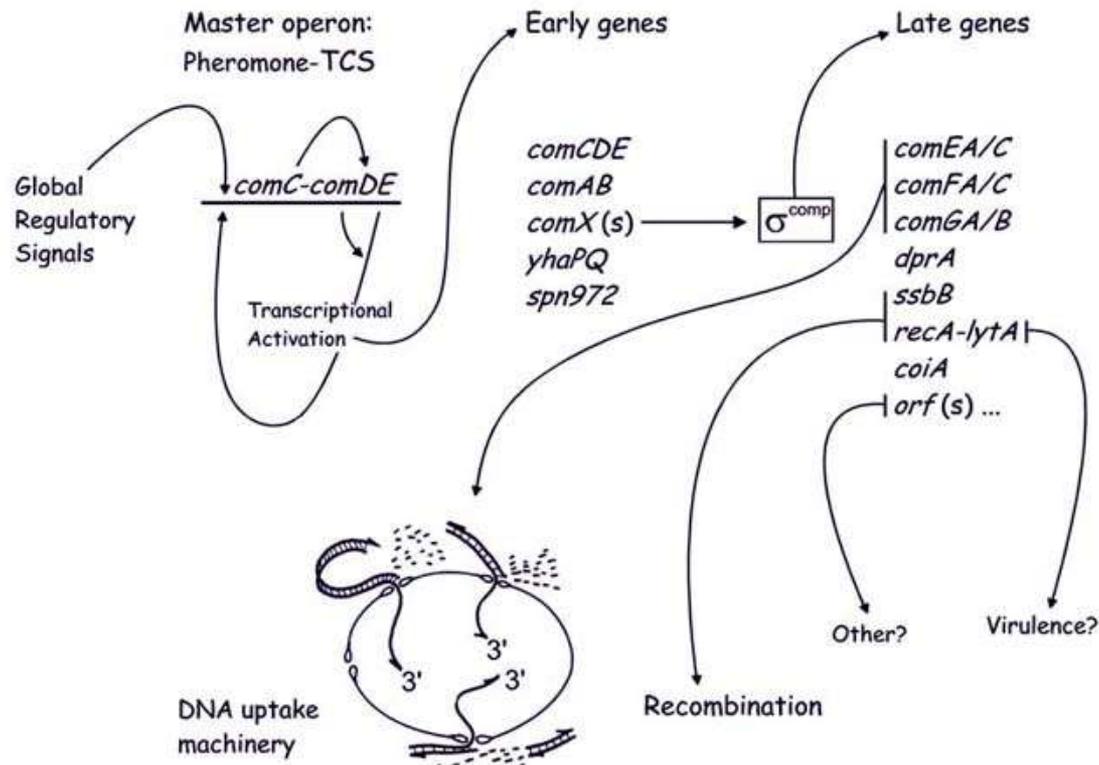


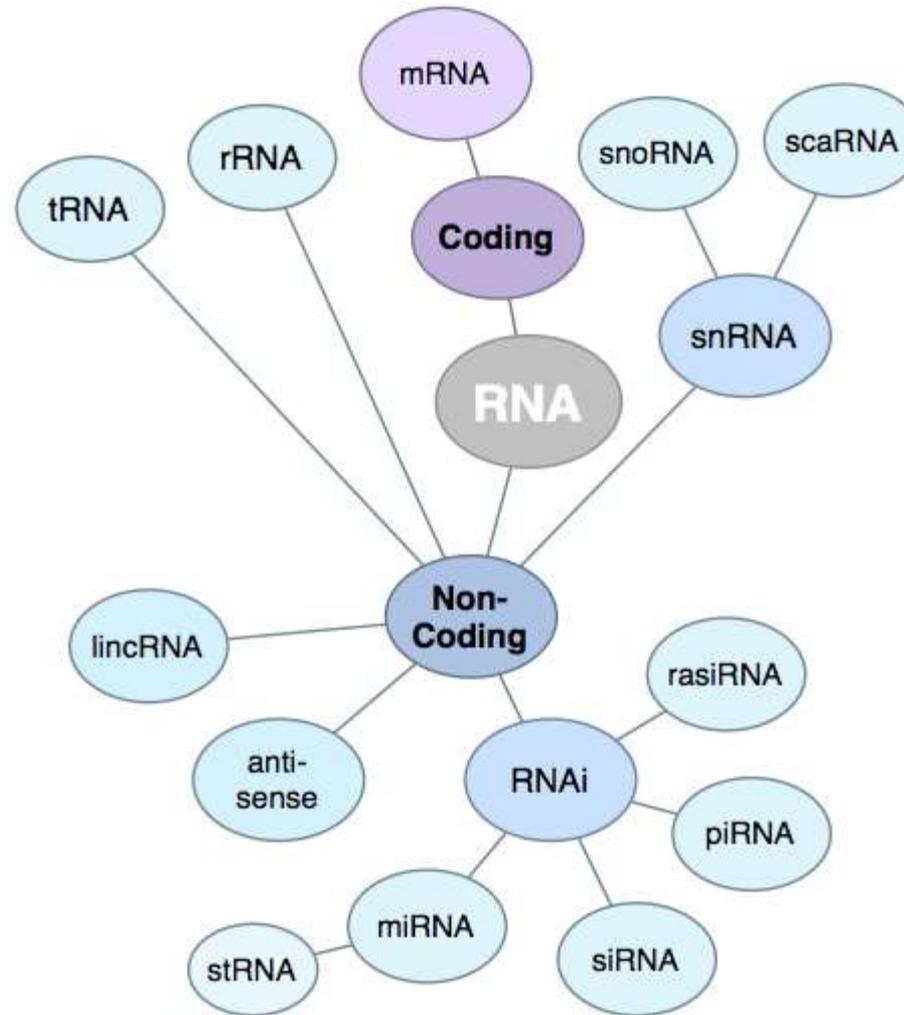
Réseaux de régulation

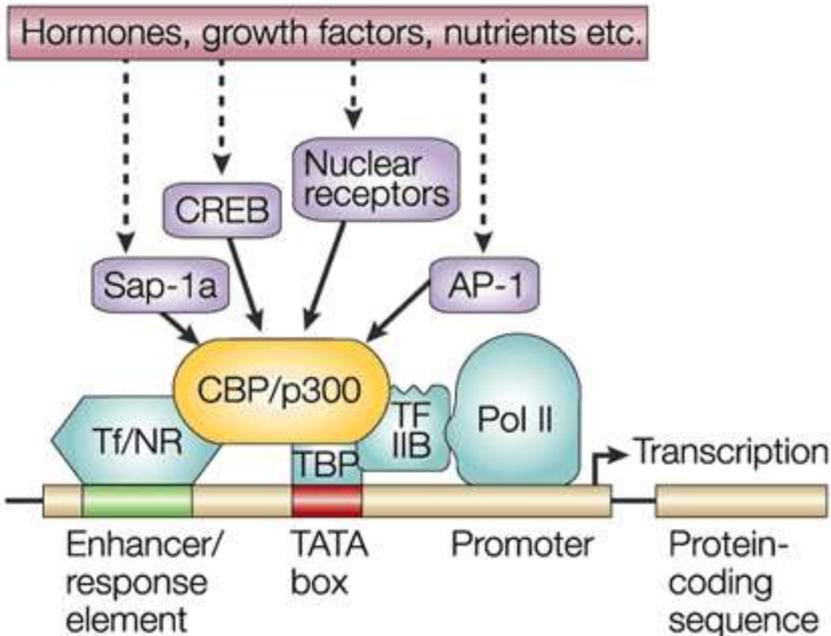
Master 1 MABS

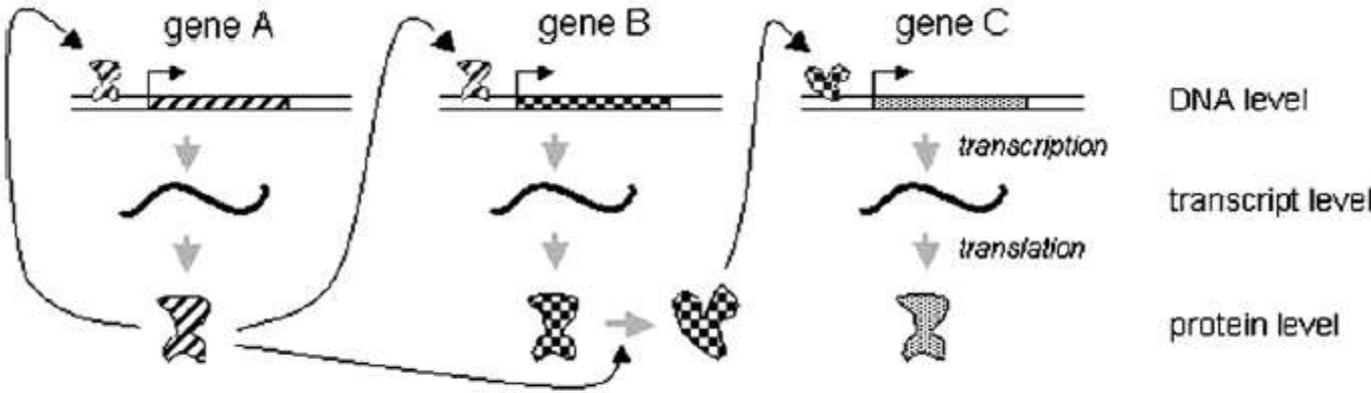


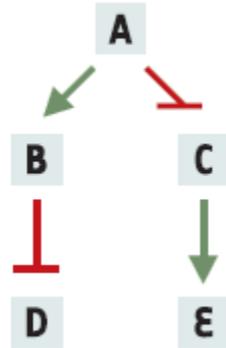
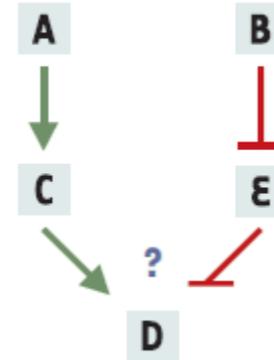
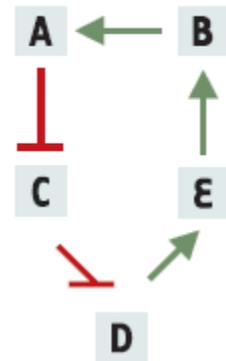
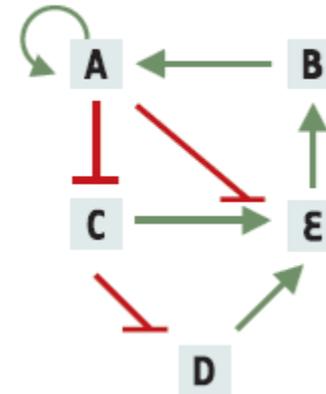
- Compréhension de propriétés du vivant conférées par les modalités d'expression du génome
- Expression
 - ◆ ARN codant et non codant
- Relation génotype/phénotype
 - ◆ et épigénétique : étude des changements, héritable au cours des divisions cellulaires, qui affectent la fonction des génomes sans altération de la séquence ADN.
- Phénomènes complexes :
 - ◆ différenciation
 - ◆ développement
 - ◆ vieillissement
 - ◆ adaptation
 - ◆ effet de l'environnement

