

# Bioinformatique: Annotation des génomes (eucaryotes)

M2 MIV - Octobre 2006

Laurent Duret

BBE – UMR CNRS n° 5558

Université Claude Bernard - Lyon 1

# Activités de recherche

- Equipe “Bioinformatique et Génomique Evolutive”
  - Labo. de Biométrie et Biologie Evolutive (CNRS, Univ. Lyon 1)
  - Pôle Bioinformatique Lyonnais (avec l’équipe de G. Deléage, IBCP):  
<http://pbil.univ-lyon1.fr>
  - Groupe HELIX (INRIA)
- Développement d’outils informatiques pour l’analyse des génomes (bases de données, algorithmes)
- Etude de l’organisation et de l’évolution des génomes
  - Évolution moléculaire
  - Analyse comparative de séquences
  - Phylogénie

# Projets génomes

- Identifier les gènes et autres éléments fonctionnels dans les séquences génomiques (où sont les gènes ?)  
=> prédiction de gènes
- Déterminer la fonction des gènes (qu'est qu'ils font ?)  
=> recherche de similarités entre séquences


# Plan du cours

- Structure des génomes eucaryotes
- Projets génomes (eucaryotes)
- Identification de gènes (eucaryotes)
- Prédire la fonction des gènes

# Qu'est-ce qu'un génome ?

- Définition historique (1920) = ensemble des gènes d'un organisme
- Définition actuelle = ensemble des molécules d'acides nucléiques transmises de génération en génération
  - Génome nucléaire
  - Génome mitochondrial
  - Génome chloroplastique
  - ....

# Genome size and the c-value paradox




# A genome is more than a set of genes

- Genes (transcription unit):
  - Protein-coding genes
  - RNA genes:
    - rRNAs, tRNAs, snRNAs, etc.
    - Untranslated RNA genes (e.g. Xist, H19)
- Regulatory elements (promoters, enhancers, etc.)
- Elements required for chromosome replication (replication origins, telomeres, centromeres, etc.)
- Non-functional sequences
  - Non-coding sequences
  - Repeated sequences
  - Pseudogenes


# How much of the genome is functional *vs* non-functional ?

- The big surprise of mammalian genome projects ...

# Number of protein genes (1999)



# Number of protein genes (2006)



Human vs *E. coli*:

Genome size:  $\times 600$

Number of genes:  $\times 5$


# How many genes in the human genome ?

---


Technique	Gene estimate	Comments/assumptions
Text book (1990)	100,000	if average size = 30 kb
Genomic sequencing (1994)	71,000	biased toward gene-rich region?
CpG islands	67,000	assumes 66% human genes have CpG islands
EST analysis (1994)	64,000	matching with GenBank; 50% EST redundancy
Chromosome 22 (1999)	45,000	correction for high gene density on chrom. 22
Exofish (2000)	28,000-34,000	Comparison human/fish
EST (2000)	35,000	Number of genes
EST (2000)	120,000	Number of transcripts
First genome draft (2001)	30,000-40,000	Known genes + predictions
Comparison / mouse (2002)	30,000	Known genes + predictions
Finished genome (2004)	20,000-25,000	Known genes + predictions

---


# Proportion of functional elements within genomes




*E. coli*




*Yeast*  
*S. cerevisiae*




**Nematode**  
*C. elegans*



**Drosophila**



**Human**




**Lungfish**  
(*dipnoi*)

Coding (protein)  
 RNA  
 Non-coding

# Eléments fonctionnels dans le génome humain

$3.1 \cdot 10^9$  nt

20 000 - 25 000 gènes protéiques




## Éléments fonctionnels non-quantifiés:

- ARN non-traduits: Xist, H19, etc.
- Éléments régulateurs: promoteurs, enhancers, etc.
- Origines de réplications, MAR, télomères


## Éléments non-fonctionnels:

- Pseudogènes : 1.2%
- Éléments transposables (SINES, LINES, HERV, etc.) : 42%

# Typical eukaryotic protein-coding gene




# Structure des gènes humains



- Tailles moyennes
  - Gene 45 kb
  - CDS 1500 nt
  - Exon (interne) 145 nt
  - Intron 5200 nt
  - 5'UTR 210 nt
  - 3'UTR 740 nt
- Intron/exon
  - Nombres d'introns:  $6 \pm 3$  introns / kb CDS
  - Introns / (introns + CDS): 92%
- Epissage alternatif dans plus de 30% des gènes

# One gene, several products


- Alternative splicing in more than 30% of human genes (Hanke et al. 1999)




- Alternative promoter
- Alternative polyadenylation sites

# Overlapping genes

Overlapping protein genes



Small nucleolar RNA genes within introns of protein genes



# Gènes non-traduits dans le génome humain

- tRNA (70-100 nt) :  $\approx 350$  gènes
- rRNA :
  - 18S (1800 nt), 5.8S (160 nt), 28S (5000 nt) : 150-200 gènes
  - 5S (120 nt): 200-300 gènes
- snRNA (small nuclear RNA) (70-200 nt): fonctions diverses (notamment épissage: U1, U2, U4, ...):  $> 100$  gènes
- snoRNA (small nucleolar RNA) (70-200 nt): maturation des rRNA dans le nucléole:  $> 100$  gènes
- miRNA (micro RNA) (régulation traduction, stabilité mRNA, transcription): 250 gènes identifiés (total ??)
- autres: Xist (17 kb), H19 (2 kb), UHG (U22 snoRNA host gene, 1-2 kb), ... : ?? gènes

