

IFT 3290 hiver 2004

Bioinformatique

Miklós Csűrös

André-Aisenstadt 3253
csuros@iro.umontreal.ca

<http://www.iro.umontreal.ca/~csuros/IFT3290/>

Préalables :

IFT2010 — Programmation 2

IFT1978 — Probabilités et statistique

Horaire :

cours	mercredi 11 :30–13 :30	AA 1207
cours	vendredi 14 :30–15 :30	AA 1177
démonstration	vendredi 15 :30–17 :30	AA 1360

Démonstrateur : on verra...

Évaluation : 30% TP, 30% intra, 40% final.

Seuil : au moins 40% au meilleur des deux exams.

4 travaux

Diversité et universalité

Diversité de la vie

Universalité au niveau moléculaire : interaction de macromolécules

Protéines et acides nucléiques

Protéines

Fonctions :

- structure de la cellule [p.e collagène form des fibres en tissu conjonctif]
- enzymes : catalysateur de réactions spécifiques
- protéines membranaires
- signalisation [p.e. EGF — facteur de croissance pour l'épiderme]
- ...

Exemple : kinesine

(moteur moléculaire)

©UIUC Theoretical and Computational Biophysics Group

Info sur une protéine

facteur de croissance EGF : voie de signalisation (www)

recherche dans une base de donnée : SWISS-PROT (www)

(Tapez «EGF receptor» au site Web de SWISS-PROT et suivez le lien vers EGFR_HUMAN.)

pleine d'information liée : e.g., structure 3D (www)

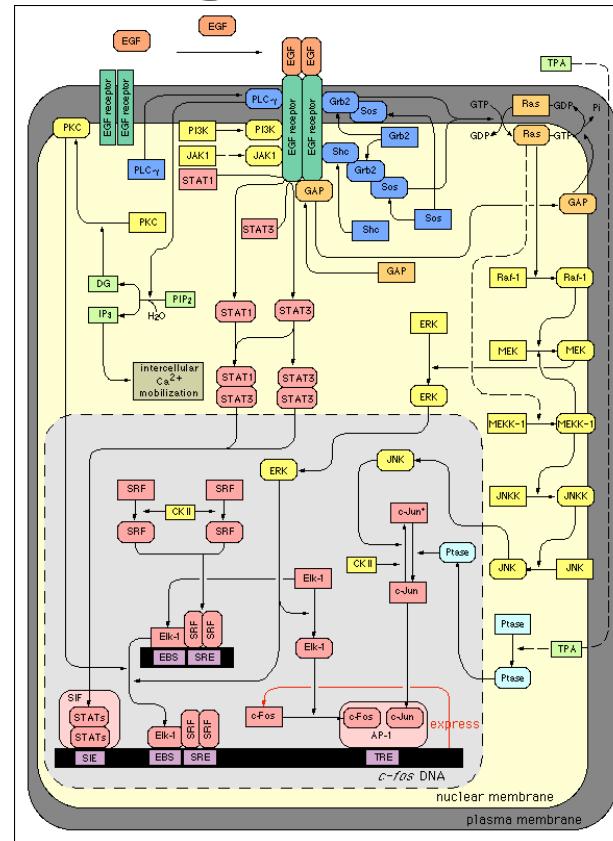
(Suivez le lien «PDB» dans la ligne «HSSP».)

Séquence

MRPSGTAGAA LLALLAALCP ASRALEEKKV CQGTSNKLTQ
LGTTFEDHFLS LQRMFNNCEV VLGNLEITYV QRNYDLSFLK

...

Voie de signalisation EGF



SPAD, Kyushu University

EGF à SWISS-PROT

NiceProt View of SWISS-PROT P00533
1/18/03 9:42 AM

NiceProt View of SWISS-PROT P00533
1/18/03 9:40 AM

nom de la BD

nombre d'accésion

une autre BD

PIR

SWISS-2DPAGE

Gene

MM

GeneCards

GlycoSamiDB

SOURCE

Ensembl

P1363: EGF [HSSP ENTRY / PDB]

P00533: HUMAN

HGNC_3236: EGFR

EGRF: Homo sapiens.

EGRF: Homo sapiens.

