

Transport optimal régularisé pour l'estimation des poids dans des modèles de mélange, et applications à la cytométrie

Soutenance de thèse

Paul Freulon,

Directeur : Jérémie Bigot

Coencadrant : Boris Hejblum

Collaborateur scientifique : Arthur Leclaire

28 mars 2023

Université de Bordeaux

Données de cytométrie

Cytométrie en flux : Mesures caractérisant différents paramètres sur des cellules dans un échantillon biologique

Principe

- Mesure de d caractéristiques biologiques sur chaque cellule
Exemple : protéines exprimées à la surface de la cellule
- Une observation $X_i \in \mathbb{R}^d \rightarrow$ valeurs mesurées sur une cellule


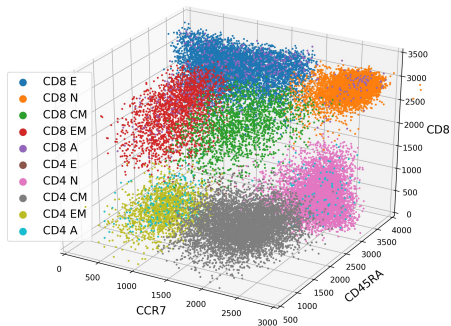
CCR7	CD4	CD45RA	CD3	HLADR	CD38	CD8
717.3	1146.5	3094.8	2526.3	1333.1	1510.2	3203.7

Une observation $X_i \in \mathbb{R}^d$ correspondant à une cellule biologique

En pratique : mesures sur n cellules $\rightarrow n$ observations X_1, \dots, X_n

Données disponibles : $n \in [10^5, 10^7]$ et $d \in \{5, 30\}$

Quantité d'intérêt : les proportions par classe




Gauche : projection selon 3 bio-marqueurs et classification en $K = 10$ sous-populations. Droite : proportions relatives des 10 sous-populations.

- X_1, \dots, X_n se répartissent en K sous-populations C_1, \dots, C_K
- Dans cette présentation : **on estime les proportions**
- Application en immunologie

Analyse manuelle des données

Classification des cellules en sous-populations en fonction des paramètres mesurés



Exemple de traitement manuel (Verschoor et al. 2015)

- Suite de projections selon 2 paramètres biologiques
- Identification des régions à forte densité
- Annotation +/- d'un sous groupe en fonction de l'intensité du signal associé au paramètre biologique à chaque étape
- **Résultat** : classification en K sous-populations C_1, \dots, C_K

Estimation supervisée

Classification X_1, \dots, X_n en K classes C_1, \dots, C_K connue

- K connu
- Mesure empirique de C_k

$$\hat{\mu}_k := \frac{1}{n_k} \sum_{i: X_i \in C_k} \delta_{X_i}, \quad \text{où } n_k = \#C_k$$

- $\rightarrow \hat{\mu}_1, \dots, \hat{\mu}_K$ connues


Modèle de mélange avec composantes $\hat{\mu}_1, \dots, \hat{\mu}_K$

$$\widehat{\mathcal{M}}_K := \left\{ \hat{\mu}_n(\theta) := \sum_{k=1}^K \theta_k \hat{\mu}_k \mid \theta \in \Sigma_K \right\}$$

- **Paramètres** : poids $\theta \in \Sigma_K = \{\theta \in \mathbb{R}_+^K \mid \sum_{k=1}^K \theta_k = 1\}$
- **Absence d'hypothèse** sur la loi de X_1, \dots, X_n

Observations **non-classifiées** : Y_1, \dots, Y_m

Objectif : proportions dans un jeu de données non classifiées



- Classification : $K = 2 \rightarrow \hat{\mu}_1, \hat{\mu}_2, \theta = (\theta_1, 1 - \theta_1) \in \Sigma_2$

$$\hat{\mu}_n(\theta) = \theta_1 \left(\frac{1}{n_1} \sum_{i: X_i \in C_1} \delta_{X_i} \right) + (1 - \theta_1) \left(\frac{1}{n_2} \sum_{i: X_i \in C_2} \delta_{X_i} \right)$$

- Observations non-classifiées (droite) Y_1, \dots, Y_m
 $\rightarrow \hat{\nu}_m := \frac{1}{m} \sum_{j=1}^m \delta_{Y_j}$


Estimateur des proportions

Classification supposée inconnue dans Y_1, \dots, Y_m


Objectif : proportions par classe dans Y_1, \dots, Y_m

$$\hat{\theta}_\lambda = (\hat{\theta}_1, \dots, \hat{\theta}_K) := \arg \min_{\theta \in \Sigma_K} \mathcal{T}_\lambda(\hat{\mu}_n(\theta), \hat{\nu}_m)$$

$\mathcal{T}_\lambda : \mathcal{P}(\mathbb{R}^d)^2 \rightarrow \mathbb{R}_+$ coût de transport régularisé (Redko et al., 2019)



Résultats sur données HIPC



$K = 10$ sous-populations, $d = 7$ paramètres, $n \in [10^5, 10^6]$ cellules

- Diagramme de Bland-Altman - référence : [méthode manuelle](#)
- Un jeu de données : $K = 10$ points $((\hat{\theta}_k + \theta_k^*)/2, \hat{\theta}_k - \theta_k^*)_{1 \leq k \leq 10}$
- Points proches de l'axe $y = 0$: bons résultats

Ça fonctionne mais...

