



# Optimisation convexe pour l'apprentissage de réseaux de régulation de gènes

Magali Champion

Sébastien Gadat, Christine Cierco-Ayrolles et Matthieu Vignes

12 septembre 2013

Introduction

Régression  
linéaire

Modèle I

Résultats de stabilité

Problème  
d'optimisation

Modèle II

Procédure  
d'optimisation

Minimisation alternée

Relaxation convexe ?

Autre  
approche

- 1 Introduction
- 2 Régression linéaire
  - Modèle I
  - Résultats de stabilité
- 3 Problème d'optimisation
  - Modèle II
  - Procédure d'optimisation
  - Minimisation alternée
  - Relaxation convexe ?
- 4 Autre approche

# Introduction biologique...

## Introduction

### Régression linéaire

Modèle I

Résultats de stabilité

### Problème d'optimisation

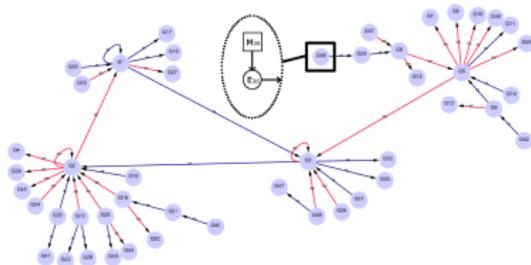
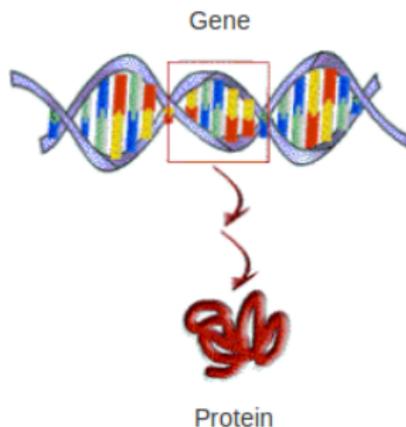
Modèle II

Procédure  
d'optimisation

Minimisation alternée

Relaxation convexe ?

### Autre approche



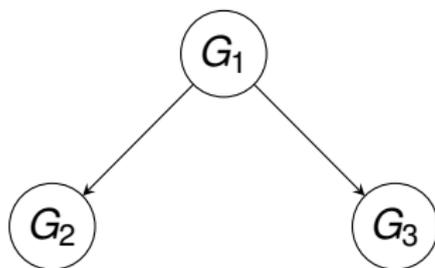
**Objectif : Reconstruire le réseau de régulation de gènes**

$\mathcal{G} = (V, E)$  défini par :

- un noeud  $i \in V$  est l'un des  $p$  gènes considérés
- une arête  $(i, j) \in E$  représente une interaction entre le gène  $i$  et le gène  $j$ .

## ... et statistique

- $p$  gènes étudiés, pour lesquels on connaît les données d'expression,
- échantillon de taille  $n$ .



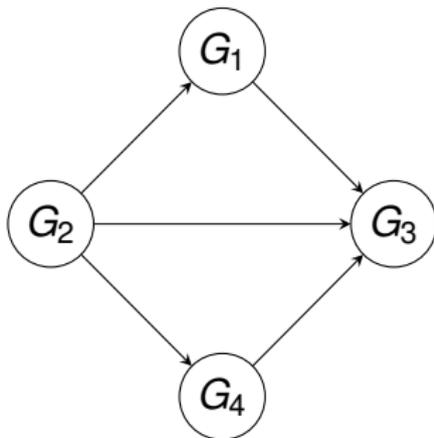
**Objectif :** Reconstruire le réseau de régulation de gènes  $\mathcal{G} = (V, E)$  défini par :

- un nœud  $i \in V$  est l'un des  $p$  gènes considérés
- une arête  $(i, j) \in E$  représente une interaction entre le gène  $i$  et le gène  $j$ .

## Modèle I

La première idée consiste à considérer à tour de rôle chacun des gènes  $G_j$  comme une observation dépendant de variables explicatives (les autres gènes).