RNA World

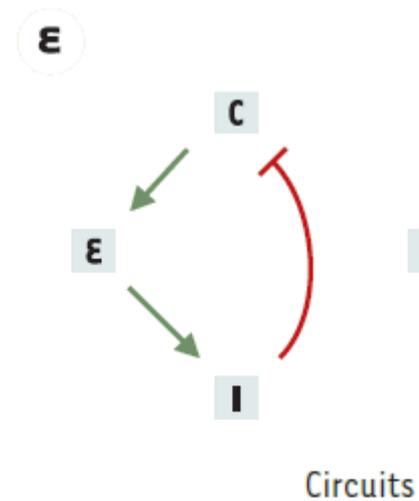
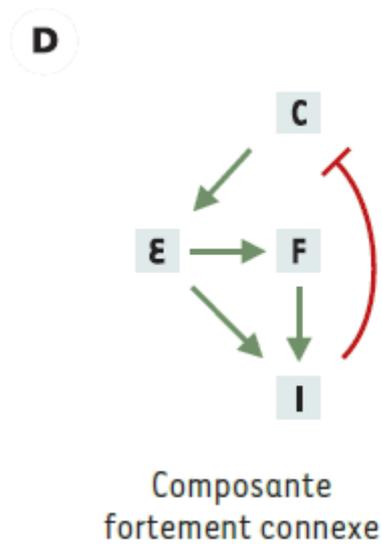
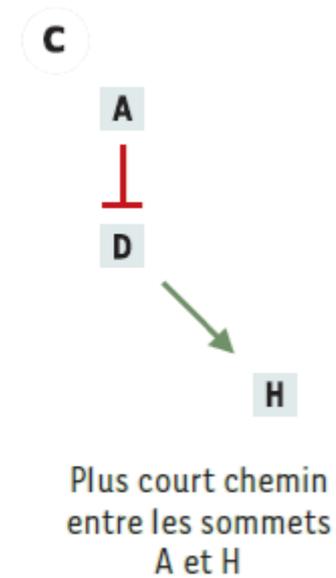
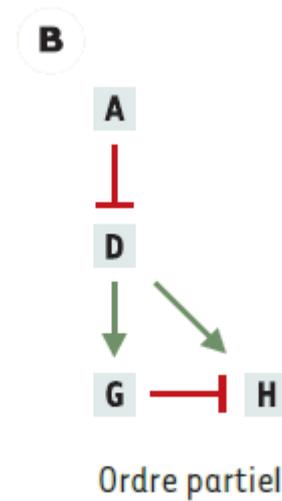
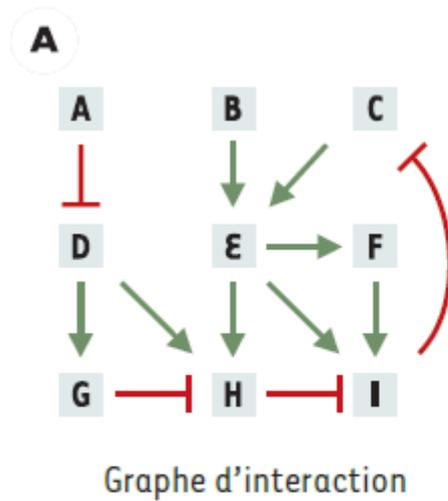




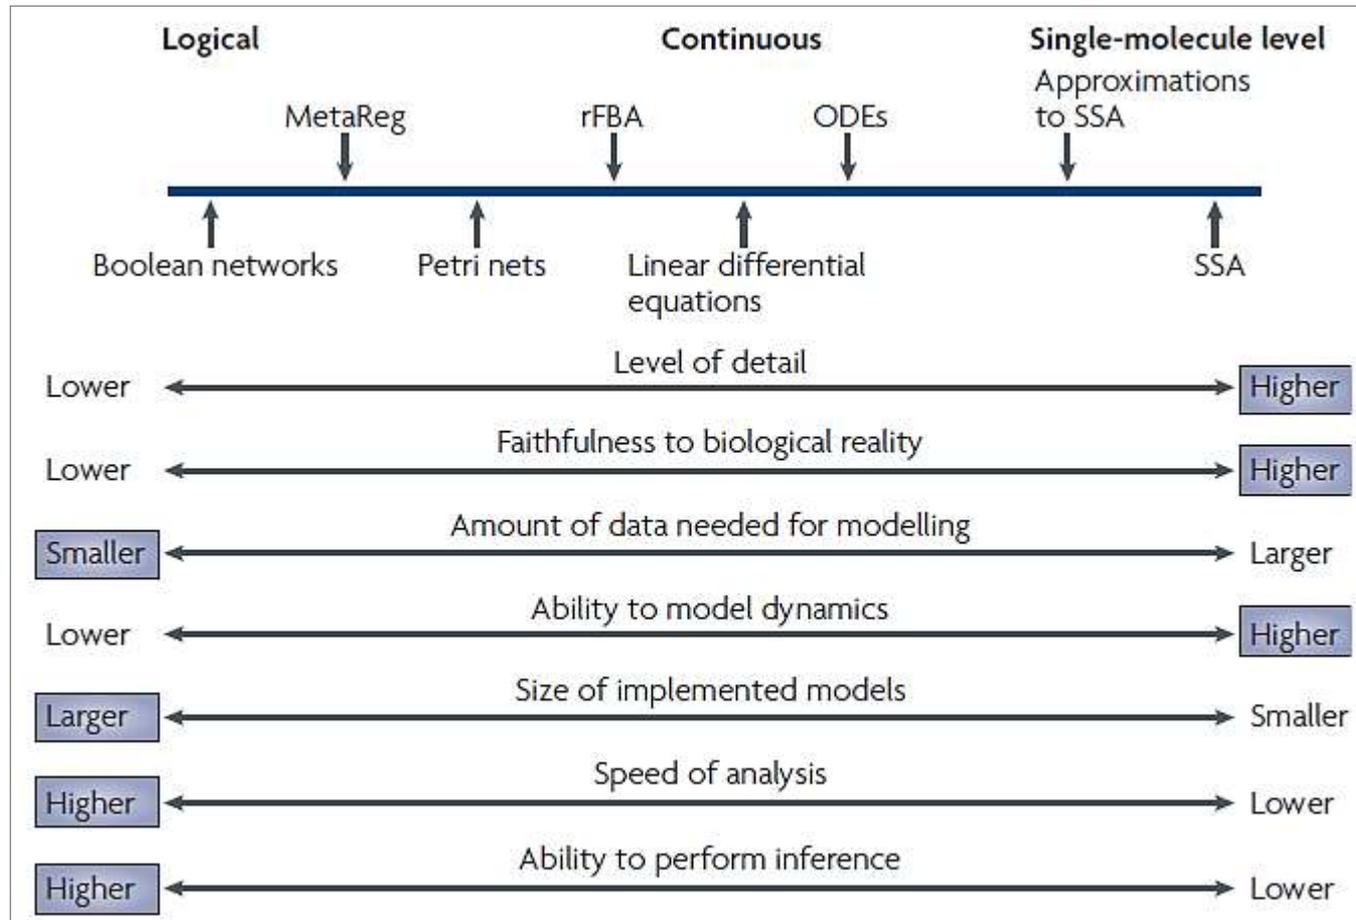


A**B****C****D****E**

Décomposition en modules

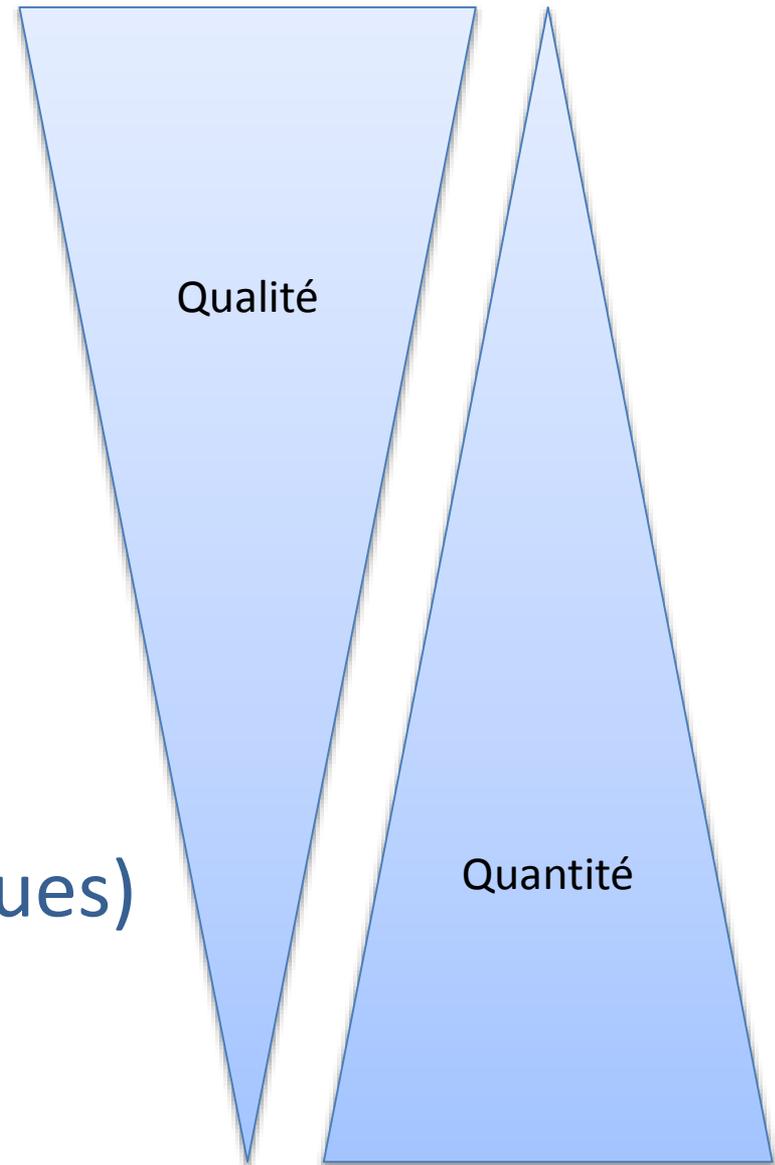


- Données d'expression
 - ◆ perturbations sur le phénomène d'intérêt
 - ◆ ensemble de conditions (>60) capturant un maximum de variations
- Données ChIP et ChIP-seq
 - ◆ localisation des sites de fixation des facteurs de transcription
- Facteurs de transcription connus
 - ◆ ex : RegulonDB, TransFac, JASPAR
- Prédiction de régions régulatrices
 - ◆ co-expression observée puis recherche des promoteurs
- Littérature et annotations