- **CytOpT** : $\hat{\theta}_\lambda = \arg \min_{\theta \in \Sigma_K} \mathcal{T}_\lambda(\hat{\mu}_n(\theta), \hat{\nu}_m)$
(Freulon, Bigot, Hejblum, 2022, AOAS)
- Si λ trop grand, la méthode **échoue**
- Si $Y_1, \dots, Y_m \sim_{\text{i.i.d.}} \nu$ où $\nu = \sum_{k=1}^K \theta_k^* \mu_k$

Questions

- Proximité $\hat{\theta}_\lambda$ et poids θ^* ?
- Comment choisir λ ?
- Calcul efficace de $\hat{\theta}_\lambda$?

1. Transport optimal régularisé
2. Estimation des poids et analyse statistique
3. Expériences et calcul efficace d'un estimateur des poids

Transport optimal régularisé

Problème de transport optimal de Kantorovich (1942)

μ, ν : mesures de probabilités sur \mathbb{R}^d à support compact

Coût (au sol) : $c(x, y) = \|x - y\|_2^2$.

Coût de transport optimal entre μ et ν


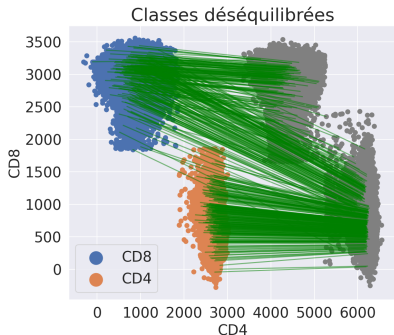
$$\mathcal{T}_0(\mu, \nu) := \underbrace{\min_{\pi \in \Pi(\mu, \nu)} \int_{\mathbb{R}^d \times \mathbb{R}^d} \|x - y\|_2^2 d\pi(x, y)}_{\text{problème de Kantorovich}}$$

$\Pi(\mu, \nu)$ mesures de probabilité ayant pour marginales μ et ν

- $\sqrt{\mathcal{T}_0(\mu, \nu)}$ distance de transport
- Plan de transport optimal : π^* solution problème
- Existence π^* : oui
- Unicité π^* : pas nécessairement

Transport discret : $\mu = \sum_{i=1}^n a_i \delta_{x_i}$ **et** $\nu = \sum_{j=1}^m b_j \delta_{y_j}$

$$\mathcal{T}_0(\mu, \nu) = \min_{\pi \in \mathbb{R}_+^{n \times m}} \sum_{i,j} \|x_i - y_j\|^2 \pi_{i,j} \quad \text{où} \quad \pi \mathbf{1}_m = a \text{ et } \pi^T \mathbf{1}_n = b$$



- Gauche $\mathcal{T}_0(\hat{\mu}_n, \hat{\nu}_m) \rightarrow a_i = 1/n$ et $b_j = 1/m$
- Droite $\mathcal{T}_0(\hat{\mu}_n(\hat{\theta}_\lambda), \hat{\nu}_m) \rightarrow a_i = a_i(\hat{\theta}_\lambda)$ et $b_j = 1/m$

Coût algorithmique important : $m = n, \mathcal{T}_0(\mu, \nu) \Rightarrow O(n^3 \log(n))$

Transport optimal régularisé (M.Cuturi, 2013)

$$\mathcal{T}_\lambda(\mu, \nu) := \min_{\pi \in \Pi(\mu, \nu)} \int_{\mathbb{R}^d \times \mathbb{R}^d} \|x - y\|^2 d\pi(x, y) + \underbrace{\lambda \text{KL}(\pi | \mu \otimes \nu)}_{\text{régularisation}}$$

$\lambda \geq 0$ paramètre de régularisation

$$\text{KL}(\pi | \mu \otimes \nu) = \int_{\mathcal{X} \times \mathcal{Y}} \log \left(\frac{d\pi}{d\mu \otimes \nu}(x, y) \right) d\pi(x, y) \text{ si } \pi \ll \mu \otimes \nu$$

- **Bénéfice algorithmique** : cas discret $m = n$
Calcul de $\mathcal{T}_\lambda(\mu, \nu)$ en $O(n^2 \log(n))$ opérations
- **Problème mieux posé** : existence **et** unicité de π_λ^* solution
- **Cette présentation** : étude des performances **statistiques** de $\mathcal{T}_\lambda(\mu, \nu)$ par rapport à $\mathcal{T}_0(\mu, \nu)$

Problème : choix de λ

Formulation duale

Transport classique et transport régularisé

$$\mathcal{T}_\lambda(\mu, \nu) = \max_{\substack{\varphi \in L^\infty(\mathcal{X}), \\ \psi \in L^\infty(\mathcal{Y})}} \int_{\mathcal{X}} \varphi d\mu + \int_{\mathcal{Y}} \psi d\nu - \int_{\mathcal{X} \times \mathcal{Y}} m_\lambda(\varphi + \psi) d\mu d\nu$$