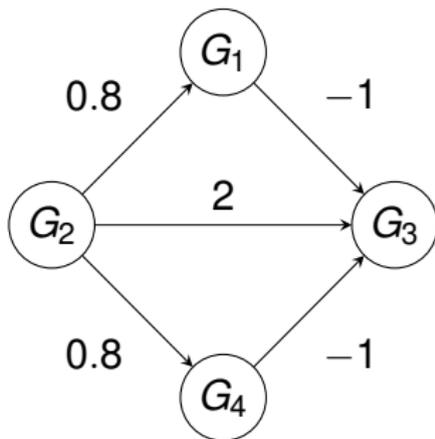
$$\forall 1 \leq j \leq p, \quad G_j = \sum_{1 \leq i \neq j \leq p} G_i + \varepsilon.$$



## Modèle I

La première idée consiste à considérer à tour de rôle chacun des gènes  $G_j$  comme une observation dépendant de variables explicatives (les autres gènes).

$$\forall 1 \leq j \leq p, \quad G_j = \sum_{1 \leq i \neq j \leq p} \theta_i^j G_i + \varepsilon.$$



$\Theta = (\theta^1, \dots, \theta^p)$  est la matrice d'adjacence associée au graphe  $\mathcal{G}$ .

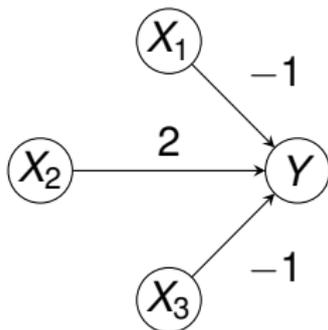
$$\Theta = \begin{pmatrix} 0 & 0 & -1 & 0 \\ 0.8 & 0 & 2 & 0.8 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & -1 & 0 \end{pmatrix}$$

# Régression linéaire et boosting

On peut réécrire ce modèle sous la forme :

$$Y = X\theta + \varepsilon.$$

→ Utilisation de méthodes classiques de régression du type lasso, elastic net...



Les algorithmes de type boosting permettent de construire une approximation globale de  $f(X) = X\theta$  à l'aide d'approximations locales.

---

**Algorithm 1:** Algorithme  $\mathbb{L}_2$ -Boosting

---

**Input:** Observations  $(X_i, Y_i)_{1 \leq i \leq n}$ ,  $\gamma \in ]0, 1]$  et  $k_{up} \in \mathbb{N}^*$

**Output:**  $\hat{G}_{k_{up}}(f)$

*Initialization* :  $\hat{G}_0(f) = 0$ .

**for**  $k = 1$  **to**  $k_{up}$  **do**

① Choisir  $\varphi_k \in (X_1, \dots, X_{p-1})$  tel que

$$|\langle Y - \hat{G}_{k-1}(f), \varphi_k \rangle_n| = \max_{1 \leq i \leq p-1} |\langle Y - \hat{G}_{k-1}(f), X_i \rangle_n|,$$

$$\text{où } \langle h_1, h_2 \rangle_n = \frac{1}{n} \sum_{i=1}^n h_1(X_i) h_2(X_i),$$

② Calculer l'approximation courante de  $f$

$$\hat{G}_k(f) = \hat{G}_{k-1}(f) + \gamma \langle Y - \hat{G}_{k-1}(f), \varphi_k \rangle_n \varphi_k.$$

**end**

---

## Consistance de l'algorithme

- 1  $p_n = O_{n \rightarrow +\infty}(\exp(Cn^{1-\xi}))$ , où  $\xi \in (0, 1)$ ,  $C < \infty$ ,
- 2  $(\varepsilon_i)_i$  sont des v.a centrées, indépendantes de  $(X_i)_i$  telles que  $\mathbb{E}|\varepsilon|^t < \infty$  pour  $t > \frac{4}{\xi}$ ,
- 3  $(\theta_i)_{1 \leq i \leq p_n}$  est  $\mathcal{S}$ -parcimonieuse, de support  $\mathcal{S}$ , et satisfait

$$\forall j \in \mathcal{S}, |\theta_j| \geq n^{-\kappa\xi}, \text{ où } 0 < \kappa < 1.$$