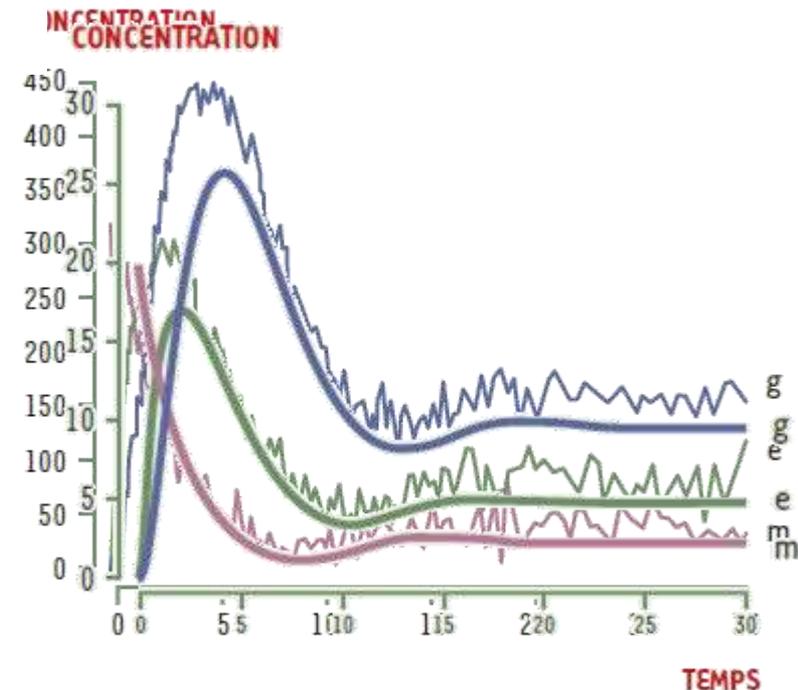
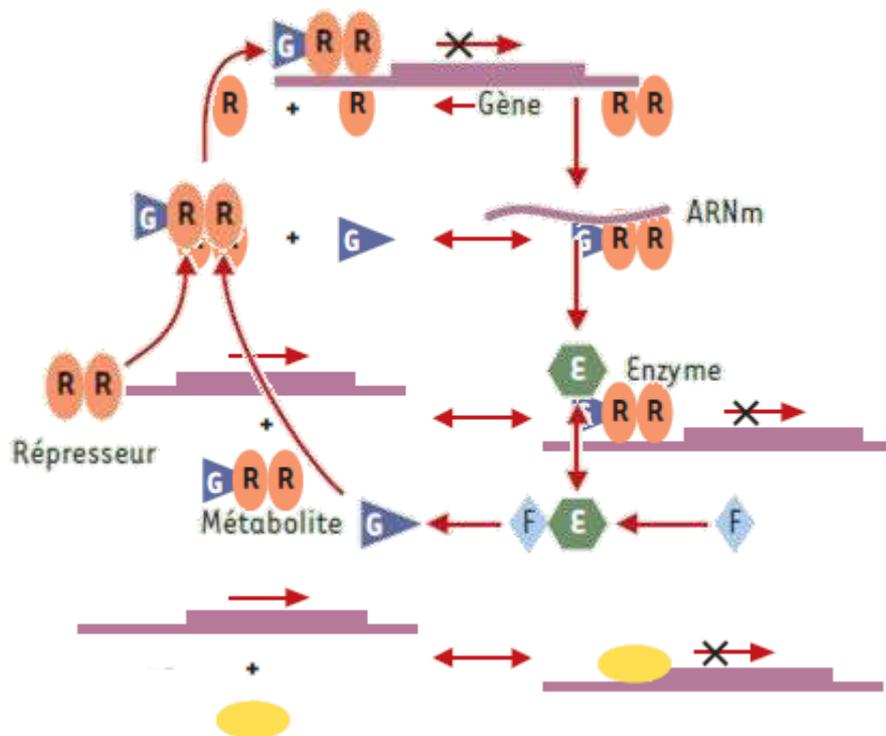


Karlebach and Shamir, 2008 *Nature reviews*

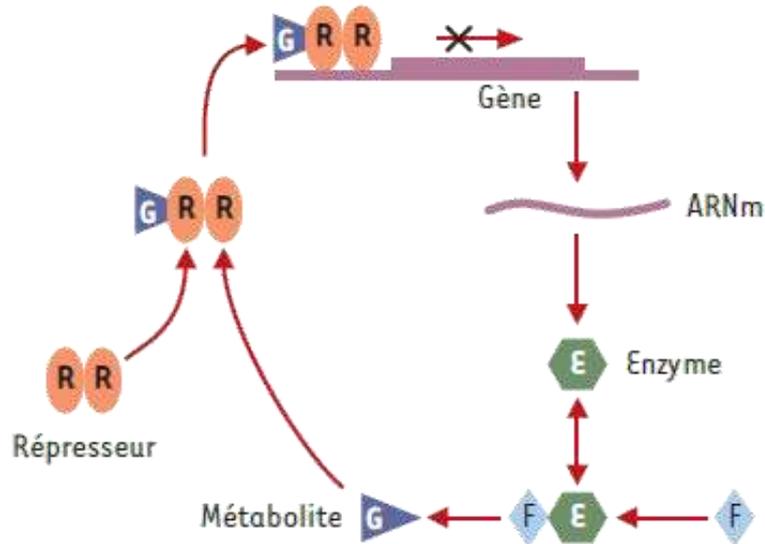
- Simulations stochastiques
- Systèmes d'équations
- Réseau de petri
- Réseaux booléens
- Réseaux bayésiens (dynamiques)
- Réseaux d'influence



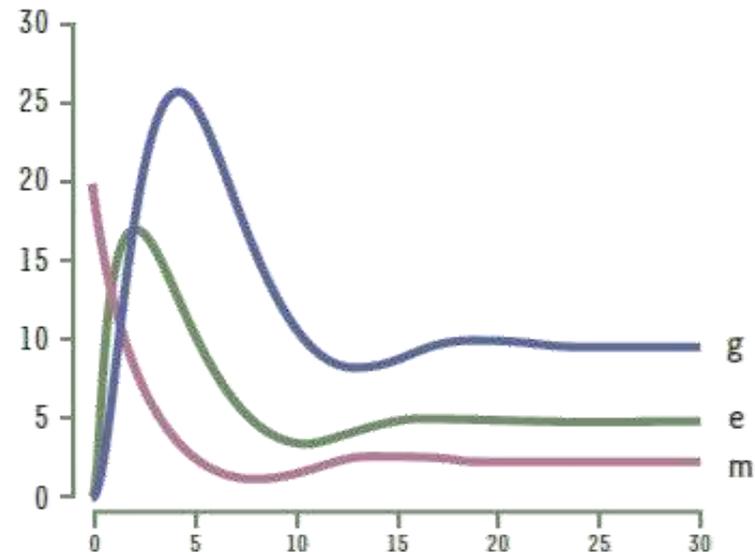
- Concentrations très faibles
- Probabilités associées aux réactions/transitions
- En général, trop complexe pour une solution analytique → simulations



- Concentrations/activités des molécules
- Vitesse de production, dégradation
- Constante de seuil, association, dissociation, coopération

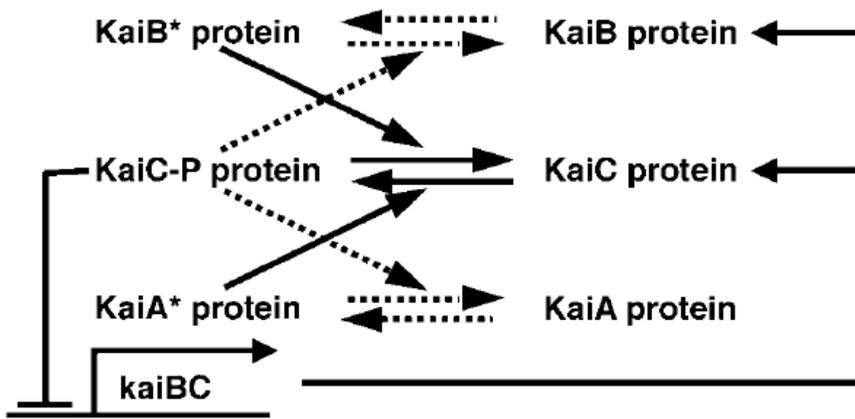


CONCENTRATION

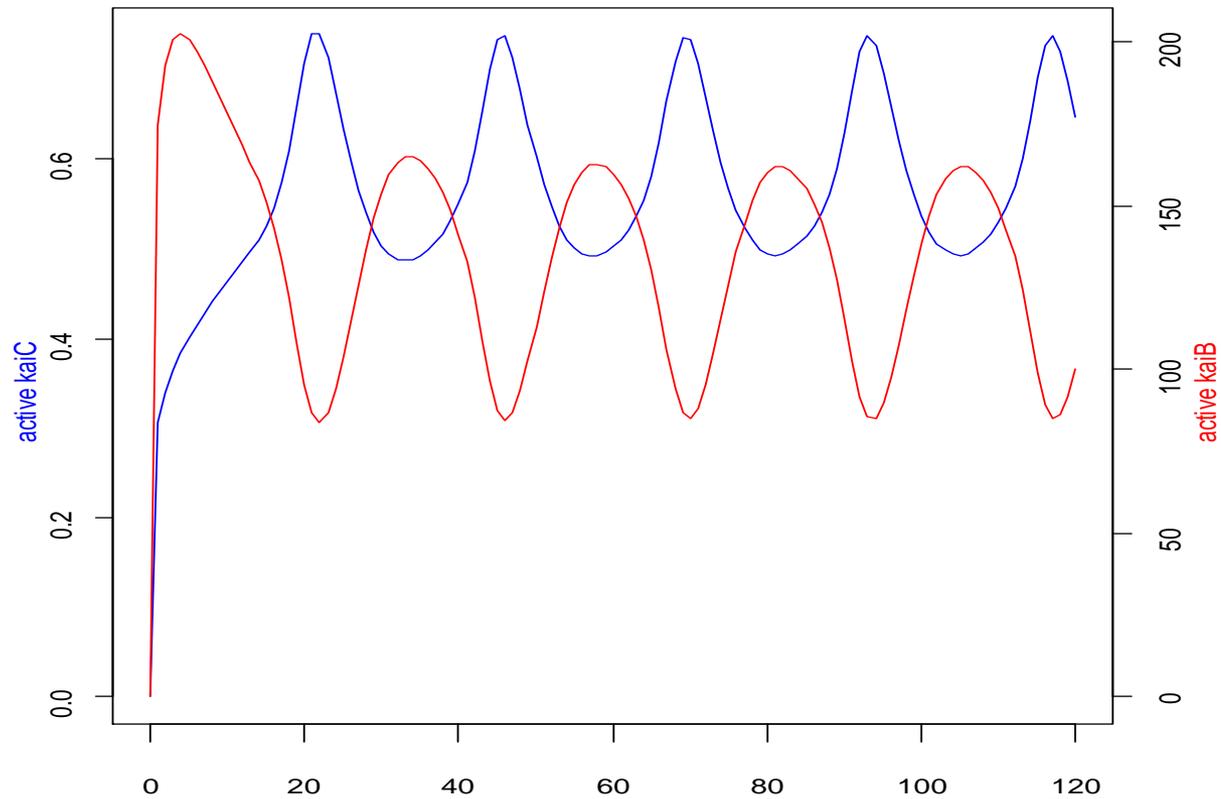


$$\frac{dm}{dt} = K_1 \frac{\theta^n}{\theta^n + g^n} - \gamma_1 m \quad \frac{de}{dt} = K_1 m - \gamma_2 e \quad \frac{dg}{dt} = K_3 e - \gamma_3 g$$