# Repeated sequences


- Tandem repeats
  - Satellite
  - Minisatellite
  - Microsatellite
- Interspersed repeats
  - DNA transposons
  - Retroelements

# Tandem repeats


	motif	bloc size	% human genome
satellite:	2-2000 nt	up to 10 Mb	6.5%
minisatellite:	2-64 nt	100-20,000 bp	0.3%
microsatellite:	1-6 nt	10-100 bp	2%

Slippage of the DNA polymerase: CACACACACACA

Unequal crossing-over:





# Centromeres, telomeres: Satellite DNA



# Interspersed repeats


- Transposable elements (autonomous or non-autonomous) :
  - DNA transposons (rare in mammals)
  - Retroelements

# Retroelements




- **LINEs** (long interspersed elements): 6-8 kb  
retroposons
- **SINEs** (short interspersed elements): 80-300 bp  
small-RNA-derived  
retrosequences (tRNA),  
pol III
- **Endogenous Retroviruses**: 1.5-10 kb

# Retrosequences: opportunist retroelements



- LINE reverse transcriptase

## Contenu en séquences répétées du génome humain




## Principales classes d'éléments transposables dans le génome humain

				Nombre de copies	Fraction du génome
			Taille		
LINE	ORF1	ORF2 (pol)	AAAA	autonome 6-8 kb	850 000 20%
SINE		— AAAA	non-autonome 100-300 pb	1 500 000	13%
Rétrovirus endogènes	gag	pol	(env)	autonome 6-11 kb	450 000
	(gag)		non-autonome 1,5-3 kb		8%
Transposons	transposase		autonome 2-3 kb	300 000	3%
			non-autonome 80-3000 pb		

# Frequency of transposable elements in the human genome

- Total = 46% (Smit 1999, MGSC 2002)
- Probably underestimated



# Vagues d'insertions dans les génomes de mammifères


- La plupart des copies présentes dans le génome de mammifères sont tronquées et ont perdu la capacité de transposer (délétions, mutations non-sens)
- Par exemple, LINE1: 500,000 copies dans le génome humain, dont seulement 80-100 encore actives
- Vagues successives d'insertions

# Comment expliquer l'omniprésence des éléments transposables dans les génomes ?


- Hypothèse 1: fonction structurale pour l'organisation du noyau
- Hypothèse 2: source d'innovations bénéfiques pour l'adaptation des espèces
  - Exemples d'éléments transposables domestiqués (régions codantes, régulatrices)
  - Sélection de second ordre
- Hypothèse 3: ADN « égoïste »
  - Conflits entre éléments transposables et leur génome hôte

# Pseudogenes

- After a gene duplication:
  - evolution of new function (sub-functionalization or neo -functionalization)
  - or gene inactivation



# Retropseudogenes




# Pseudogenes

- About 20,000 retropseudogenes in the human genome
- Often derive from housekeeping genes
- About 2,000 unprocessed pseudogenes

# Vertebrate genome organization: variations of base composition along chromosomes


Sequence  
of human  
MHC




# Isochore organization of vertebrate genomes

- Large scale variations of GC-content along chromosomes
  - Affect both coding and non-coding regions (introns, intergenic regions)
  - Large regions ( $> 300$  kb) of relatively homogenous base composition = **isochores**
  - Bernardi et al. (1985, 2000)
- Correlation with other genomic features:
  - Insertion of repeated sequences (A. Smit 1996)
  - Recombination frequency (Eyre-Walker 1993)
  - Chromosome banding (Saccone, 1993)
  - Replication timing (Bernardi, 1998)
  - Gene density (Mouchiroud, 1991)
  - Gene structure (Duret, 1995)
  - Gene expression ?? -> No


## Isochores and insertion of repeat sequences (Smit 1999)



# Isochores and gene density





Mouchiroud et al 1991



IHGSC 2001

# Isochores and introns length


Gene compaction  
(intron length/coding region length)



IHGSC 2001

# Isochores and replication timing


(Watanabe et al. 2002)



# Isochores and replication timing

(Watanabe et al. 2002)

- Human chromosomes 21q and 11q (total: 180 Mb)



# Human genome: summary

- Genes, regulatory elements: ~ 2-5%
- Non-coding sequences: ~ 95-98%
  - Satellite DNA (centromeres) ~ 6-7%
  - Microsatellites ~ 2%
  - Transposable elements ~ 46%
  - Pseudogenes ~ 1%
  - Other (ancient transposable elements?) ~ 42%
- Variations in gene and repeat density along chromosomes


# Séquençage de l'ADN: historique

- 1943-1953: ADN support de l'information génétique
- 1977: techniques modernes de séquençage de l'ADN (Maxam & Gilbert, Sanger *et . al*)
- 1982: création des premières banques de données de séquence (GenBank, EMBL)
- 1990: début du projet génome humain (cartographie)
- 1995: premier génome complet d'un organisme cellulaire (*H. influenzae*)
- 2001: première ébauche du génome humain
- 2004: environ 200 génomes complets
- 2005: nouvelle technique de séquençage (x 30)


# Les projets génomes: objectifs

- faire l'inventaire de l'information génétique nécessaire au développement et à la reproduction des organismes
- comprendre l'organisation du génome (système d'information intégré ?)
- comprendre l'évolution des génomes
- applications médicales, agronomiques, industrielles