P00533: Homo sapiens. [Entry / Config view]

IPR000949: EGFR_L_domain

IPR000710: Euk_plkase

IPR000710: Tvc_kinase

IPR001243: Tvc_kinase

Graphical view of domain structure

Pfam

Pfam0069: plkinase_1

Pfam00737: EGFR_L-domain_1

Pfam00738: EGFR_L_domain_2

PRINTS

PR00109: TYRKINASE

ProDom

PD000001: Prot_kinase_1

Domain structure / List of seq sharing at least 1 domain

SMART

SM00261: Tyk2c_1

PS00107: PROTEIN_KINASE_ATP_1

PS00109: PROTEIN_KINASE_TYR_1

PS00111: PROTEIN_KINASE_DOM_1

BLOBS

P00533:

ProtoNet

P00533:

ProtoMap

PRESAGE

P00533:

DIP

P00533:

ModBase

P00533:

Keywords

Transmembrane Glycoprotein_Repeat; Receptor_Signal_Transferas; Tyrosine-protein_kinase_ATP-binding_Phosphorylation; Alternative_splicing

Features

Key	From	To	Description
IGNAL	1	24	
CHAIN	2	1210	1186 EPIDERMAL GROWTH FACTOR RECEPTOR.
DOMAIN	2	645	621 EXTRACELLULAR (POLENTIAL).
TRANSMEM	646	650	27
DOMAIN	649	1210	542 CYTOPLASMIC (POLENTIAL).
REPEAT	2	100	226 APPROXIMATE.
REPEAT	200	600	211 APPROXIMATE.

<http://ca.expasy.org/cgi-bin/niceprot.pl?P00533>

<http://ca.expasy.org/cgi-bin/niceprot.pl?P00533>

EGF à PDB

Structure Explorer - 1FGK 1/10/03 9:22 AM

PDB
PROTEIN DATA BANK

Structure Explorer - 1FGK



Title Crystal Structure Of The Tyrosine Kinase Domain Of Fibroblast Growth Factor Receptor 1
Classification Phosphotransferase
Compound Mol_Id: 1; Molecule: Fgf Receptor 1; Chain: A, B; Fragment: Tyrosine Kinase Domain, Human Fgfr1 Residues That Possess Ptk Activity; Synonym: Fgfr1K, Fibroblast Growth Factor Receptor 1; Ec: 2.7.1.112; Engineered: Yes; Mutation: L457V, C488A, C584S
Exp. Method X-ray Diffraction

[View Structure](#) 

[Summary Information](#)
[View Structure](#)
[Download/Display File](#)
[Structural Neighbors](#)
[Geometry](#)
[Other Sources](#)
[Sequence Details](#)
[Structure Factors \(compressed\)](#)

[Explore](#) 

© RCSB

<http://www.rcsb.org/pdb/cgi/explore.cgi?job=graphics;pdbleid=1FGK;page=&opt=show&size=500>

Page 1 of 1

Séquences protéiques

Protéine : un ou plusieurs polymères d'acides aminés (polymère est une grosse molécule formée de l'union de molécules plus petites)

Alanine (Ala) Glycine (Gly) Méthionine (Met)

Sérine (Ser) Cystéine (Cys) Histidine (His)

Asparagine (Asn) Thréonine (Thr) Acide aspartique (Asp)

Isoleucine (Ilu) Proline (Pro) Valine (Val)

Acide glutamique (Glu) Lysine (Lys) Glutamine (Gln)

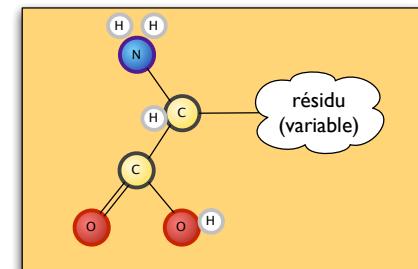
Tryptophane (Trp) Phénylalanine (Phe) Leucine (Leu)

Arginine (Arg) Tyrosine (Tyr)

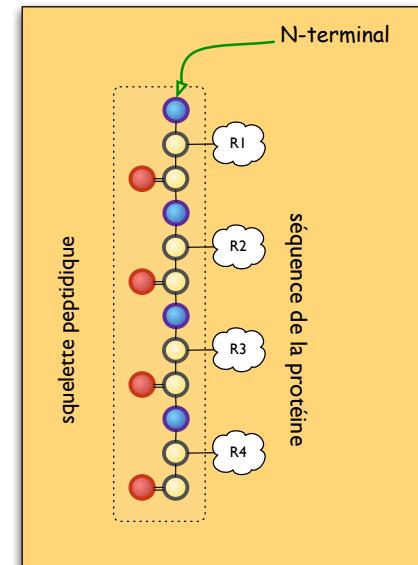
La séquence détermine la structure

⇒ **Problème de prédition de structure protéique.**

Acides aminés



Acide
aminé



Protéine

(Phe, Pro, Met, Gly)

Song Tan, Penn State U

Autres problèmes

Comment est la structure établie ?