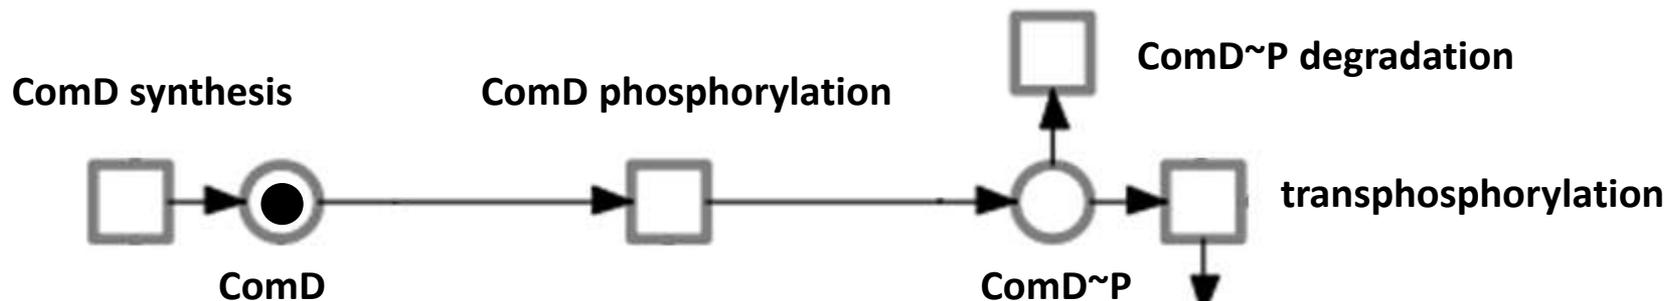
Exemple : oscillations circadiennes chez les cyanobactéries



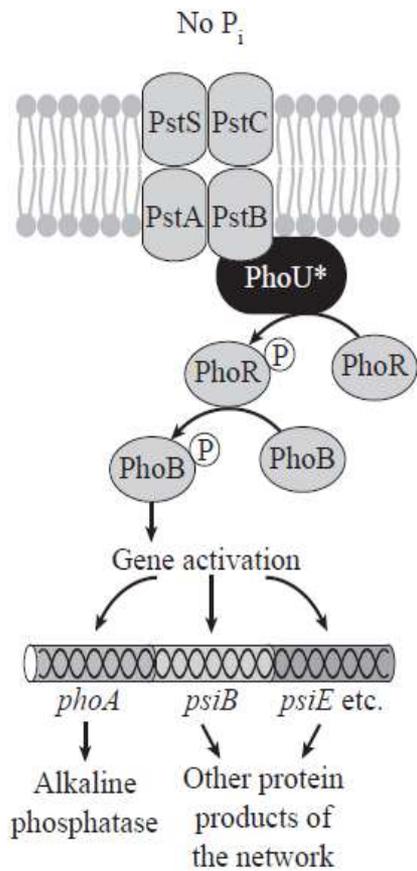
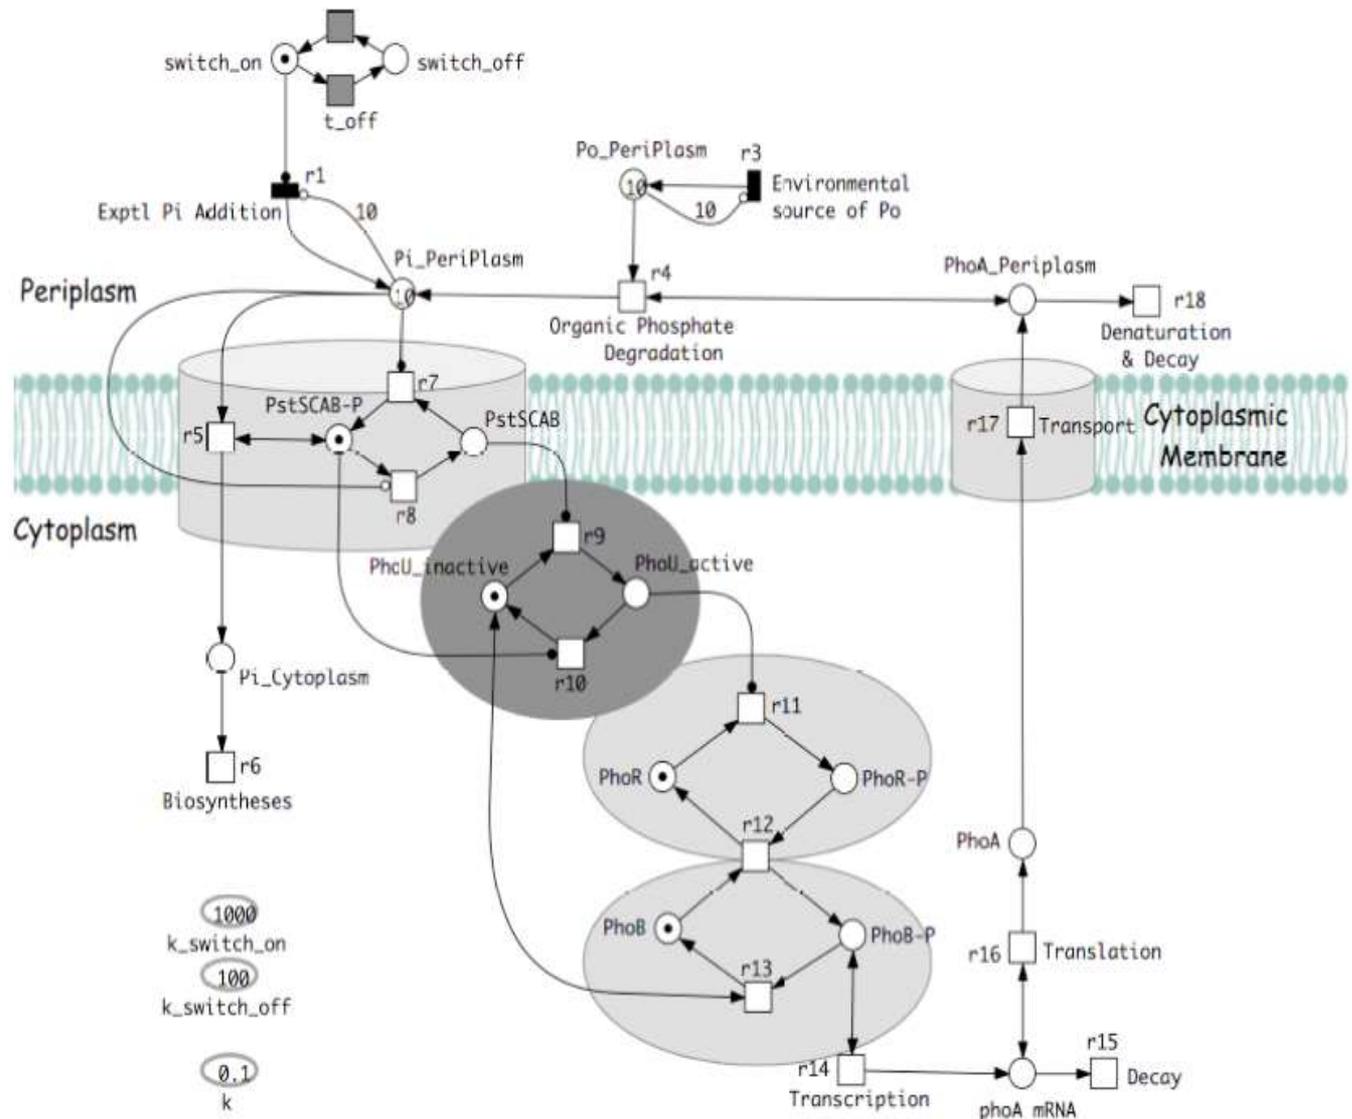
$$\begin{aligned} dx/dt &= pa(C_0s - x) - bx(y + f), \\ dy/dt &= g(B_0s - y) - k_1yx^n/(q^n + x^n), \\ dB/dt &= \varepsilon_1\{B_0\lambda/(1 + h_1x^m) - \mu B\}, \\ dC/dt &= \varepsilon_1\{C_0\lambda/(1 + h_1x^m) - \mu C\}. \end{aligned}$$



- Graphe biparti
 - ♦ Places : composés ou espèces moléculaires
 - ♦ Transitions : réactions
 - ♦ Jetons
- Différentes classes : colorés, stochastiques
- Permet
 - ♦ Analyse, propriétés du réseau
 - ♦ Simulations, prédiction



Réseau de petri

Neidhardt *et al.* 1990Durzinsky *et al.*, 2011

Synchrone

$(xy)_t$	$(xy)_{t+1}$
$\begin{matrix} + + \\ 0 0 \end{matrix}$	11
[01]	01
[10]	10
$\begin{matrix} - - \\ 1 1 \end{matrix}$	00

$$x_{t+1} = \bar{y}_t$$

$$y_{t+1} = \bar{x}_t$$

équations

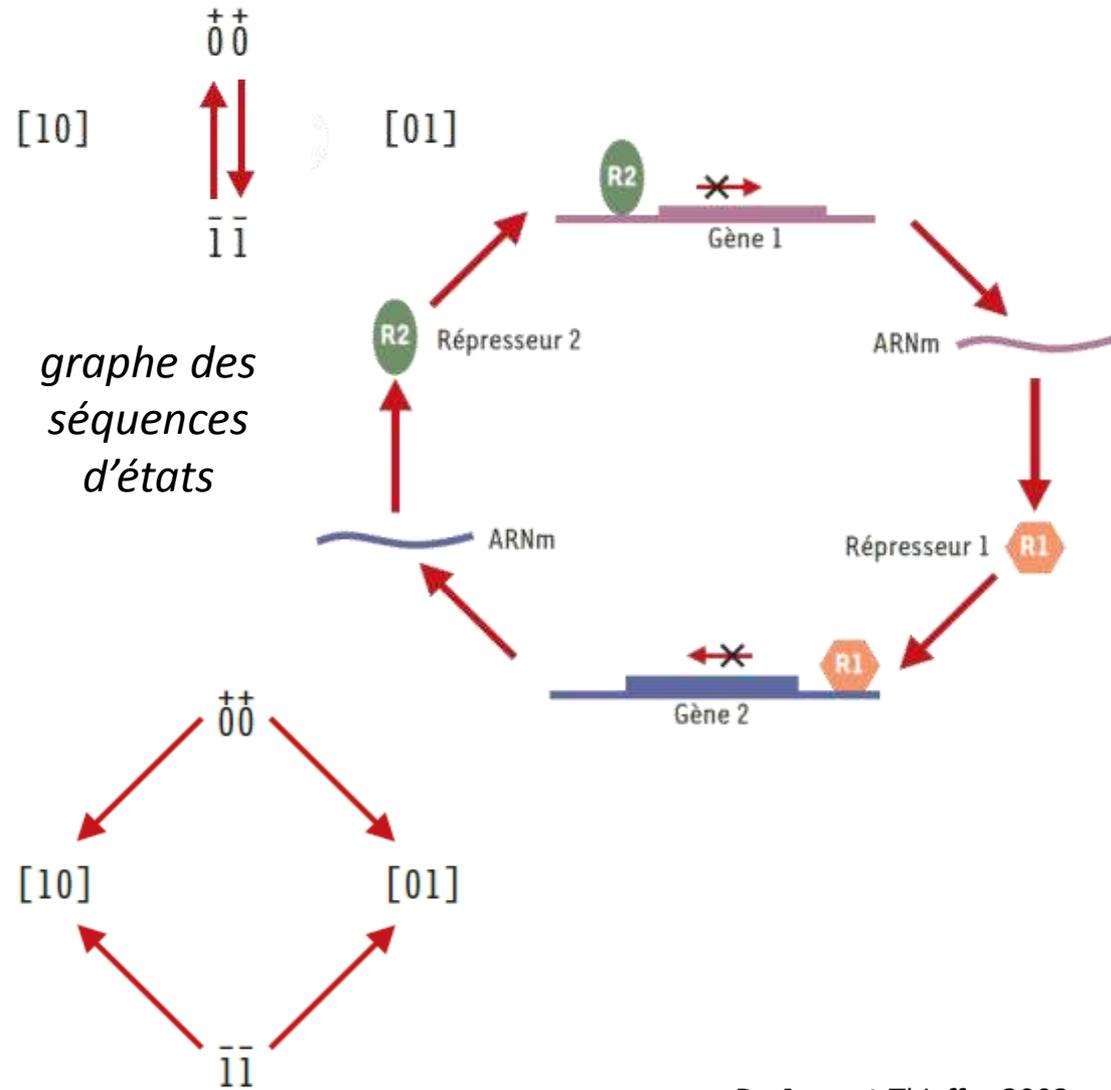
table des états

Asynchrone

xy	XY
$\begin{matrix} + + \\ 0 0 \end{matrix}$	11
[01]	01
[10]	10
$\begin{matrix} - - \\ 1 1 \end{matrix}$	00

$$x = \bar{y}$$

$$y = \bar{x}$$



- Théorème de Bayes

$$P(A|B) = \frac{P(B|A) P(A)}{P(B)}.$$

- ♦ $A = (a_1, a_2, \dots, a_n)$
- ♦ $B = (b_1, b_2, \dots, b_n)$
- ♦ Pas faisable avec des milliers de variables
- ♦ Hypothèse de l'indépendance **ou**
- ♦ prise en compte partielle par modèle réseau
 - modélisation de l'influence d'un facteur de transcription sur ces cibles