### Théorème (Bühlmann, 2006)

Sous les hypothèses 1 et 2, il existe  $k_n := C \log n$  avec  $C < \xi/4 \log(3)$  tel que :

$$\|f - \hat{G}_{k_n}(f)\| \xrightarrow[n \rightarrow +\infty]{\mathbb{P}} 0.$$

## Recouvrement du support

On définit la cohérence  $\rho$  de la famille  $(X_i)_{1 \leq i \leq p-1}$  de la manière suivante :

$$\rho = \max_{1 \leq i \neq j \leq p-1} \langle X_i, X_j \rangle.$$

Notons  $\mathcal{S}_k$  le support de  $\hat{G}_k(f)$ .

### Théorème

*On suppose que  $\rho(2S - 1) < 1$ . Sous les hypothèses 1 et 2, si  $\gamma$  est suffisamment petit, avec grande probabilité, on a alors :*

$$\forall k, \mathcal{S}_k \subset \mathcal{S}.$$

*De plus, si l'hypothèse 3 est satisfaite, à la fin des itérations de l'algorithme, on a*

$$\mathcal{S}_{k_n} = \mathcal{S}.$$

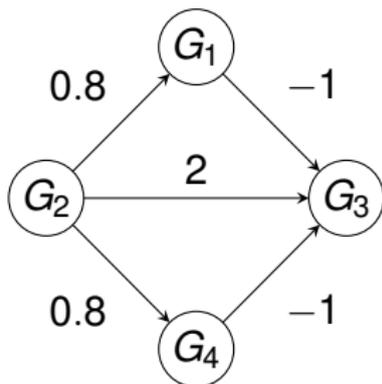
## Modèle II

On considère l'ensemble des graphes acycliques orientés gaussiens (*Directed Acyclic Graphs*).

## Proposition

Toute matrice d'adjacence  $\Theta$  associée à un DAG  $\mathcal{G}$  satisfait :

$$\Theta = PT^tP \text{ où } \begin{cases} P & \text{matrice de permutation} \\ T & \text{matrice triangulaire inférieure stricte} \end{cases}$$



$$T = \begin{pmatrix} 0 & 0 & 0 & 0 \\ -1 & 0 & 0 & 0 \\ -1 & 0 & 0 & 0 \\ 2 & 0.8 & 0.8 & 0 \end{pmatrix}$$

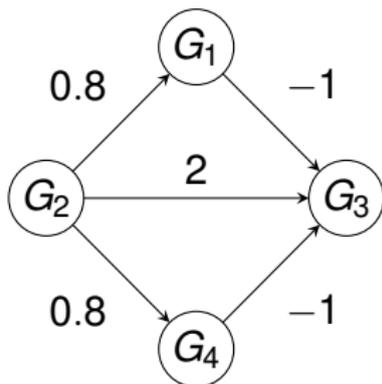
## Modèle II

On considère l'ensemble des graphes acycliques orientés gaussiens (*Directed Acyclic Graphs*).

## Proposition

Toute matrice d'adjacence  $\Theta$  associée à un DAG  $\mathcal{G}$  satisfait :

$$\Theta = PT^tP \quad \text{où} \quad \begin{cases} P & \text{matrice de permutation} \\ T & \text{matrice triangulaire inférieure stricte} \end{cases}$$



$$P = \begin{pmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 \\ 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{pmatrix}$$