# Projets de séquençage : Génome / Transcriptome




# Shotgun sequencing



# Shotgun sequencing: improvement


(E. Myers)



# Strategy for sequencing the human genome


(Academic international consortium)

- Genome
- Cloning of long inserts (e.g. BAC DNA library : 100-200 kb)
- Genomic mapping
- Selection of clones to sequence
- Sub-cloning of short inserts (e.g. M13 DNA library : 1-20 kb)
- Sequencing M13 clones
- Assembly: contigs
- Finishing: gap closure



# Genomic Sequences


GenBank/EMBL HTG division : High Throughput Genome sequences



- |         |  |
|---------|--|
| Phase 0 | single-few pass reads of a single clone (not contigs).       |
| Phase 1 | Unfinished, may be unordered, unoriented contigs, with gaps. |
| Phase 2 | Unfinished, ordered, oriented contigs, with or without gaps. |
| Phase 3 | Finished, no gaps (with or without annotations)              |

# Complete genome sequence ?

- **Contig**: overlapping sequences without any gap
- **Scaffold**: set of ordered and orientated contigs; gaps of known length
- **Mapped scaffold**: set of scaffold localized along chromosomes (but not always ordered and orientated, gaps of unknown length)
- 2002: 97% of the human genome is sequenced, but only 85% in scaffolds assembly = draft sequence




<http://genome.ucsc.edu/>

# Genome Projects

- 263 complete genomes publically available (Oct. 2005) (215 bacterias, 22 archeaes, 26 eukaryotes)
- The 10 largest sequenced genomes
  - *Tetraodon nigroviridis* 365 Mb (2004) (draft)
  - chicken 1200 Mb (2004) (draft)
  - zebrafish 1600 Mb (2004) (draft)
  - mous 2600 Mb (2002) (draft)
  - rat 2600 Mb (2003) (draft)
  - chimpanzee 3000 Mb (2004) (draft)
  - human 3000 Mb (2001-2003)
  - opossum 3000 Mb (2005) (draft)
  - dog 3000 Mb (2005) (draft)
  - cow 3000 Mb (2005) (draft)

2006

+ elephant, hedgehog,  
rabbit, armadillo (2x  
coverage)



Complete sequence, finished assembly

Nearly complete sequence; preliminary assembly (draft)

Sequencing in progress

# Projets EST (transcriptome)

- Expressed Sequence Tags (EST)
- Inventaire des ARNm exprimés par un organisme, dans différents tissus, stades de développement, pathologies, ...
- Extraction et clonage des ARNm (banques d 'ADNc)
- Séquençage systématique des clones
  - Séquences partielles d 'ARNm (300-500 nt) - mauvaise couverture des extrémités 5'
  - Erreurs de séquence (1-3%)
  - Redondance (gènes fortement exprimés)
  - Qualité suffisante pour identifier un gène
- Automatisation
- Possibilité d'obtenir les clones cDNA (consortium IMAGE) (<http://image.llnl.gov/>)

# Large scale EST projects

	Number of ESTs (Feb. 05)
• <i>Homo sapiens</i>	6,029,601
• <i>Mus musculus</i> (mouse)	4,329,768
• <i>Rattus sp.</i> (rat)	691,985
• <i>Ciona intestinalis</i>	684,319
• <i>Xenopus tropicalis</i> (tropical frog)	634,367
• <i>Danio rerio</i> (zebrafish)	592,837
• <i>Triticum aestivum</i> (wheat)	587,650
• <i>Gallus gallus</i> (chicken)	531,351
• <i>Bos taurus</i> (cow)	513,065
• <i>Xenopus laevis</i> (xenope)	449,492
• <i>Zea mays</i> (maize)	417,803

# Projets GSS

- Genome Survey Sequence (GSS)
- Echantillonage aléatoire de séquence génomiques: donner un premier aperçu du contenu d'un génome
- Banques d 'ADN génomique
- Séquençage systématique de clones
  - Séquences courtes (< 1kb)
  - Erreurs de séquence (1-3%)
  - Qualité suffisante pour identifier un gène
- Automatisation

# Projets GSS à grande échelle

	Nombre de GSS (Sept. 2003)
• <i>Mus musculus</i> (souris)	952,000
• <i>Homo sapiens</i>	876,000
• <i>Zea mais</i> (maïs)	642,000
• <i>Brassica</i> (choux fleur)	567,000
• <i>Rattus norvegicus</i> (rat)	307,000
• <i>Arabidopsis thaliana</i> (arabette)	240,000
• <i>Tetraodon nigroviridis</i>	189,000
• <i>Danio rerio</i> (poisson zèbre)	159,000
• <i>Pan troglodytes</i> (chimpanzé)	158,000
• <i>Gallus gallus</i> (poulet)	137,000



## Different types of nucleotide sequences in current databases

	Standard	High throughput genome (HTG)	Genome survey sequence (GSS)	Expressed sequence tags (EST)
Contents	biologically characterized genes and RNAs, finished clones from genome projects	unfinished clones from genome projects	single pass sequences from random genomic clones	single pass sequences from random cDNA clones
Length	variable	>20,000 bp	<1,000 bp	<1,000 bp
Accuracy	medium-high	high	low	low
Annotation	medium to high, rich biological annotation	technically useful, biologically poor	technically useful, biologically poor	technically useful, biologically poor

## Augmentation exponentielle des données du séquençage

- Doublement tous les 18 mois

Quantité de séquences publiées (Mb)



# Pas seulement des séquences ...

- Expression des gènes (puces à ADN, filtres haute densité, SAGE, EST...)
- Polymorphisme (SNP, microsatellites)
- Structure 3D des protéines
- Interactions moléculaires
- ...