Variables duales: φ, ψ

- Si $\lambda = 0$, alors $m_0(\varphi + \psi) = +\infty 1_{\varphi(x) + \psi(y) > \|x - y\|^2}$
- Si $\lambda > 0$, alors $m_\lambda(\varphi + \psi) = \lambda \exp\left(\frac{\varphi(x) + \psi(y) - \|x - y\|^2}{\lambda}\right)$

Intérêt de la formulation duale

- **Solutions numériques** : $\lambda = 0$ algorithme des enchères
 $\lambda > 0$ algorithme de **Sinkhorn**, algorithme **stochastique**
- **Analyse statistique** : contrôle de $|\mathcal{T}_\lambda(\mu, \nu) - \mathcal{T}_\lambda(\mu, \hat{\nu}_n)|$ par $\sup_{\varphi \in \mathcal{F}} \left| \int \varphi d(\nu - \hat{\nu}_n) \right|$
 \mathcal{F} contient les variables duales optimales

Estimation des poids et analyse statistique

Application du transport optimal en statistique

Objectif: Approcher une mesure de probabilité inconnue ν avec un modèle paramétrique $\{\mu_\theta \mid \theta \in \Theta\}$ où $\Theta \subset \mathbb{R}^D$

Ici: Modèle de mélange à K composantes μ_1, \dots, μ_K :

$$\mathcal{M}_K := \left\{ \mu(\theta) := \sum_{k=1}^K \theta_k \mu_k \mid \theta \in \Sigma_K \right\}$$

Projection de ν sur \mathcal{M}_K au sens du transport optimal

$$\theta^* \in \arg \min_{\theta \in \Sigma_K} \mathcal{T}_0(\mu(\theta), \nu) \quad \text{i.e.} \quad \forall \theta \in \Sigma_K, \mathcal{T}_0(\mu(\theta^*), \nu) \leq \mathcal{T}_0(\mu(\theta), \nu)$$

Problème : en pratique ν **inconnue**

Estimation de $\theta^* = \arg \min_{\theta \in \Sigma_K} \mathcal{T}_0(\mu(\theta), \nu)$

Hypothèse :

- modèle $\left\{ \mu(\theta) := \sum_{k=1}^K \theta_k \mu_k \mid \theta \in \Sigma_K \right\}$ connu
- observations $Y_1, \dots, Y_n \sim_{\text{i.i.d.}} \nu$ disponibles

On remplace ν par $\hat{\nu}_n = \frac{1}{n} \sum_{j=1}^n \delta_{Y_j}$

→ famille d'estimateurs $(\hat{\theta}_\lambda)_{\lambda \geq 0}$

$$\hat{\theta}_\lambda = \arg \min_{\theta \in \Sigma_K} \mathcal{T}_\lambda(\mu(\theta), \hat{\nu}_n) \quad \text{où } \lambda \geq 0.$$

- Convergence de $\hat{\theta}_\lambda = \hat{\theta}_\lambda^{(n)}$ vers θ^* quand n augmente ?
- Comment choisir λ ?
- Solutions numériques pour calculer $\hat{\theta}_\lambda$ en pratique ?
En cytométrie $n \in [10^5, 10^7]$.

Écart entre $\hat{\theta}_\lambda$ et θ^*

Objectif : contrôler l'écart entre

$$\theta^* = \arg \min_{\theta \in \Sigma_K} \mathcal{T}_0(\mu(\theta), \nu) \quad \text{et} \quad \hat{\theta}_\lambda = \arg \min_{\theta \in \Sigma_K} \mathcal{T}_\lambda(\mu(\theta), \hat{\nu}_n)$$

Critère : $r(\hat{\theta}_\lambda, \theta^*) := \mathcal{T}_0(\mu(\hat{\theta}_\lambda), \nu) - \mathcal{T}_0(\mu(\theta^*), \nu)$

Fait :

$$0 \leq r(\hat{\theta}_\lambda, \theta^*) \leq 2 \sup_{\theta \in \Sigma_K} |\mathcal{T}_0(\mu(\theta), \nu) - \mathcal{T}_\lambda(\mu(\theta), \hat{\nu}_n)|$$

Fixons $\theta \in \Sigma_K$ et regardons

$$|\mathcal{T}_0(\mu(\theta), \nu) - \mathcal{T}_\lambda(\mu(\theta), \hat{\nu}_n)|$$

Estimation du coût de transport $\mathcal{T}_0(\mu, \nu)$

- Mesure μ connue
- $Y_1, \dots, Y_n \sim_{\text{i.i.d.}} \nu \rightarrow \hat{\nu}_n = \frac{1}{n} \sum_{j=1}^n \delta_{Y_j}$

Contrôle de

$$|\mathcal{T}_0(\mu, \nu) - \mathcal{T}_\lambda(\mu, \hat{\nu}_n)|$$

$\mathcal{T}_\lambda(\mu, \hat{\nu}_n)$ est un estimateur de $\mathcal{T}_0(\mu, \nu)$

- Résultat non-asymptotique

$$\mathbb{E}[|\mathcal{T}_0(\mu, \nu) - \mathcal{T}_\lambda(\mu, \hat{\nu}_n)|] \leq B(n, d, \lambda)$$

Puis en **déduire un choix de λ**

Estimation de $\mathcal{T}_0(\mu, \nu)$: état de l'art

Théorème (Chizat et al., 2020)

Si μ et ν sont à support compact et $d > 4$

$$\mathbb{E} [|\mathcal{T}_0(\mu, \nu) - \mathcal{T}_0(\mu, \hat{\nu}_n)|] \leq C_0 n^{-2/d}$$

Peut-on espérer mieux ?