- Niveau d'expression de B dépend de celui de A (influence)
 - ♦ $P(B/A)$
- Le niveau d'expression de C
 - ♦ dépend de celui de B
 - ♦ est indépendant de celui de A sachant B

	cond1	cond2	cond3	cond4	cond5
A	off	low	high	low	low
B	off	low	high	high	low
C	off	off	low	high	low

observations



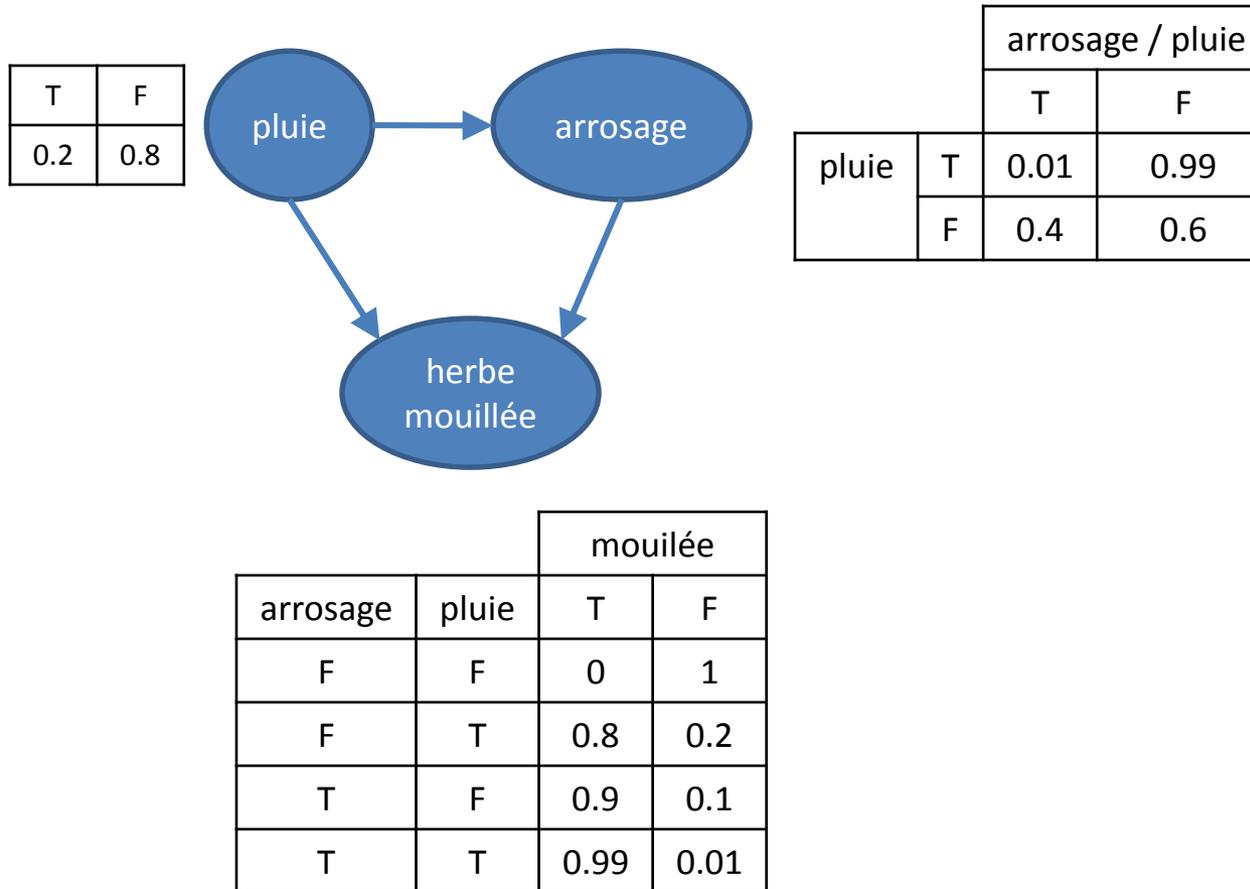
$P(B/A)$

B\A	off (1)	low (3)	high (1)
off	1/1	0/3	0/1
low	0/1	2/3	0/1
high	0/1	1/3	1/1



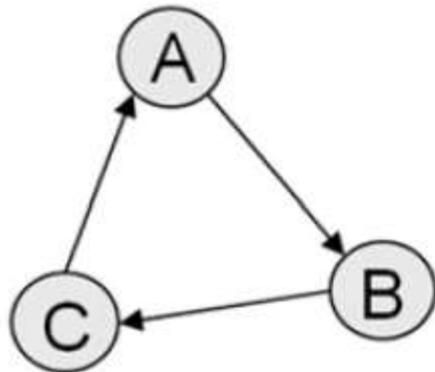
- Niveau d'expression de B dépend de celui de A (influence)
 - ♦ $P(B/A)$
- Le niveau d'expression de C
 - ♦ dépend de celui de B
 - ♦ est indépendant de celui de A sachant B
- Avantages :
 - ♦ capture l'aspect stochastique de la régulation
 - ♦ possibilité d'intégrer des régulations connues
 - ♦ peu de sur-apprentissage et robustesse
 - ♦ quantitatif (niveau d'expression) ou qualitatif (on/off)
- Inconvénient : Pas de cycle donc pas de boucle d'auto-régulation

Réseaux bayésiens : illustration



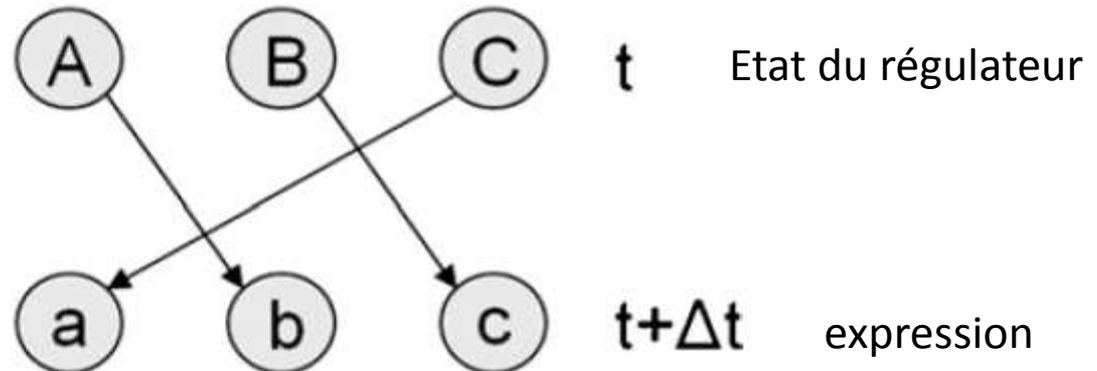
- Information temporelle (temps discret)
 - ◆ variable indicée par son pas de temps
 - ◆ distribution des probabilités d'une variable dépend de l'état de ses prédécesseurs au pas de temps précédent

Static BN

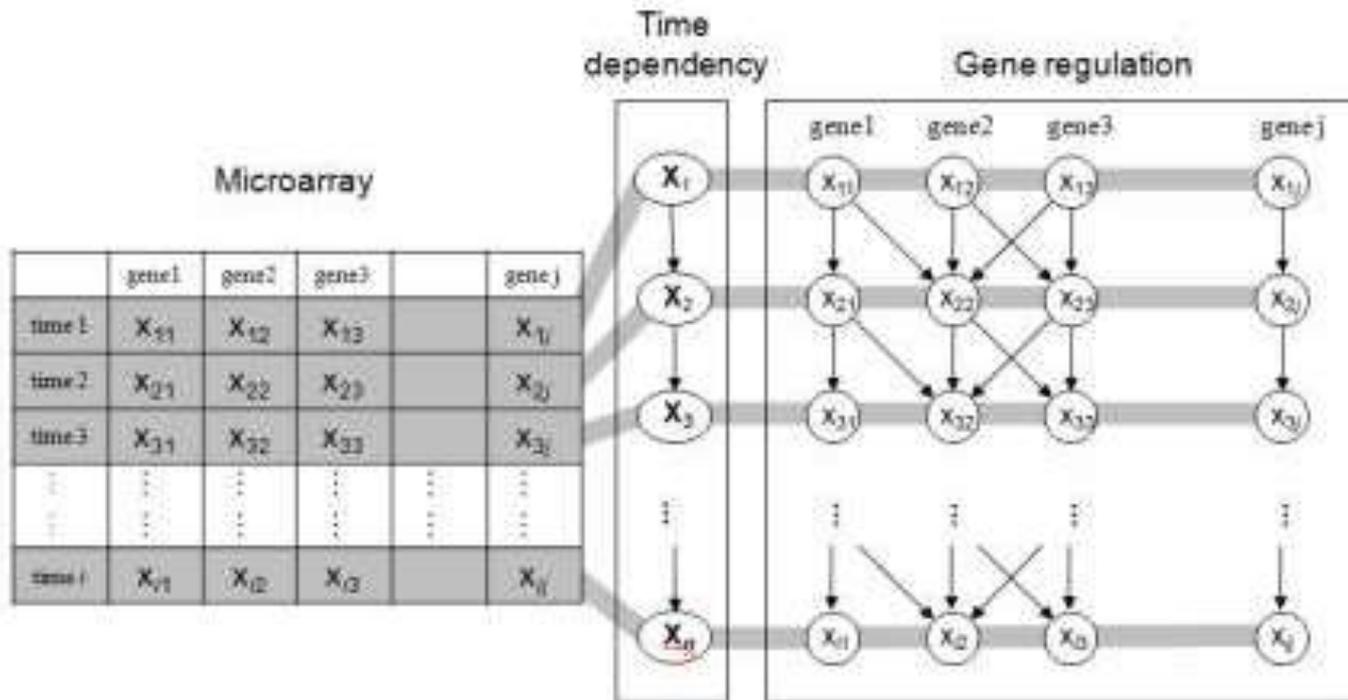
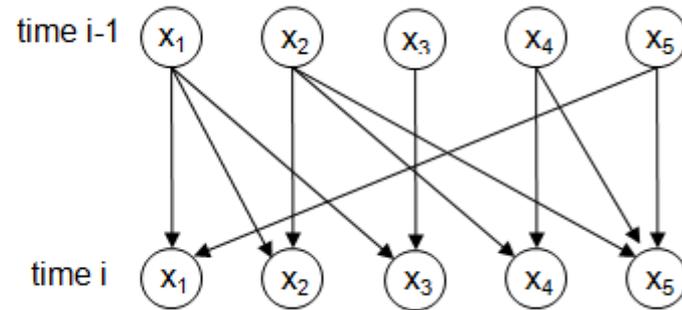
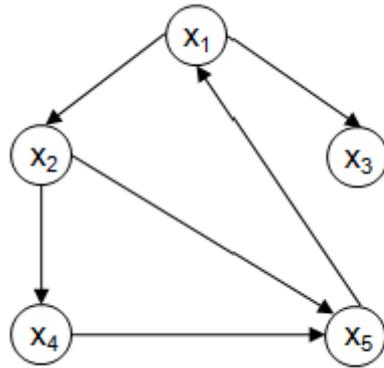


Not allowed !