# Banques de données en biologie moléculaire

- Séquences
  - Banques généralistes (nucléiques, protéiques)
  - Banques spécialisées
- Structure des protéines
- Cartographie génomique
- Maladies génétiques, phénotypes
- Bibliographie
- ...


# Les banques de séquences généralistes

- Banques de séquences nucléotidiques :
  - EMBL (Europe) (1980)
  - GenBank (USA) (1979)
  - DDBJ (Japon) (1984)
  - Ces 3 centres échangent leurs données quotidiennement  
=> contenu identique
- Banques de séquences protéiques :
  - SwissProt-TrEMBL (Suisse, Europe) (1986 et 1996) => UniProt

Acquisition des données

Annotation

Distribution



# Taille de GenBank/EMBL

(Septembre 2006)

- $67 \cdot 10^9$  nucléotides.
- $43 \cdot 10^6$  séquences.
- 3 364 000 gènes (protéines et ARN).
- 439 000 références bibliographiques.
- 236 giga-octets sur disque.
- Augmentation de 200% en 24 mois.

## GenBank release 155 (August, 2006)


<u>Division</u>	<u>Nucleotides</u>	<u>% nt</u>
EST	21.4 Gb	32%
HTG	16.2 Gb	24%
GSS	9.9 Gb	15%
<u>Other</u>	<u>19.5 Gb</u>	<u>29%</u>
<b>Total</b>	<b>67.0 Gb</b>	<b>100%</b>
Human	12.4 Gb	19%

# Contenu des banques de séquences nucléiques: échantillonage taxonomique

- 268,000 espèces pour lesquelles on a au moins une séquence
- 10 espèces (0.004%) représentent à elles seules 60% des séquences
  - *Homo sapiens* 19%
  - *Mus musculus* (souris) 12%
  - *Rattus norvegicus* (rat) 9%
  - *Bos taurus* (vache) 5%
  - *Danio rerio* (poisson zèbre) 4%
  - *Zea mays* (maïs) 3%
  - *Oryza sativa* (riz) 2%
  - *Strongylocentrotus purpuratus* (oursin) 2%
  - *Sus scrofa* (porc) 2%
  - *Xenopus tropicalis* (grenouille tropicale) 1%

# La redondance

- Un problème majeur des banques est celui de la redondance.



# Variations dans les séquences

- Les doublons présentent fréquemment des variations dans leurs séquences et leurs annotations.
- Il est impossible de décider si ces différences sont issues :
  - D'un polymorphisme.
  - D'erreurs de séquençage.
  - De duplications de gènes.
- GenBank: 20% de redondance parmi les séquences de gènes protéiques de vertébrés; 40% de redondance parmi les séquences génomiques humaines

# UniProt: SWISS-PROT et son complément TrEMBL

- Collaboration entre le *Swiss Institute of Bioinformatics* (SIB) et l'EBI (EMBL).
- SwissProt:
  - Expertise manuelle poussée: annotations riches (fonction des protéines, localisation sub-cellulaire, strucutre, modifications post-traductionnelles, ...)
  - Redondance minimale
  - Incomplète
- TrEMBL: traduction des séquences codantes d 'EMBL qui ne sont pas déjà dans SwissProt
  - Annotation automatique: annotations moins riches
- UniProt: SwissProt+TrEMBL: ensemble complet, redondance minimale

# Banques de séquences spécialisées

- *PROSITE, PFAM, PRODOM, PRINTS, INTERPRO* : banques de motifs protéiques
- *Protein Data Bank* (PDB): structures 3D (protéines, DNA, RNA)
- *Ribosomal Database Project* (RDP) : rRNA
- Banques de données taxon-spécifiques:
  - Homme: OMIM: phénotypes, maladies génétiques, mutations
  - Génomes animaux: Ensembl
  - Levure (LISTA, SGD, YPD).
  - Nématode (ACeDB).
  - Drosophile (FlyBase).
  - ...

# Banques de données bibliographiques

- MEDLINE/PUBMED: médical, génétique, biologie moléculaire, biochimie, physiologie, ...
  - <http://www.ncbi.nlm.nih.gov/entrez/>
- ISI Science Citation Index: général
- EMBASE: médical
- PASCAL: général

# Interrogation des bases de données

- Sélection des entrées en fonction de :
  - Noms et numéros d’accession des séquences.
  - Références bibliographiques (auteurs, articles, ...).
  - Mots-clés.
  - Taxonomie (espèce, genre, ordre, ...).
  - Date de publication
  - Organelles, hôte
  - ...
- Accès aux aux régions fonctionnelles décrites dans les *features*.
  - régions codantes (CDS), tRNA, rRNA, ...