Estimation de $\mathcal{T}_0(\mu, \nu)$: état de l'art

Théorème (Chizat et al., 2020)

Si μ et ν sont à support compact et $d > 4$

$$\mathbb{E} [|\mathcal{T}_0(\mu, \nu) - \mathcal{T}_0(\mu, \hat{\nu}_n)|] \leq C_0 n^{-2/d}$$

Peut-on espérer mieux ?

Théorème (Manole and Niles-Weed, 2021)

Borne inférieure "minimax"

$$\inf_{\hat{\mathcal{T}}_n} \sup_{\substack{\mu \in \mathcal{P}(\mathcal{X}), \\ \nu \in \mathcal{P}(\mathcal{Y})}} \mathbb{E} [|\mathcal{T}_0(\mu, \nu) - \hat{\mathcal{T}}_n|] \geq C_1 (n \log n)^{-2/d}$$

infimum calculé sur l'ensemble des estimateurs de $\mathcal{T}_0(\mu, \nu)$

Pour l'estimateur régularisé $\mathcal{T}_\lambda(\mu, \hat{\nu}_n)$ avec $\lambda > 0$?

$$\mathbb{E} [|\mathcal{T}_\lambda(\mu, \nu) - \mathcal{T}_\lambda(\mu, \hat{\nu}_n)|] \lesssim \left(1 + \frac{1}{\lambda^{d/2}}\right) \frac{1}{\sqrt{n}}$$

Décomposition approximation-estimation

$$|\mathcal{T}_0(\mu, \nu) - \mathcal{T}_\lambda(\mu, \hat{\nu}_n)| \leq \overbrace{|\mathcal{T}_0(\mu, \nu) - \mathcal{T}_\lambda(\mu, \nu)|}^{\text{approximation}} + \overbrace{|\mathcal{T}_\lambda(\mu, \nu) - \mathcal{T}_\lambda(\mu, \hat{\nu}_n)|}^{\text{estimation}}$$

Contrôle décomposition approximation-estimation

À partir de (Genevay et al., 2019) et (Chizat et al., 2020)

$$\mathbb{E}[|\mathcal{T}_0(\mu, \nu) - \mathcal{T}_\lambda(\mu, \hat{\nu}_n)|] \lesssim \underbrace{\lambda \log(\lambda^{-1})}_{\text{approximation}} + \underbrace{\left(1 + \frac{1}{\lambda^{d/2}}\right) \frac{1}{\sqrt{n}}}_{\text{estimation}}$$

Compromis approximation-estimation:

$$\lambda_n = n^{-1/(d+2)} \Rightarrow \mathbb{E}[|\mathcal{T}_0(\mu, \nu) - \mathcal{T}_{\lambda_n}(\mu, \hat{\nu}_n)|] \lesssim n^{-1/d+2}$$

Choix de λ , mais vitesse sous-optimale ($n^{-2/d}$ avec $\mathcal{T}_0(\mu, \hat{\nu}_n)$)

Point faible : borne d'estimation $(1 + \lambda^{-d/2})/\sqrt{n}$

Une erreur d'estimation indépendante de λ

Théorème (Bigot, Freulon, Hejblum, Leclaire)

Pour $\lambda \geq 0$, en dimension $d > 4$

$$\mathbb{E} [|\mathcal{T}_\lambda(\mu, \nu) - \mathcal{T}_\lambda(\mu, \hat{\nu}_n)|] \leq C_0 n^{-2/d}$$

C_0 dépend des supports, de la dimension, **pas** de λ

Retour à la décomposition approximation-estimation :

$$\mathbb{E}[|\mathcal{T}_0(\mu, \nu) - \mathcal{T}_\lambda(\mu, \hat{\nu}_n)|] \lesssim \underbrace{\lambda \log(\lambda^{-1})}_{\text{approximation}} + \underbrace{n^{-2/d}}_{\text{estimation}}$$

- Choisir λ_n t.q. $|\mathcal{T}_0(\mu, \nu) - \mathcal{T}_{\lambda_n}(\mu, \nu)| \lesssim \lambda_n \log(\lambda_n^{-1}) \leq n^{-2/d}$

Corollaire (Bigot, Freulon, Hejblum, Leclaire)

Avec $\lambda_n = \frac{n^{-2/d}}{d}$ si $d > 4$

$$\mathbb{E} [|\mathcal{T}_0(\mu, \nu) - \mathcal{T}_{\lambda_n}(\mu, \hat{\nu}_n)|] \lesssim n^{-2/d} \log(n)$$