# Problème d'optimisation

On souhaite maximiser la log-vraisemblance pénalisée :

$$(\hat{P}, \hat{T}) = \underset{P \in \mathbb{P}_\rho(\mathbb{R}), T \in \mathbb{T}_\rho(\mathbb{R})}{\operatorname{argmin}} \left\{ \frac{1}{n} \left\| G - GPT^t P \right\|_F^2 + \lambda \|T\|_1 \right\},$$

où

- $\mathbb{P}_\rho(\mathbb{R})$  est l'ensemble des matrices de permutation,
- $\mathbb{T}_\rho(\mathbb{R})$  est l'ensemble des matrices triangulaires inférieures strictes,
- $\|M\|_F^2 = \operatorname{Trace}({}^t M M) = \sum_{i,j} (M_i^j)^2$ ,
- $\|M\|_1 = \sum_{i,j} |M_i^j|$ .

Critère à minimiser :

$$\hat{T} = \underset{T \in \mathbb{T}_p(\mathbb{R})}{\operatorname{argmin}} \left\{ \frac{1}{n} \left\| G - GPT^t P \right\|_F^2 + \lambda \|T\|_1 \right\}.$$

- minimisation d'une fonction convexe, différentiable et quadratique + un terme de pénalisation

$$T_{k+1} = \underset{T}{\operatorname{argmin}} \left\{ \frac{L}{2} \left\| T - \left( T_k - \frac{\nabla f(T_k)}{L} \right) \right\|_F^2 + \lambda \|T\|_1 \right\}.$$

- projection sur l'espace des contraintes  $\mathbb{T}_p(\mathbb{R})$ .

**A T fixé**

Critère à minimiser :  $\hat{P} = \operatorname{argmin}_{P \in \mathbb{P}_p(\mathbb{R})} \left\{ \frac{1}{n} \left\| G - GPT^t P \right\|_F^2 \right\}$ .

Comme l'espace des contraintes n'est pas convexe, on propose une relaxation convexe du critère à minimiser.

## Definition

*Une matrice bistochastique  $A = (a_{ij})_{1 \leq i, j \leq p}$  est une matrice telle que :*

- $a_{ij} \geq 0$ ,
- $\sum_i a_{ij} = \sum_j a_{ij} = 1$ .

## Proposition (Birkhoff)

*L'ensemble des matrices bistochastiques  $\mathbb{B}_p(\mathbb{R})$  est un ensemble convexe dont les matrices de permutation sont les points extrémaux.*

## Minimisation alternée

$$(\hat{P}, \hat{T}) = \underset{P \in \mathbb{B}_\rho(\mathbb{R}), T \in \mathbb{T}_\rho(\mathbb{R})}{\operatorname{argmin}} \frac{1}{n} \left\| G - GPT^t P \right\|_F^2 + \lambda \|T\|_1.$$

$$P_0 \in \mathbb{P}_\rho(\mathbb{R}) \xrightarrow{\text{optimisation}} T_0 \xrightarrow{\text{proj}} T'_0 \in \mathbb{T}_\rho(\mathbb{R})$$

descente de gradient projeté

$$P_1 \in \mathbb{B}_\rho(\mathbb{R}) \xrightarrow{\text{optimisation}} T_1 \xrightarrow{\text{proj}} T'_1 \in \mathbb{T}_\rho(\mathbb{R})$$

descente de gradient projeté

$$P_2 \in \mathbb{B}_\rho(\mathbb{R}) \longrightarrow \dots \xrightarrow{\text{Projection sur } \mathbb{P}_\rho(\mathbb{R})}$$

# Matrices de permutation

On veut trouver la projection d'une matrice bistochastique  $B \in \mathbb{B}_\rho(\mathbb{R})$  sur  $\mathbb{P}_\rho(\mathbb{R})$ , ce qui s'écrit sous la forme :

$$\begin{aligned}\text{Proj}_{\mathbb{P}_\rho(\mathbb{R})}(B) &= \underset{P \in \mathbb{P}_\rho(\mathbb{R})}{\text{argmin}} \|B - P\|_F \\ &= \underset{P \in \mathbb{P}_\rho(\mathbb{R})}{\text{argmin}} -2\langle B, P \rangle_F.\end{aligned}$$