# Logiciels d 'interrogation

- ACNUC/Query : <http://pbil.univ-lyon1.fr/>
  - Accès à GenBank, EMBL, SWISS-PROT, TrEMBL.
  - Requêtes complexes
  - Sélection et extraction de sous-séquences (e.g. CDS, tRNAs, rRNAs, ...)
- SRS (sequence retrieval system) <http://srs.ebi.ac.uk/>
  - À ce jour, près de 90 banques consultables sous SRS.
  - Permet des interrogations multi-banques.
- Entrez <http://ncbi.nlm.nih.gov/>
  - Accès aux banques du NCBI : GenBank, GenPept, NRL\_3D, MEDLINE.
  - Recherches par voisinage:
    - séquences : recherche de similarités.
    - références bibliographiques : mots-clés communs dans les titres ou les résumés.


# Genome annotation

- Identification of repeats (RepeatMasker, Reputer, ...)
- Prediction of protein-coding genes
  - Intrinsic methods (GenScan, Genmark, Glimmer, ...)
  - Genomic/mRNA (EST) comparison (blastn, sim4, ...)
  - Genomic/protein comparison (blastx, GeneWise, ...)
- Prediction of RNA genes
  - Intrinsic methods (tRNA: tRNAScanSE, snoRNA ...)
  - Genomic/RNA (EST) comparison (blastn, sim4, ...)
- And more ...
  - Replication origins (bacteria) (oriloc)
  - Pseudogenes (by similarity) (blastn, blastx)
  - Regulatory elements (CpG islands, promoters ??)


# Proportion of functional elements within genomes




*E. coli*




*Yeast*  
*S. cerevisiae*




**Nematode**  
*C. elegans*



**Drosophila**




**Human**



**Lungfish**  
(*dipnoi*)

Coding (protein)  
 RNA  
 Non-coding

# Structure des gènes humains



- Tailles moyennes
  - Gene 45 kb
  - CDS 1500 nt
  - Exon (interne) 145 nt
  - Intron 5200 nt
  - 5'UTR 210 nt
  - 3'UTR 740 nt
- Intron/exon
  - Nombres d'introns:  $6 \pm 3$  introns / kb CDS
  - Introns / (introns + CDS): 92%
- Epissage alternatif dans plus de 30% des gènes

start

introns

MDQASLIDESEQSFEQSRRVEPTVSDKMKRTESATLKQKIINFIRDVQQSKLPLDSMPSI  
VQQKISDFEDEFQDLWKEDEYLRENGEAIEKLVMKPLCSKLISIDPVKDREIEFSMKAY  
SFVQAKHLEIDENIEKHKMFNQVVDLISKIDKVETPKELN CIVNAGKQTS AIVNQMANN  
QPTGADNLLPVLIYATLKAQPSKAYSNILFVSYRSPKRITGEDEYYFTTYESTLQFIEK  
LDYQKLNINHQEFQDLSKERLDVIKNSQNELSQNGIFNMDAHQNYVNLOMIKMKIQLDQR  
KSKFYEQSKKYKLKFNQKQLNNITLNEIPEFYDEYONLYKNLLEMQKDIHNLYNLNTNEII  
KESQSETKKVATRKFFGII\*

stop

## Prédiction de gènes: informations utilisées

- 1- caractérisation de la taille et du contenu des régions (codantes/non-codantes)
- 2- caractérisation des signaux au niveau de sites fonctionnels (e.g. signaux d'épissage, début et fin de traduction, ...)
- 3- utilisation de similarité ADN/protéines, ADN/ARNm, ADN/ADN
  
- méthodes intrinsèques (*ab initio*): utilisent 1 et 2
- méthodes extrinsèques (approche comparative): utilisent 3, et éventuellement 2

# Prédiction de gènes : méthodes intrinsèques

- Prédiction des régions codantes uniquement !
- Recherche de phases ouvertes de lecture (ORF: open reading frame) = série de codon sans STOP

Phase +0

Phase +1

Phase +2

ATGTACCGTCGATCGTAGCTTGATCGATCG  
TACATGGCAGCTAGCATCGAACTAGCTAGC

Phase -0

Phase -1

Phase -2

- Taille moyenne des ORF:  $\pm 150$  nt

- Distinction codant/non-codant : contenu et taille des séquences
  - usage des codons: utilisation non aléatoire des codons synonymes
  - fréquence des amino-acides (e.g. tryptophane est rare)
  - corrélations entre amino-acides (codons) successifs
  - taille des exons et introns
- Apprentissage sur un ensemble de gènes connus
- Fréquence d'oligomères (e.g. hexamères)
- chaînes de Markov

## Prédiction de gènes : méthodes intrinsèques (suite)


- Recherche de signaux: sites fonctionnels conservés
  - signaux d'épissage: site donneur, accepteur d'épissage, point de branchement
  - codon d'initiation de la traduction
  - codon stop
  - Utilisation de consensus (historique): e.g.

donneur	accepteur
A/CAG GT RAGT	YYYYYYYYYY*C AG G


- Utilisation de matrices de pondération position-dépendantes (profils)

## Prédiction de gènes : méthodes intrinsèques (suite)

- Construction d'un modèle de gène protéique
  - Combinaison d'exons de phases compatibles (pondération en fonction des scores de chaque exon potentiel) - pas de codons stop en phase!