Idées de preuve concernant l'erreur d'estimation

En notant $\hat{\nu}_n = \frac{1}{n} \sum_{i=1}^n \delta_{Y_i}$ où $Y_1, \dots, Y_n \sim_{\text{i.i.d.}} \nu$, on a

$$|\mathcal{T}_\lambda(\mu, \nu) - \mathcal{T}_\lambda(\mu, \hat{\nu}_n)| \leq \sup_{\varphi \in \mathcal{F}} \left| \int \varphi d(\nu - \hat{\nu}_n) \right|$$

\mathcal{F} contient les variables optimales pour le problème dual

$$\mathcal{T}_\lambda(\mu, \nu) = \max_{\varphi, \psi} \int_{\mathcal{X}} \psi d\mu + \int_{\mathcal{Y}} \varphi d\nu - \int_{\mathcal{X} \times \mathcal{Y}} m_\lambda(\varphi + \psi) d\mu d\nu$$

$$\text{Fait : } \|x - y\|^2 = \|x\|^2 - 2\langle x, y \rangle + \|y\|^2$$

Nouveau problème de transport \rightarrow coût $s(x, y) = -\langle x, y \rangle$

$$\mathcal{T}_\lambda^s(\mu, \nu) = \min_{\pi \in \Pi(\mu, \nu)} \int_{\mathbb{R}^d \times \mathbb{R}^d} \underbrace{-\langle x, y \rangle}_{s(x, y)} d\pi(x, y) + \lambda \text{KL}(\pi | \mu \otimes \nu)$$

Lemme : $\mathcal{F}^s = \{\text{fonctions convexes et Lipschitziennes}\}$

Résultat connu (Chizat et al. 2020) :

$$\mathbb{E} \left[\sup_{\varphi \in \mathcal{F}^s} \left| \int \varphi d(\nu - \hat{\nu}_n) \right| \right] \lesssim n^{-2/d}$$

Bilan sur le choix de λ

On a $\mathbb{E}[|\mathcal{T}_0(\mu, \nu) - \mathcal{T}_\lambda(\mu, \hat{\nu}_n)|] \lesssim \lambda \log(\lambda^{-1}) + n^{-2/d}$

Théorie : plus λ est petit, plus $\mathcal{T}_\lambda(\mu, \hat{\nu}_n)$ est proche de $\mathcal{T}_0(\mu, \nu)$

Pratique : prendre λ petit ralentit le calcul numérique de $\mathcal{T}_\lambda(\mu, \hat{\nu}_n)$

Compromis : erreur d'approximation – gain algorithmique

Ce dont on ne parlera pas :

- Réduction de l'erreur d'approximation $\rightarrow \mathcal{S}_\lambda(\mu, \nu)$
- Réduction du coût algorithmique : limitation du nombre d'itérations de l'algorithme de Sinkhorn

Choix de λ pour l'estimation des poids

Retour sur les modèles de mélange :

$$\theta^* = \arg \min_{\theta \in \Sigma_K} \mathcal{T}_0(\mu(\theta), \nu) \quad \text{et} \quad \mu(\theta) = \sum_{k=1}^K \theta_k \mu_k$$

Analyse similaire pour $\hat{\theta}_\lambda = \arg \min_{\theta \in \Sigma_K} \mathcal{T}_\lambda(\mu(\theta), \hat{\nu}_n)$

Théorème (Bigot, Freulon, Hejblum, Leclaire)

$\text{supp}(\nu)$ compact et $\forall k \in \{1, \dots, K\}$, $\text{supp}(\mu_k)$ compact.


Avec $\lambda_n = \frac{n^{-2/d}}{d}$

$$0 \leq \mathbb{E} \left[\mathcal{T}_0(\mu(\hat{\theta}_{\lambda_n}), \nu) - \mathcal{T}_0(\mu(\theta^*), \nu) \right] \lesssim n^{-2/d} \log(n)$$

Extension : probablement vrai pour un modèle $(\mu_\theta)_{\theta \in \Theta}$ s'il existe \mathcal{K} borné tel que pour tout $\theta \in \Theta$, $\text{supp}(\mu_\theta) \subset \mathcal{K}$

Expériences et calcul efficace d'un estimateur des poids

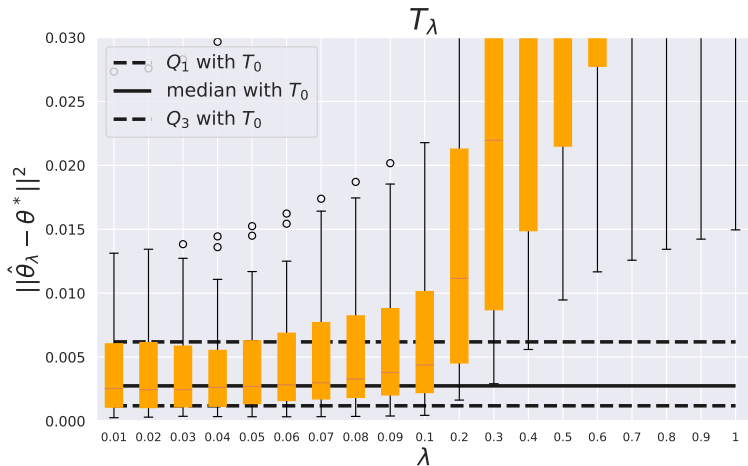
Données synthétiques



Projection 2D d'observations selon un mélange gaussien de $K = 5$ composantes en dimension $d = 6$