⇒ **Repliement de protéines**

La structure détermine la fonction

⇒ **Problème de prédiction de fonction protéique.**

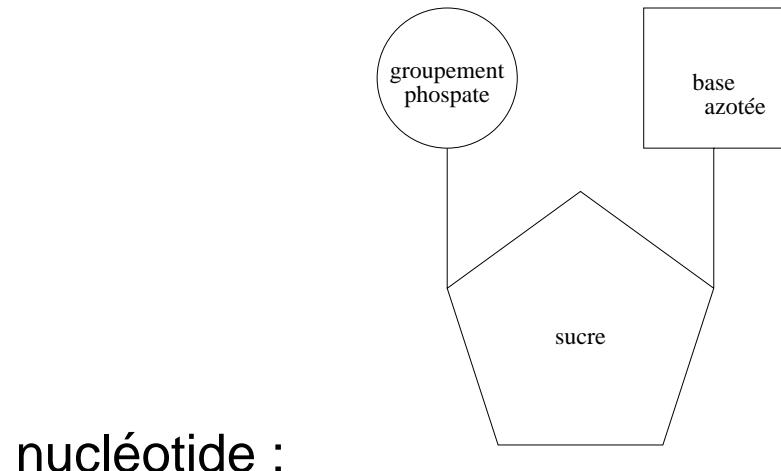
Interaction de protéines

⇒ **Analyses de voies métaboliques, chemins de signalisation, réseaux régulatoires**

D'où viennent les protéines ?

Encodage en acides nucléiques : ADN et ARN.

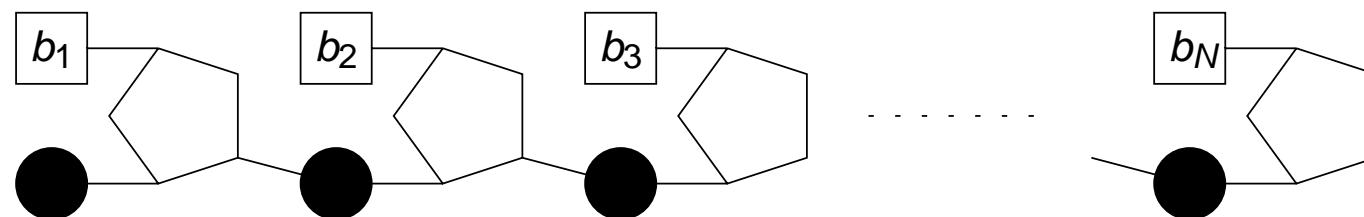
ADN : polymère de nucléotides



ADN 2

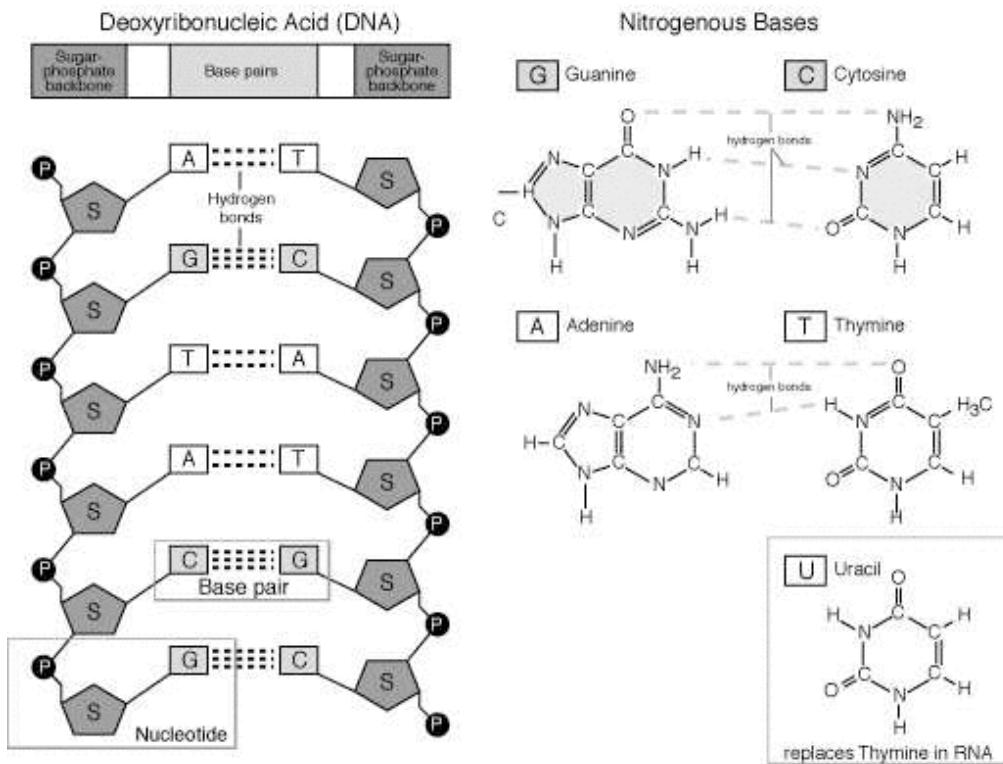
4 bases : adénine, thymine, guanine, et cytosine