- Recherche de limites de gènes
  - Exons terminaux (5', 3')
  - Promoteur
  - Signal de polyadénylation



# Qualité de la prédiction par exon

- Évaluation de la fiabilité de la prédiction
  - essai des logiciels de prédiction sur un ensemble de séquences caractérisées expérimentalement (différentes de celles utilisées pour entraîner les logiciels)
- Sensibilité : fraction des exons présents dans la séquence qui sont retrouvés par le logiciel

$$sensibilité = \frac{VraisPositifs}{VraisPositifs + Faux Négatifs}$$

- Spécificité : fraction des vrais exons parmi tous ceux prédis

$$spécificité = \frac{VraisPositifs}{VraisPositifs + Faux Positifs}$$

## Prédiction de gènes eucaryotes: qualité de la prédiction


- Comparaison des différents logiciels: sensibilité/spécificité
  - Sn: sensibilité Sp: spécificité par exon (sn\_e, sp\_e) ou par nucéotide (sn\_n, sp\_n)
  - Locus BRCA2 (1.4 Mb, chrom. 13q) (Sanger Centre 1999): région "difficile" pour les logiciels de prédiction. 159 exons

	Sn_e	Sp_e	Sn_n	Sp_n
GenScan	0.66	0.36	0.81	0.44
FGENES 1.6	0.69	0.57	0.79	0.66
FGENES 1.6 masked	0.69	0.65	0.79	0.74
GenScan+FGENES	0.61	0.82	0.67	0.90

# Prédiction de gènes protéiques complets

- Prédiction de gènes complets: sensibilité ?

Probabilité de détecter tous les exons d'un gène



- + les faux positifs ! + épissage alternatif ! + exons non-codants !

## Un peu d 'optimisme

- Fraction de la longueur des gènes correctement prédicts:

70-80%

- Probabilité que deux exons potentiels consécutifs soient réels (et donc positifs en RT-PCR)

0.5

## Prédiction de gènes : méthodes intrinsèques (bilan)

- Procaryotes (pas d'intron):
  - sensibilité et spécificité > 95% (dépend du taux de G+C du génome)
- Eucaryotes: efficacité variable (dépend du taux de G+C du génome et du nombre et de la taille des introns)
  - prédiction d'exons: sensibilité et spécificité 60-80%
  - prédiction de gènes complets:
    - levure: >90% des gènes correctement prédis
    - nématode: 50% des gènes correctement prédis
    - homme: 20% (?) des gènes correctement prédis
- très utile pour guider les expérimentations


# Prediction of protein genes : mRNA / DNA comparison

- Large scale transcriptome data
  - ESTs
  - full-length cDNA sequencing projects
- Alignment genomic DNA / mRNA : identification of exons (blastn, sim4, est2genome)
  - information on alternative splicing, gene expression pattern
  - not restricted to protein-coding regions (UTRs, non-coding RNAs)
- Problems:
  - weakly expressed genes; genes with a restricted tissue-distribution
  - artefacts in EST sequences (contamination with nuclear RNA, DNA)

# Prediction of protein genes: comparative approach

- Comparison of a genomic sequence with genes that have been already characterized (e.g. in other species)
  - DNA/protein alignments: blastx, genewise
- Comparison of homologous genomic sequences
  - DNA/DNA alignments

# Analyse comparative des gènes de β-actine de l'homme et de la carpe




introns: —  
régions codantes: ■  
éléments régulateurs: ■■■

échelle de similarité:  
■ pas de similarité significative  
■■ 80 - 90% identité  
■■■ 70 - 80% identité

Comparison of human and mouse CD4-C9 locus:  
gene-rich, repeated-element poor, G+C-rich region (50.5%)

Human chromosome 12p13  
Mouse chromosome 6

8 genes: CD4, A, B, GNB3, C8, ISOT, TPI, C9



# Prediction of protein genes: comparative approach

- Problems: sensitivity depends on the evolutionary distance
  - rapidly evolving genes
  - lineage-specific genes (orphans)
- How to distinguish protein-coding regions from conserved non-coding sequences ?

# Distinction des régions conservées codantes *vs.* non-codantes

	Q	V	E	L	G	G	G	P	G	A	G	S	L
Homme	cag	gtg	gag	ctg	ggc	ggg	ggc	cct	ggt	gca	ggc	agc	ctg
Souris	caa	ctg	gag	ctg	ggt	gga	---	ccg	gga	gca	ggt	gac	ctt
	Q	L	E	L	G	G	-	P	G	A	G	D	L

- Substitutions synonymes (Ks)
- Substitutions non-synonymes (Ka)
- Insertion ou délétion

Ratio Ka/Ks << 1 => région codante

# Transposable elements: noise for gene prediction

- Transposable elements: ubiquitous in eukaryotic genomes (50% of mammalian genomes)
- TEs contain coding-regions (transposases, reverse-transcriptase) => recognized as “genes” by gene prediction software
- Domesticated (recruited) TEs are very rare
- Mask TEs before running gene prediction software (RepeatMasker)

# Prédiction de gènes : démarche

- 1- recherche de séquences répétées (RepeatMasker)
- 2- méthodes intrinséques (consensus de différentes méthodes)
- 3- recherche de similarité ADN/protéines (blastx/genewise)
- 4- recherche de similarité ADN/mRNA (blastn/sim4)
- 5- recherche de similarité ADN/ADN (blastn)
- COMBINER LES RESULTATS
- 6- prédiction de gènes RNA
  - tRNA: tRNAscanSE
  - rRNA: par similarité
  - snRNA ...