- Dans ces expériences, λ varie entre $\lambda = 0.01$ et $\lambda = 1$
- Calcul $\hat{\theta}_\lambda = \min_{\theta \in \Sigma_K} \mathcal{T}_\lambda(\mu(\theta), \hat{\nu}_n)$: descente de gradient
- $\nu = \sum_{k=1}^K \theta_k^* \mu_k$, donc θ^* connu !

Évolution des performances de $\hat{\theta}_\lambda$ en fonction de λ

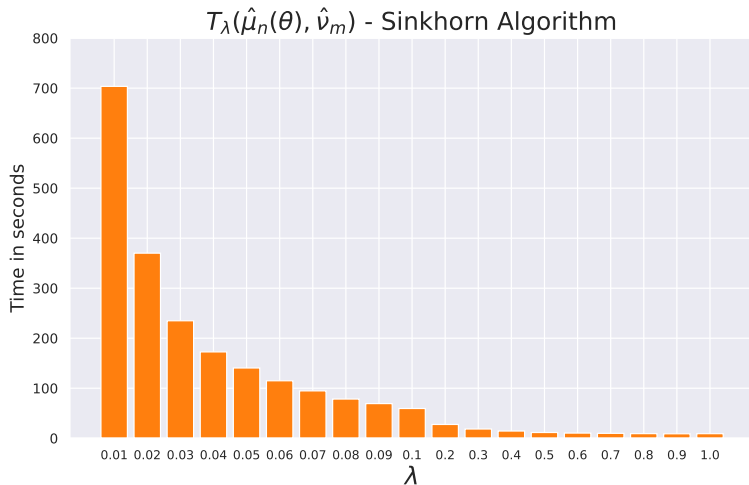


Pour λ fixé, on calcule 50 estimateurs $\hat{\theta}_\lambda^{[1]}, \dots, \hat{\theta}_\lambda^{[50]}$ de θ^*

Expérimentalement : λ petit $\Rightarrow \|\hat{\theta}_\lambda - \theta^*\|^2$ petit

Ici $n = 50$, $d = 6$ donc $\lambda_n \approx 0.05$

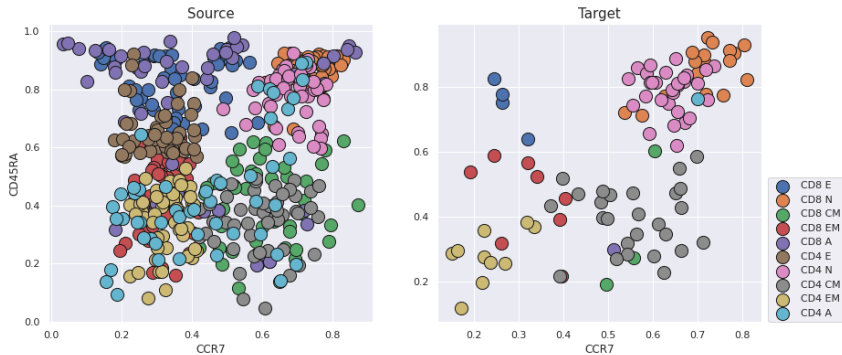
Temps de calcul de $\hat{\theta}_\lambda$ en fonction de λ



Temps nécessaire pour calculer 50 estimateurs des poids $\hat{\theta}_\lambda$

Calcul de $\nabla_\theta T_\lambda(\mu(\theta), \hat{\nu}_n)$: algorithme de Sinkhorn

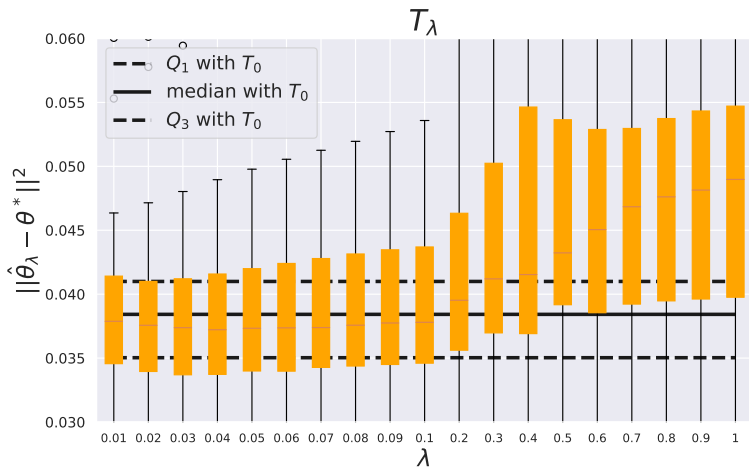
Résultats numériques sur données de cytométrie en flux