chaîne de ADN :



$$b_i = \text{A, C, G, T.}$$

ADN : bases complémentaires



Watson et Crick : double hélice

1 pas de l'hélice : 10 paires de base, 3.4 nm (forme usuelle)

Doug Lundberg

ADN

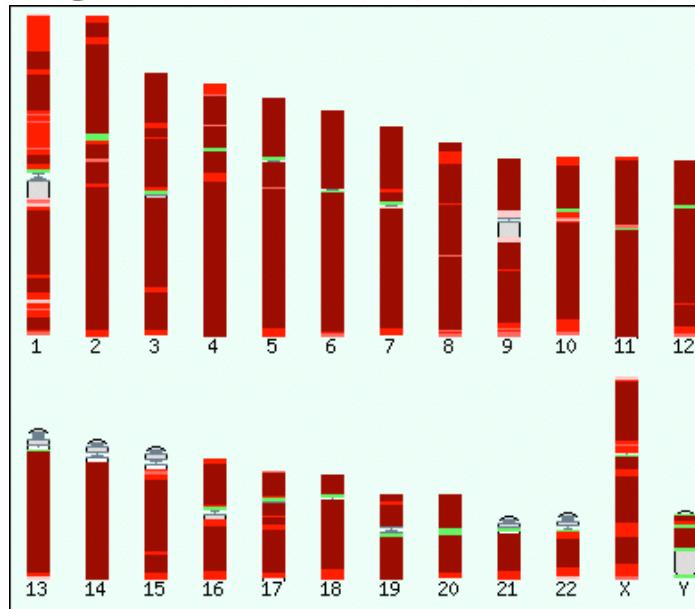
stockage de l'ADN : dans le noyau de la cellule, organisé en chromosomes

1. duplication de l'information en ADN : hérédité
2. duplication de l'information en ARN (qui est traduit en protéines)

RéPLICATION

Lodish et al., Molecular Biology of the Cell, 2002

Chromosomes



22 chromosomes diploïdes et 2 chromosomes sexuels

tailles : $250 \cdot 10^6$ – $23 \cdot 10^6$ paires de base

taille totale du génome humaine : $3 \cdot 10^9$ pb

NCBI

Code génétique

20 acides aminés encodés par 4 nucléotides ?

Encodages par triplets : 64 codons

AAA = Phe	AAG = Phe	AAT = Leu	AAC = Leu
AGA = Ser	AGG = Ser	AGT = Ser	AGC = Ser
ATA = Tyr	ATG = Tyr	ATT = FIN	ATC = FIN
...			

3 triplets d'arrêt, 1 triplet de début (encode aussi Met)

De ADN à protéine

1. transcription : copie du brin informatif à ARN messager
(ARN : utilise Uracile au lieu de Thymine)
2. traduction : ARNm à protéine (par le ribosome) : acides aminés fournis par ARN de transfert

Mécanisme universelle !

⇒ Problème de déterminer la séquence de l'ADN.

De ADN à protéine

Lodish et al., Molecular Biology of the Cell, 2002

Gènes

Gène : unité d'hérédité, se traduit à une protéine (en général)

Exons et introns

⇒ Problème de prédiction de gênes.

Expression d'un gène : quantité de ARNm transcrit ⇒ Problème d'analyse de l'expression génétique.

Comparaisons

Comparaisons de séquences : pour déterminer structure, fonction, . . .
⇒ Problème de comparaison de séquences.

Grandes bases de données
⇒ Problème de recherche de séquences.

Évolution

Calcul moléculaire