# Annotation systématique du génome humain

- ENSEMBL project
  - <http://www.ensembl.org/>
- Human Genome Project Working Draft at UCSC
  - <http://genome.ucsc.edu/>

# Prédiction de régions régulatrices

- Méthodes intrinsèques (*ab initio*)
  - Prédiction de promoteurs
  - Îlots CpG
- Approche comparative

# Prédiction de promoteurs eucaryotes

- Combinaison de sites de fixation de facteur de transcription (ordre, orientation, distance)
- Motifs courts, dégénérés
  - Difficile de distinguer les vrais sites des faux positifs:
  - Motif à 4 bases:  $\approx 1/256$  pb ( $1/128$  pb sur les deux brins)
- Boîtes TATA, CAAT , GC: absents dans beaucoup de promoteurs
- Banques de données de sites de fixation de facteurs de transcription (TRANSFAC), de promoteurs caractérisés expérimentalement (EPD)
- PromoterScan (Prestridge 1995): Mesure de la densité en sites potentiels de fixation de facteurs de transcription de long de la séquence (pondération en fonction de la fréquence des sites dans ou en dehors des vrais promoteurs)

## Prédiction de promoteurs: sensibilité, spécificité

- Sensibilité: fraction des promoteurs qui sont trouvés par le logiciel

$$\text{sensibilité} = \frac{\text{vrais\_positifs}}{\text{vrais\_positifs} + \text{faux\_négatifs}}$$

– PromoterScan: sensibilité = 70% (promoteurs à boîte TATA)


- Spécificité: fraction des vrais promoteurs parmi ceux qui ont été prédits

$$\text{spécificité} = \frac{\text{vrais\_positifs}}{\text{vrais\_positifs} + \text{faux\_positifs}}$$

– PromoterScan: spécificité = 20%

– Un faux positif / 10 kb

- Génome humain:
- $\approx 25\ 000$  gènes,  $\approx 1$  promoteur/100 kb




# Îlots CpG

- Génome de vertébrés :

- méthylation des C dans les dinucléotides 5'-CG-3' (CpG)

- Me-C fortement mutable -> T



- Génome des vertébrés: globalement dépourvu en CpG (excès de TG, CA)

$$CpG_{o/e} = \frac{\text{Nombre de CpG observé}}{\text{Nombre de CpG attendu}} = 0.25$$

- Certaines régions (200 nt à plusieurs kb) échappent à la méthylation

- Pas de déplétion en CpG:  $CpG_{o/e}$  proche de 1


- Riche en G+C

- Îlot CpG:

- Longueur > 500 nt

- $CpG_{o/e} > 0.6$

- G+C > 50%



## Îlots CpG


- Bird (1986), Gardiner-Garden (1987) Larsen (1992) ref
  - 40% des gènes tissu-spécifiques possèdent un îlot CpG en 5'
  - 100% des gènes ‘ housekeeping ’ possèdent un îlot CpG en 5'
- Rechercher des îlots CpG pour prédire des régions promotrices ?
  - Sensibilité: 40-100%
  - Spécificité ?? (Quelle fraction des îlots CpG correspondent effectivement à des régions promotrices ?)
- Ponger (2001): comparaison des îlot CpG qui recouvre ou non le site d'initiation de la transcription

# Prédiction de promoteurs

La prédiction des régions promotrices:

$sn = \text{nb prom de gènes connus préd} / \text{nb prom de gènes connus}$


$sp = \text{nb prom préd} / \text{nb de prédictions}$



## Recherche de régions régulatrices par analyse comparative (empreintes phylogénétiques)

- Goodman et al. 1988: régulation de l'expression des gènes du cluster  $\beta$ -globine au cours du développement
  - Alignement de séquences orthologues de 6 mammifères ( $> 270$  Ma d'évolution)
  - 13 empreintes phylogénétiques:  $\geq 6$  nt, conservation 100%
  - Analyse par retard de bande sur gel:
  - 12/13 (92%) correspondent à des sites de fixation de protéines
- 1996: 35 empreintes phylogénétiques avec protéines fixatrices identifiées

# Analyse comparative des gènes de $\beta$ -actine de l'homme et de la carpe



échelle de similarité

- introns: —
- régions codantes: ■
- éléments régulateurs: ■■■

- pas de similarité significative
- 80 - 90% identité
- 70 - 80% identité


# Recherche d'empreintes phylogénétiques à l'échelle du génome

- Empreintes phylogénétique = séquences qui évoluent plus lentement que des séquences non soumises à pression de sélection
- En absence de sélection, le taux d'évolution est égal au taux de mutation (= évolution neutre)
- Mammifères: taux de mutation environ  $3 \cdot 10^{-9}$  substitution/site/an
- Variation des taux de mutation le long du génomes (et entre espèces)
- Utilisation de marqueurs neutres pour mesurer le taux de mutation local : pseudogènes, éléments transposables défectifs

# Comparaison des génomes de l'homme et de la souris

- Alignement des génomes de l'homme et de la souris: 40% du génome humain est alignable avec le génome de la souris
- Utilisation de marqueurs neutres pour mesurer le taux de mutation local : éléments transposables défectifs orthologues homme/souris (i.e. insérés dans le génome avant la divergence primates/rongeurs)
- Comparaison des taux de substitution dans les séquences non-répétées et dans les marqueurs neutres

# Comparaison des génomes de l'homme et de la souris



Distribution des taux de substitution

- Marqueurs neutres
- Séquences non-répétées

Probabilité d'être sous pression de sélection négative


- Plus de 5% du génome des mammifères est sous pression de sélection négative
- NB: seulement 1.2% du génome est codant !! 4 fois plus des régions non-codantes fonctionnelles que de régions codantes !!
- Problème: faible discrimination des séquences sous pression de sélection !!