Dynamic BN



Réseaux bayésiens dynamiques

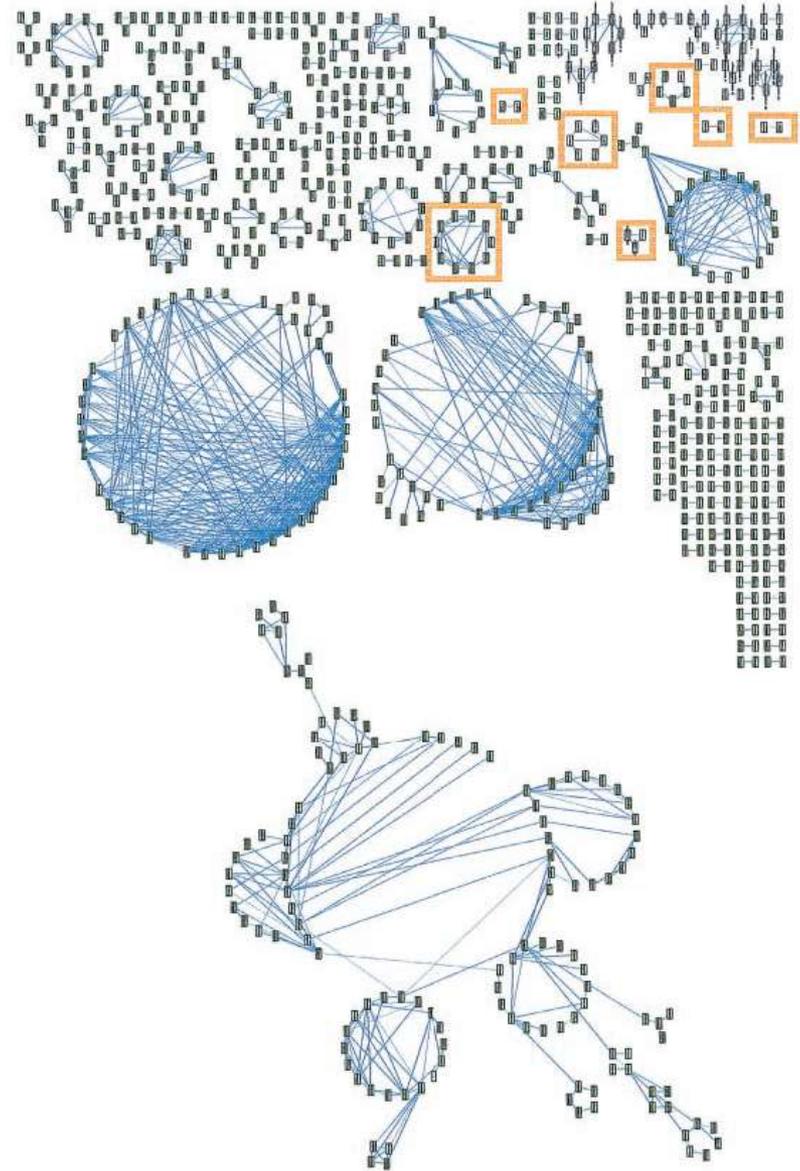


- Adéquation entre observations et modèle
- Généralement en 3 étapes :
 - ◆ inférence de(s) la structure
 - ◆ détermination des paramètres
 - ◆ sélection du meilleur modèle
- Optimisation
 - ◆ de la structure ($2^n - 1$ connexions pour chaque sommet, BIC)
 - feature selection : considérer uniquement les gènes différentiellement exprimés
 - feature mapping : agréger les ensembles tels que les opérons ou les gènes co-exprimés impliqués dans un même processus biologique
 - ◆ des paramètres : fonction de score
 - moindres carrés
 - maximum de vraisemblance
- Contraintes et incorporation de connaissances

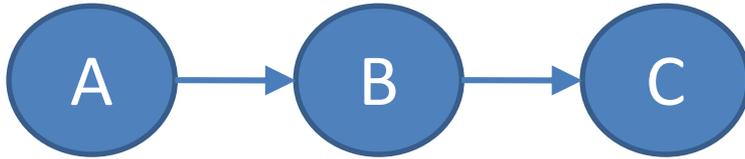
- Mesure de similarité entre profils
 - ◆ Basée sur la corrélation entre l'activité de 2 éléments

$$\hat{r}^2 = \frac{r}{abs(r)} r^2$$

- ◆ seuil pour l'inférence d'un lien entre les éléments



- Information Mutuelle



$$I(X; Y) = \sum_{i,j} P(x_i, y_j) \log \frac{p(x_i, y_j)}{p(x_i)p(y_j)}$$

observations

	cond1	cond2	cond3	cond4	cond5
A	high	low	high	low	low
B	high	low	high	high	low

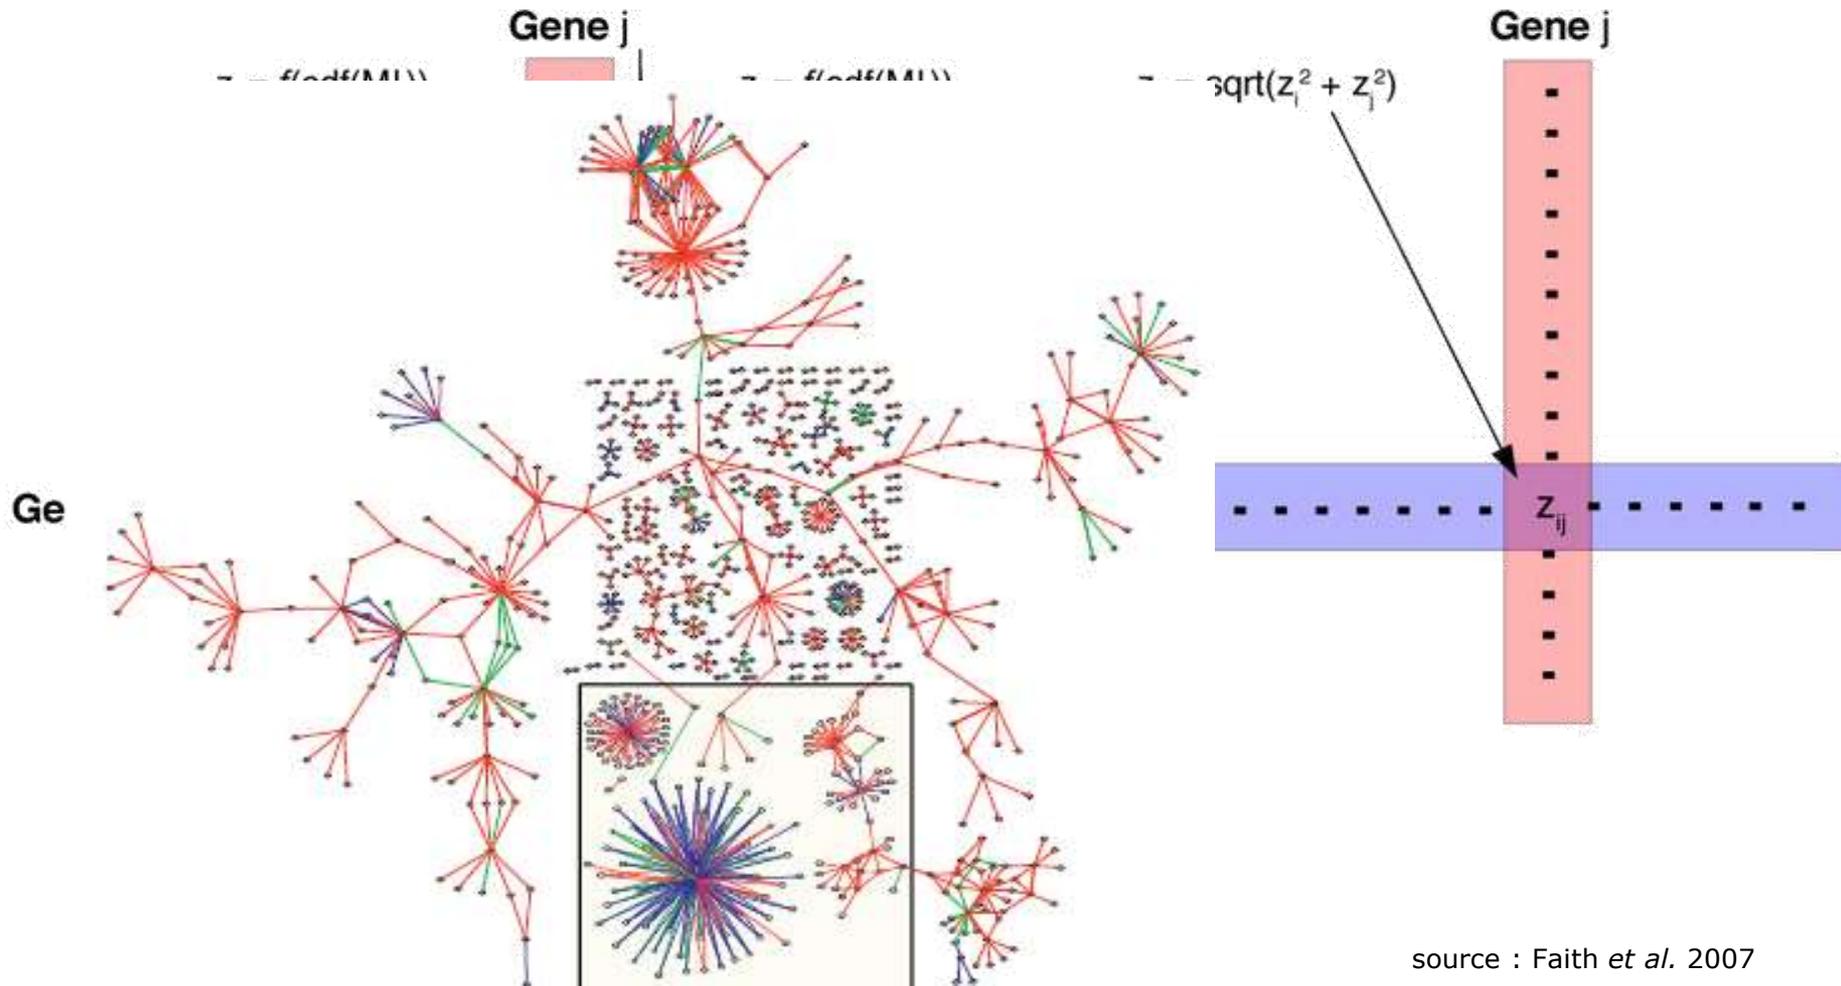
	B = low	B = high	total
A = low	2 / 5	1 / 5	3 / 5
A = high	0	2 / 5	2 / 5
total	2 / 5	3 / 5	1

$$\begin{aligned}
 & \text{ab} \quad \text{ab} \quad \text{a b} \quad \text{aB} \quad \text{aB} \quad \text{a B} \quad \text{Ab} \quad \text{AB} \quad \text{AB} \quad \text{A B} \\
 & > .4 * \log(.4 / (.6*.4)) + .2 * \log(.2 / (.6*.6)) + 0 + .4 * \log(.4 / (.4*.6)) \\
 & [1] 0.2911032
 \end{aligned}$$