Projection 2D des mesures de cytométrie en flux. $K = 10$ sous-populations cellulaires identifiées. $d = 7$ paramètres biologiques sont mesurés

$\lambda > 0$ varie entre $\lambda = 0.01$ et $\lambda = 1$

Performance de $\hat{\theta}_\lambda$ en fonction de λ (données de cytométrie)

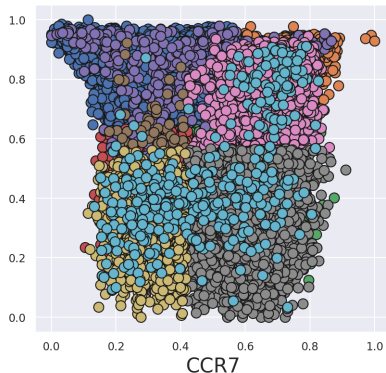



Calcul de $\nabla_{\theta} T_{\lambda}(\mu(\theta), \hat{\nu}_n)$: algorithme de Sinkhorn

Expérimentalement : λ petit $\Rightarrow \|\hat{\theta}_\lambda - \theta^*\|^2$ petit

Ici $n = 100$, $d = 7$, $\lambda_n \approx 0.04$

Calcul et minimisation d'un coût de transport



Gauche : sous-échantillon $n = 500$. droite : jeu complet $n \approx 31000$

Calcul de $\mathcal{T}_\lambda(\mu, \hat{\nu}_n)$ ou de $\nabla_\theta \mathcal{T}_\lambda(\mu(\theta), \hat{\nu}_n)$

- Discret - discret : Sinkhorn (1964), Cuturi (2013)
- Discret - continu (ou grand support) : Genevay et al. (2016), Bercu et al. (2020)

Calcul de l'estimateur $\hat{\theta}_\lambda = \arg \min_{\theta \in \Sigma_K} \mathcal{T}_\lambda(\hat{\mu}_n(\theta), \nu)$

Problème d'optimisation :

$$\min_{\theta \in \Sigma_K} \overbrace{\max_{\varphi \in \mathbb{R}^n} \mathcal{J}_\lambda(\varphi, \theta)}^{\mathcal{T}_\lambda(\hat{\mu}_n(\theta), \nu)}$$

\mathcal{J}_λ fonction duale $\longrightarrow \mathcal{J}_\lambda(\varphi, \theta) = \int_{\mathcal{X}} \varphi d\hat{\mu}_n(\theta) + \int_{\mathcal{Y}} \varphi^{c, \lambda} d\nu$

Calcul de l'estimateur $\hat{\theta}_\lambda = \arg \min_{\theta \in \Sigma_K} \mathcal{T}_\lambda(\hat{\mu}_n(\theta), \nu)$

Problème d'optimisation :

$$\min_{\theta \in \Sigma_K} \overbrace{\max_{\varphi \in \mathbb{R}^n} \mathcal{J}_\lambda(\varphi, \theta)}^{\mathcal{T}_\lambda(\hat{\mu}_n(\theta), \nu)}$$

\mathcal{J}_λ fonction duale $\rightarrow \mathcal{J}_\lambda(\varphi, \theta) = \int_{\mathcal{X}} \varphi d\hat{\mu}_n(\theta) + \int_{\mathcal{Y}} \varphi^{c, \lambda} d\nu$

Régularisation sur l'espace des paramètres (Ballu et al. 2020)

$$\hat{\theta}_{\lambda, \tau} := \arg \min_{\theta \in \Sigma_K} \mathcal{T}_\lambda(\hat{\mu}_n(\theta), \nu) + \tau H(\theta)$$

où $H(\theta) = \sum_{k=1}^K \theta_k \log(\theta_k)$ et $\tau \geq 0$

- Modèle discret $\{\hat{\mu}_n(\theta) = \sum_{k=1}^K \theta_k \hat{\mu}_k \mid \theta \in \Sigma_K\}$ (données classifiées)
- On peut simuler $Y_1, Y_2, \dots \sim_{\text{i.i.d.}} \nu$ (mesures de cytométrie arrivent en ligne)

Régularisation τH : conséquences

$$\begin{aligned}\min_{\theta \in \Sigma_K} \mathcal{T}_\lambda(\hat{\mu}_n(\theta), \nu) + \tau H(\theta) &= \min_{\theta \in \Sigma_K} \max_{\varphi \in \mathbb{R}^n} \mathcal{J}_\lambda(\varphi, \theta) + \tau H(\theta) \\ &= \max_{\varphi \in \mathbb{R}^n} \min_{\theta \in \Sigma_K} \mathcal{J}_\lambda(\varphi, \theta) + \tau H(\theta) \\ &= \max_{\varphi \in \mathbb{R}^n} \mathcal{J}_\lambda(\varphi, \chi_\tau(\varphi)) + \tau H(\chi_\tau(\varphi))\end{aligned}$$