# Comparaison à plus grande distance évolutive

- Mammifères/Oiseaux
  - Empreinte phylogénétique couvrent 2,5% du génome humain
  - 56% des ces empreintes sont non-codantes
- Mammifères/Poissons:
  - Empreinte phylogénétique couvrent 1,8% du génome humain
  - 50% des ces empreintes sont non-codantes
  - Empreintes phylogénétiques non-codantes souvent à proximité des gènes impliqués dans le développement
  - 36 testées expérimentalement: 27 (75%) ont une activité enhancer (Nobrega 2003)

# Empreintes phylogénétiques: compromis sensibilité/spécificité

- Grande distance évolutive: ne détecte pas les éléments fonctionnels spécifiques d'une lignée
  - Mammifères/poissons: 1.8% génome humain
  - Mammifères/oiseaux: 2.5% génome humain
  - Primates/rongeurs: 5% génome humain
  - Homme/grands singes: 10% génome humain ??
- Faible distance évolutive: ne discrimine pas les régions conservées contraintes vs. neutres
- Solution: augmenter le nombre d'espèces !



Complete sequence, finished assembly

Nearly complete sequence; preliminary assembly (draft)

Sequencing in progress

# Prediction of gene function

- Analysis of expression pattern (ESTs, SAGE,...)
- Prediction of the subcellular location of the protein : nucleus, membrane, excreted, etc.
  - SignalPep : <http://www.cbs.dtu.dk/services/SignalP/>
  - Psort: <http://psort.nibb.ac.jp/>
  - etc. (see <http://www.expasy.org/tools/>)
- Search for functional motifs (e.g. DNA binding domains, catalytic sites, ...)  
<http://hits.isb-sib.ch/cgi-bin/PFSCAN>

- Prediction by homology

# Function prediction by homology ?

- Similarity between proteins => homology
- Homology => conserved structure
- Conserved structure => conserved function
- Yes, but ...
  - Function: fuzzy concept
    - Identical biochemical activity ?
    - Identical expression pattern (tissu-specific isoforms) ?
    - Identical subcellular location (cytoplasm, mitochondria, etc.) ?
  - Homologous proteins with different function
    - e.g. homologous proteins binding a same receptor but opposite activity (activator/repressor)
    - homologous proteins with totally different functions:  $\tau$ -cristalline /  $\alpha$ -énolase
  - Orthology/paralogy
  - Modular evolution

# Function prediction by homology ?


MZEORFG: 1 NSPDRACNLAKQAFDEAISELDSDLGEESYKDSTLIMQLLDNLTLWTSDNE 59  
N+P++AC LAKQAFD+AI+ELD+L E+SYKDSTLIMQLLDNLTLWTSD E  
BOV1433P: 186 NAPEQACLLAKQAFDDAIAELDTLNEDSYKDSTLIMQLLDNLTLWTSEGE 244

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

LOCUS BOV1433P 1696 bp mRNA MAM 26-APR-1993  
DEFINITION Bovine brain-specific 14-3-3 protein eta chain mRNA  
ACCESSION J03868

LOCUS MZEORFG 187 bp mRNA linear PLN 01-FEB-2001  
DEFINITION Zea mays putative brain specific 14-3-3 protein,  
tau protein homolog mRNA, partial cds.  
ACCESSION M95066

# Orthology/paralogy



Homology: two genes are homologous if they share a common ancestor


↔ Orthologues: homologous genes that have diverged after a speciation

↔ Paralogues: homologous genes that have diverged after a duplication




Orthology ≠ functional equivalence

# Phylogenetic approach for function prediction



# Modular evolution



# The ENCODE (ENCyclopedia Of DNA Elements) Project

The ENCODE Project Consortium\*†

The ENCyclopedia Of DNA Elements (ENCODE) Project aims to identify all functional elements in the human genome sequence. The pilot phase of the Project is focused on a specified 30 megabases (~1%) of the human genome sequence and is organized as an international consortium of computational and laboratory-based scientists working to develop and apply high-throughput approaches for detecting all sequence elements that confer biological function. The results of this pilot phase will guide future efforts to analyze the entire human genome.

approaches, such as cDNA-cloning (4, 5) and chip-based transcriptome analysis (6, 7), have revealed the existence of transcribed sequences of unknown function. As a reflection of this complexity, about 1% of the human genome is evolutionarily conserved with respect to rodent genome sequences, and therefore is inferred

# Encode Project: make the inventory of all functional elements in the human genome

Genes (transcription units, coding or not), promoters, enhancers, silencers, replication origin/termination, TFBS, methylation, chromatin modification, conserved regions of unknown function





Fig. 1. Functional genomic elements being identified by the ENCODE pilot phase. The indicated methods are being used to identify different types of functional elements in the human genome.

# Encode Project

- Combine all possible methods to identify functional elements
- Large scale experiments:
  - transcriptome analysis
  - Chip on chip experiments
  - ...
- Comparative genomics



## Inter-species Comparisons

Polymorphism Analysis (48 individuals)

# Open Consortium

- Phase 1 pilot: 44 regions (30 Mb = 1% of the human genome)
  - Target regions (e.g. globin, CFTR)
  - Randomly sampled regions
  - Test various approaches
- Phase 2: technology development (large scale!)
- Phase 3: production