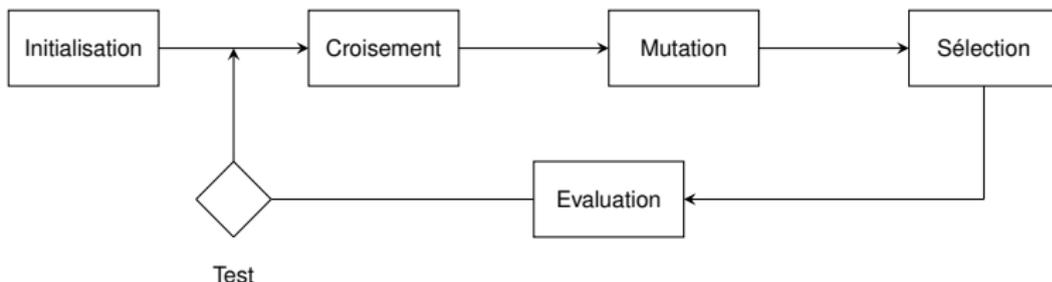
La fonction  $-2\langle B, P \rangle_F$  à minimiser est linéaire et l'espace des contraintes  $\mathbb{P}_\rho(\mathbb{R})$  est l'ensemble des points extrémaux d'un polyèdre convexe. Il existe donc un point extrémal solution du problème relaxé

$$P = \underset{P \in \mathbb{B}_\rho(\mathbb{R})}{\text{argmin}} -2\langle B, P \rangle_F.$$

# Algorithmes génétiques

Travail en collaboration avec Victor Pichény

Au lieu de relaxer la condition  $P \in \mathbb{P}_p(\mathbb{R})$ , nous proposons d'utiliser des algorithmes génétiques, qui sont des procédés de recherche heuristiques reproduisant les processus d'évolution naturelle.



## En quelques mots (initialisation)

- 1 On considère  $N$  matrices de permutation. Chacune d'entre elles est représentée par une suite de "gènes", appelée "chromosome".

$$P = \begin{pmatrix} 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \\ 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \end{pmatrix}$$

chromosome  $\longrightarrow$ 

2	3	6	1	4	5
---	---	---	---	---	---

- 2 On cherche la matrice triangulaire inférieure stricte  $T$  associée à chaque chromosome.

# En quelques mots (croisement)

- 1 Sélection pour le croisement : roulette wheel selection
- 2 Méthode de croisement

1	2	3	4	5	6
6	5	1	3	2	4



		1	3	2	
		3	4	5	

# En quelques mots (croisement)

- 1 Sélection pour le croisement : roulette wheel selection
- 2 Méthode de croisement

1	2	3	4	5	6
6	5	1	3	2	4



4	5	1	3	2	6
6	1	3	4	5	2

## Résultats numériques

Pour comparer les calculs, on calcule :

- la MSE :  $\left\| \hat{\Theta} - \Theta^* \right\|_F^2$
- la MSEP :  $\frac{1}{n} \left\| G - G\hat{\Theta} \right\|_F^2$ .

Pour  $n = 100$  et  $p = 5$

	Optimisation	Algorithmes génétiques
Temps de calcul	10 s	11 s
MSE	2.45	2.10
MSEP	3.74	3.72

## Résultats numériques

Introduction

Régression  
linéaireModèle I  
Résultats de stabilitéProblème  
d'optimisationModèle II  
Procédure  
d'optimisation  
Minimisation alternée  
Relaxation convexe ?Autre  
approche

Pour comparer les calculs, on calcule :

- la MSE :  $\left\| \hat{\Theta} - \Theta^* \right\|_F^2$
- la MSEP :  $\frac{1}{n} \left\| G - G\hat{\Theta} \right\|_F^2$ .

Pour  $n = 100$  et  $p = 50$

	Optimisation	Algorithmes génétiques
Temps de calcul	26 s	15 s
MSE	13.20	6.18
MSEP	20.82	12.44