- Information Mutuelle

$$I(X; Y) = \sum_{i,j} P(x_i, y_j) \log \frac{p(x_i, y_j)}{p(x_i)p(y_j)}$$

- Context Likelihood Ration (CLR)



BMC Bioinformatics



Proceedings

Open Access

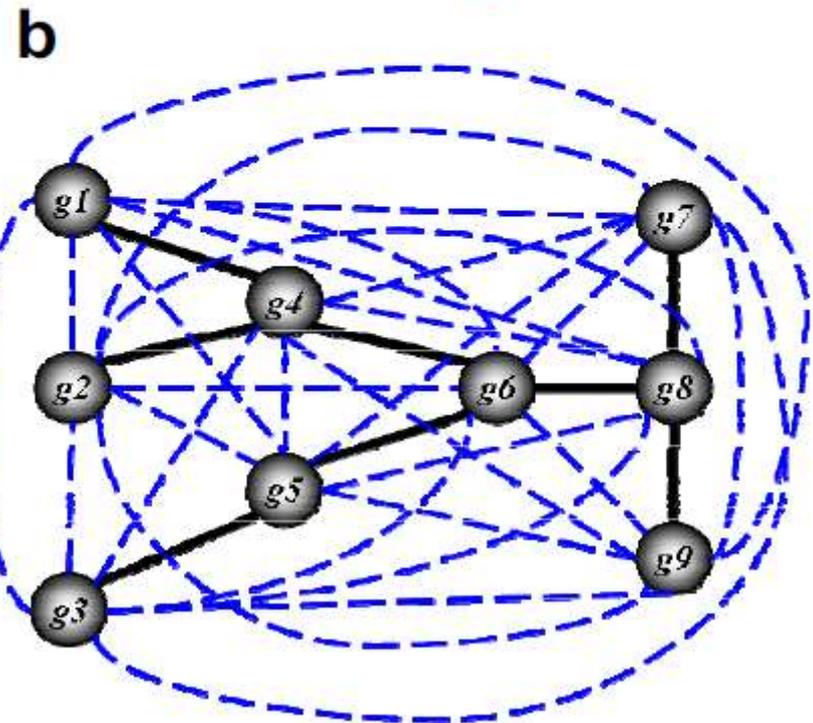
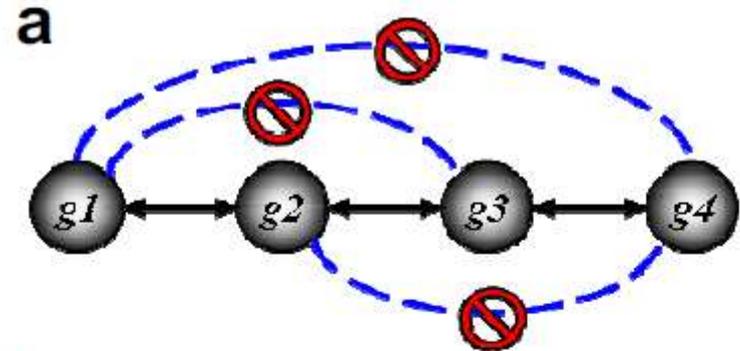
ARACNE: An Algorithm for the Reconstruction of Gene Regulatory Networks in a Mammalian Cellular Context

Adam A Margolin^{1,2}, Ilya Nemenman², Katia Basso³, Chris Wiggins^{2,4}, Gustavo Stolovitzky⁵, Riccardo Dalla Favera³ and Andrea Califano^{*1,2}

Data Processing Inequality

The DPI (Figure 2) [14] states that if genes g_1 and g_3 interact only through a third gene, g_2 , (i.e., if the interaction network is $g_1 \leftrightarrow \dots \leftrightarrow g_2 \leftrightarrow \dots \leftrightarrow g_3$ and no alternative path exists between g_1 and g_3), then

$$I(g_1, g_3) \leq \min [I(g_1, g_2); I(g_2, g_3)]. \quad (3)$$



- Apprentissage supervisé de la fonction de V variables

- La première variable sélectionnée est telle que $I(X_i, Y)$ est maximum (maximum relevance)

- La seconde variable sélectionnée est telle que $I(X_j, Y) - I(X_j, X_i)$ est maximum (minimum redundancy).

- Les suivantes telles que

$$I(X_k, Y) - \frac{1}{|S|} \sum_{X_i \in S} I(X_k, X_i)$$

est maximum

Information-Theoretic Inference of Large Transcriptional Regulatory Networks

Patrick E. Meyer III, Kevin Konios, Frederic Lafitte and Gianluca Bontempi

EURASIP Journal on Bioinformatics and Systems Biology 2007, 2007:73679 | DOI: 10.1155/2007/73679 | © Patrick E. Meyer et al. 2007
Received: 25 January 2007 | Accepted: 12 May 2007 | Published: 24 June 2007

Abstract

The paper presents MRNET, an original method for inferring genetic networks from microarray data. The method is based on maximum relevance/minimum redundancy (MRMR), an effective information-theoretic technique for feature selection in supervised learning. The MRMR principle consists in selecting among the least redundant variables the ones that have the highest mutual information with the target. MRNET extends this feature selection principle to networks in order to infer gene-dependence relationships from microarray data. The paper assesses MRNET by benchmarking it against RELNET, CLR, and ARACNE, three state-of-the-art information-theoretic methods for large (up to several thousands of genes) network inference. Experimental results on thirty synthetically generated microarray datasets show that MRNET is competitive with these methods.

- Apprentissage supervisé : on cherche à prédire une sortie Y en fonction de V variables en entrée.
- Utilisation de forêts aléatoires (GENIE3) avec un tirage aléatoire des variables en entrée qui dépend d'autres sources de données (iRafNet)

OPEN ACCESS Freely available online

PLoS one

Inferring Regulatory Networks from Expression Data Using Tree-Based Methods

Vân Anh Huynh-Thu^{1,2*}, Alexandre Irrthum^{1,2}, Louis Wehenkel^{1,2}, Pierre Geurts^{1,2}

¹ Department of Electrical Engineering and Computer Science, Systems and Modeling, University of Liège, Liège, Belgium, ² GIGA-Research, Bioinformatics and Modeling, University of Liège, Liège, Belgium

Bioinformatics, 31, 2015, i197–i205

doi: 10.1093/bioinformatics/btv268

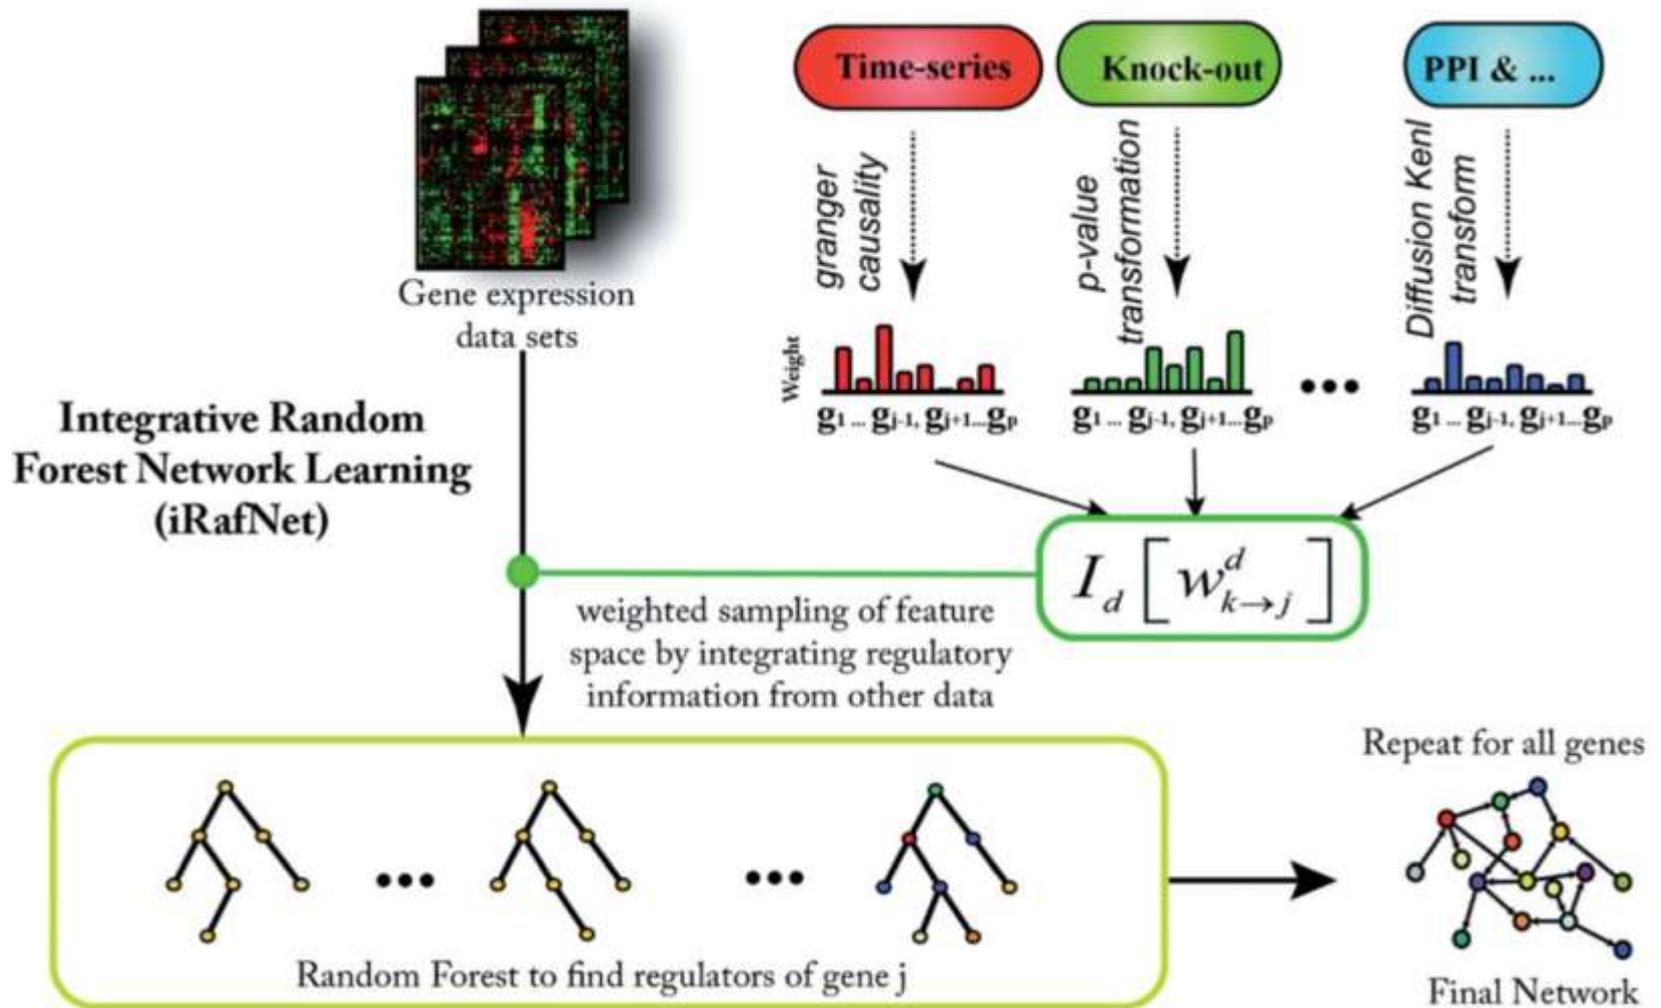
ISMB/ECCB 2015

Integrative random forest for gene regulatory network inference

Francesca Petralia, Pei Wang, Jialiang Yang and Zhidong Tu*

Department of Genetics and Genomic Sciences, Icahn School of Medicine at Mount Sinai, New York, NY 10029, USA

