIIVSMWAKISTQADTIGTETLERLFLSHPQTQTYF
PHFDLHPGSAQLRAHGSKVVAAVGDAVKSIDDIGGALKSELHAYILRVDPVNFKLL
SHCLLVTLAARFPADFTAEEAHAAWDKFLSVVSSVLTEKYR"
BASE COUNT        80 a    173 c    127 g    78 t
ORIGIN           79 bp upstream of BglII site.
                  1 actccagtgc agctgcccac cctgccgcca tgtctctgac caagactgag aggaccatca
                  .....
                  421 cggtcgtatc ctctgtcctg accgagaagt accgctga
//
```

## GENBANK - CHAMPS 3

FEATURES annotation de la séquence : un «feature» comprend un **mot-clé**, sa **position**, et des **qualifieurs**

position : sous-mot [p.e., 2 .. 280], entre deux bases [p.e., 91 ^ 92], ...  
et opérations : complement(·), join(·, ..., ·)

mots-clé :

- source information taxonomique
- CDS partie traduite en une séquence protéique
- exon, intron, gene
- repeat\_region
- ...

Exemple : **U96726**

# GENBANK - ENTRÉES VIRTUELLES

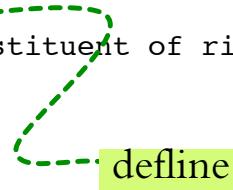
Exemple : U00089

```
LOCUS          U00089                      816394 bp      DNA      circular CON 06-DEC-2002
DEFINITION    Mycoplasma pneumoniae M129, complete genome.
...
CONTIG         join(AE000016.2:1..19313,AE000015.2:59..17535,AE000014.2:22..12521,
                  AE000013.2:53..10328,AE000012.2:59..10228,AE000011.2:59..15387,
                  ... [plusieurs lignes]
                  AE000019.2:59..10270,AE000018.2:59..11147,AE000017.2:62..15963)
//
```

# FASTA

Un autre format très répandu, utilisé originellement par les logiciels du package FASTA.

```
>CRA|agCP11170 /len=264 /protein_uid=197000044174854 /org=Anopheles_gambiae
ATSFTMPQNEYIERHIKYGRRLDYEERKRKREAREPKKRAAMARKLRGMKAKLFQKQRR
NEKIQMKRKIQAQEEKKVKKTTEKVEDGALPPYLMDRGIQSNAKVLNSNMIKQKRKEKAGK
WDVPIPKVRAQADAEVFKVIRSGKTKRKAWKRMVTKVTVGENFTRKPPKYERFIRPMAL
RMNKAHVTHPELKATFHLPPIIGVKNPSSPMYTSLGVITKGTVIEVNISELGLVTQSGKV
VWGKYAQVTNNPENDGCINAVLLV
>gi|30697195|ref|NP_200732.2|gnl|TIGR|At5g59240| Structural constituent of ribosome [A. thaliana]
MGISRDSIHKKRATGGKQKMWRKKRKYELGRQPANTKLSSNKTVRRIRVGGNVKWRALR
LDTGNFSWGSEAVTRKTRILDVAYNASNNELVRTQTLVSAIVQVDAAPFKQGYLQHYGV
DIGRKKKGEAVTTEEVKNSNHVQRKLEMRLQEGRALDSHLEEQFSSGRLLACIASRPGQCG
RADGYILEGKELEFYMKKLQKKKGKNAGAA
...
...
```



defline

une ou plusieurs séquences (ADN ou protéine)  
en-tête pour chaque séquence (ligne > . . . )  
syntaxe souvent utilisé : /propriété=valeur  
*defline* : références à des banques de séquences  
fomat général : <db> | <ident>

# NCBI

GenBank «flatfile» généré automatiquement à partir des bases de données.

Entrez : interface intégré : recherche par identificateurs, mots clés, auteurs, etc.

BLAST : famille d'outils pour trouver des occurrences inexactes d'une séquence  $S$  dans le «texte»  $T$

choix de  $T$  : nr, est, month, etc.