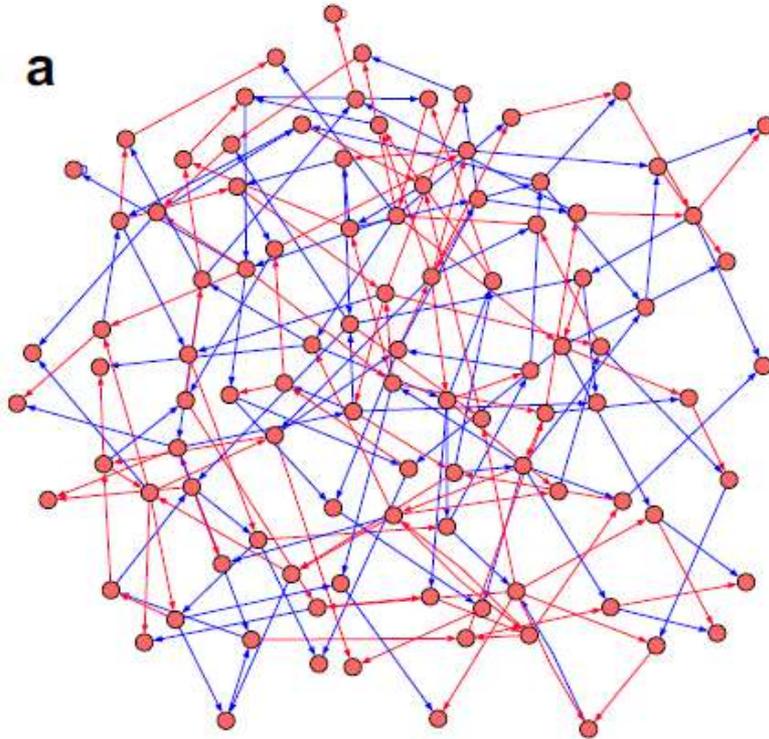
iRafNet schematics.



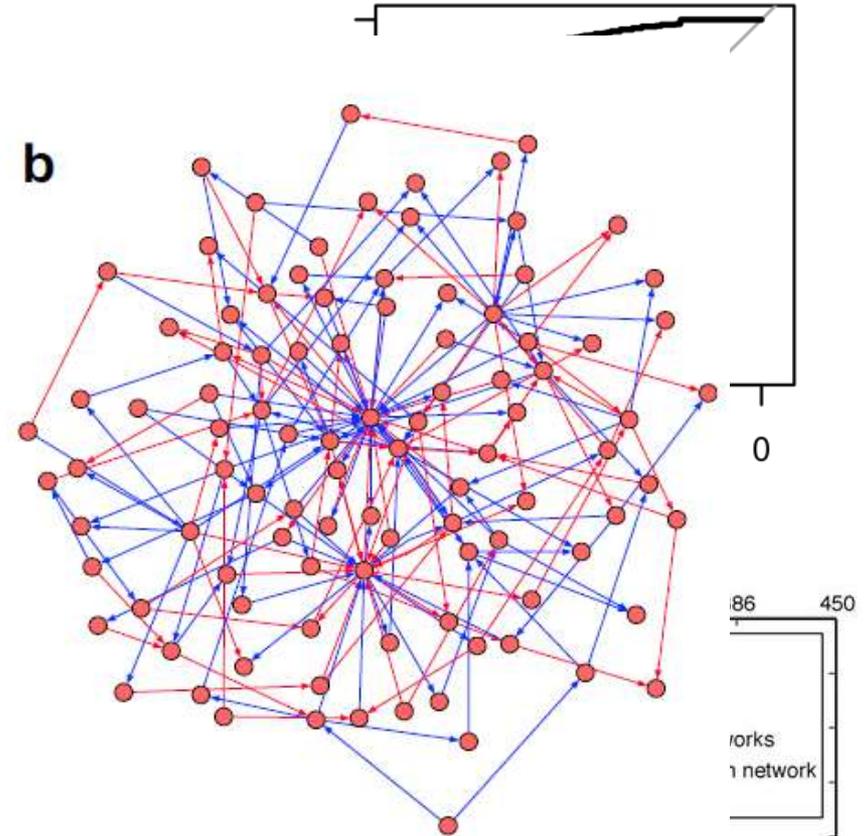
Francesca Petralia et al. *Bioinformatics* 2015;31:i197-i205

- Besoin d'un jeu de données de référence

a

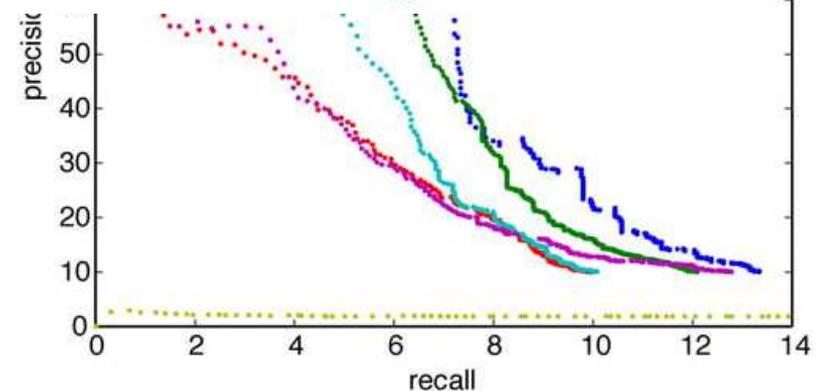


b

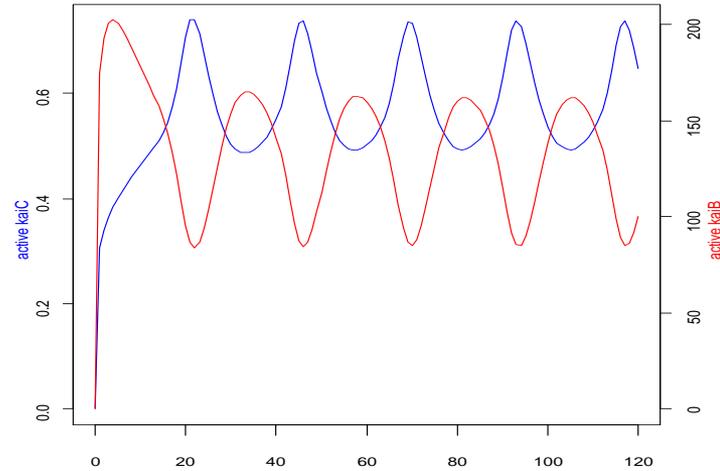


• T
T
li

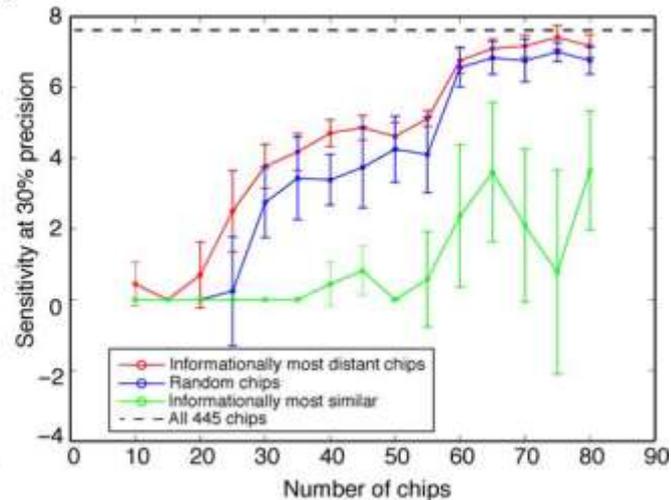
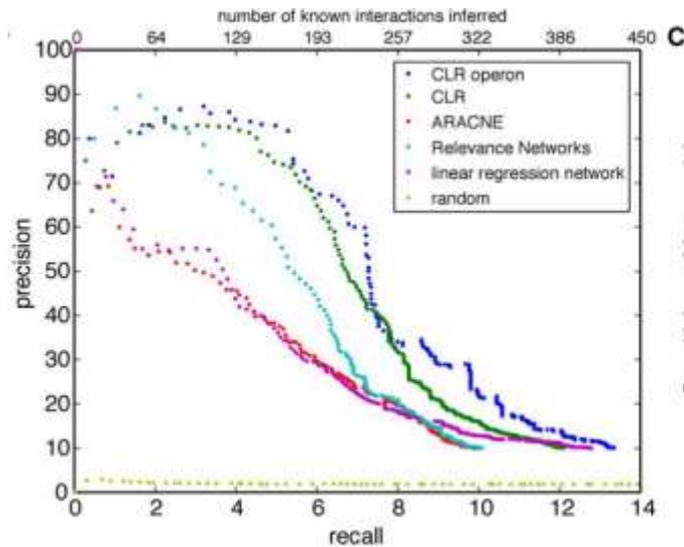
- ◆ Precision = $IP / (IP+FP)$
- ◆ Spécificité = $TN / (TN+FP)$
- ◆ FPR = 1 - spécificité
- ◆ FDR = 1 - précision



- Validation d'un modèle, d'un comportement observé



- Simulation et prédiction



Controls

A
LexA

	p-value	Motif location
recN	4.4e-09	
yebG	6.4e-10	
lexA	8.3e-10	
uvrA	1e-08	
sulA	1.7e-08	
dinI	2e-08	
dinP	4.4e-08	
recA	6.5e-08	
SCALE		1 25 50 75 100 125

The known motif is found in
8 out of 13 promoters

Putative novel regulons

C
YnaE

	p-value	Motif location
cspB	3.9e-10	
cspG	6.3e-09	
b1374_s	1.1e-08	
cspH	3.7e-08	
b1459	2.9e-07	
rhsE	6.1e-07	
SCALE		1 25 50 75 100 125

A conserved motif is found in
6 out of 8 promoters