Régularisation τH : conséquences

$$\begin{aligned}\min_{\theta \in \Sigma_K} \mathcal{T}_\lambda(\hat{\mu}_n(\theta), \nu) + \tau H(\theta) &= \min_{\theta \in \Sigma_K} \max_{\varphi \in \mathbb{R}^n} \mathcal{J}_\lambda(\varphi, \theta) + \tau H(\theta) \\ &= \max_{\varphi \in \mathbb{R}^n} \min_{\theta \in \Sigma_K} \mathcal{J}_\lambda(\varphi, \theta) + \tau H(\theta) \\ &= \max_{\varphi \in \mathbb{R}^n} \mathcal{J}_\lambda(\varphi, \chi_\tau(\varphi)) + \tau H(\chi_\tau(\varphi))\end{aligned}$$

Conséquence : $\hat{\theta}_{\lambda, \tau} = \chi_\tau(\varphi^*)$ où φ^* solution de

$$\max_{\varphi \in \mathbb{R}^n} \mathcal{J}_\lambda(\varphi, \chi_\tau(\varphi)) + \tau H(\chi_\tau(\varphi)) = \max_{\varphi \in \mathbb{R}^n} \mathbb{E}_{Y \sim \nu} [h_{\lambda, \tau}(Y, \varphi)]$$

- Algorithme de Robbins-Monro : $(\varphi_\ell)_{\ell \geq 0}$
- Retour vers l'espace des paramètres : $\theta_\ell = \chi_\tau(\varphi_\ell)$

Convergence vers $\hat{\theta}_{\lambda, \tau} = \arg \min_{\theta \in \Sigma_K} \mathcal{T}_{\lambda}(\hat{\mu}_n(\theta), \nu) + \tau H(\theta)$

Théorème (Freulon)

Si $\sup_{\varphi \in \mathbb{R}^n} \mathbb{E}_{Y \sim \nu} [h_{\lambda, \tau}(Y, \varphi)]$ admet un maximum, et $\nu \ll \text{Leb}$.
On peut calculer une suite $(\theta_{\ell})_{\ell \geq 0}$ telle que

$$\theta_{\ell} \xrightarrow{\ell \rightarrow +\infty} \hat{\theta}_{\lambda, \tau} \quad \text{presque sûrement}$$

Preuve : même technique que (Bercu et al. 2020)

Remarque : dans le résultat précédent $\mathcal{T}_{\lambda} = \mathcal{T}_{\lambda}^{\mathfrak{M} \otimes \text{Leb}}$

Convergence vers $\hat{\theta}_{\lambda, \tau} = \arg \min_{\theta \in \Sigma_K} \mathcal{T}_\lambda(\hat{\mu}_n(\theta), \nu) + \tau H(\theta)$

Théorème (Freulon)

Si $\sup_{\varphi \in \mathbb{R}^n} \mathbb{E}_{Y \sim \nu} [h_{\lambda, \tau}(Y, \varphi)]$ admet un maximum, et $\nu \ll \text{Leb}$.
On peut calculer une suite $(\theta_\ell)_{\ell \geq 0}$ telle que

$$\theta_\ell \xrightarrow{\ell \rightarrow +\infty} \hat{\theta}_{\lambda, \tau} \quad \text{presque sûrement}$$

Preuve : même technique que (Bercu et al. 2020)





Remarque : dans le résultat précédent $\mathcal{T}_\lambda = \mathcal{T}_\lambda^{\mathfrak{M} \otimes \text{Leb}}$

Heuristique (Freulon)

Avec $\lambda_n = \frac{n^{-2/d}}{d}$ et $\tau_n = \frac{n^{-2/d}}{K}$, l'estimateur $\hat{\theta}_{\lambda, \tau}$ vérifie

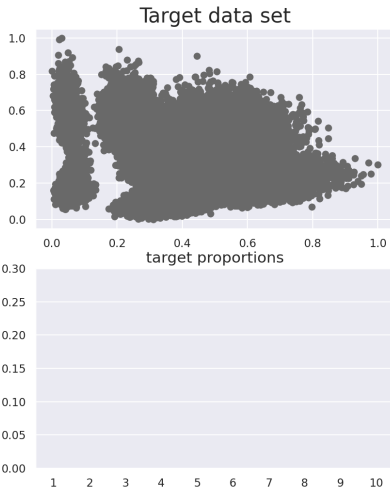
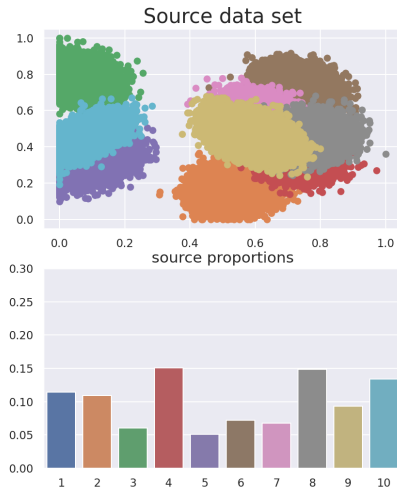
$$R(\hat{\theta}_{\lambda_n, \tau_n}, \theta^*) = \mathbb{E} \left[\mathcal{T}_0(\mu(\hat{\theta}_{\lambda_n, \tau_n}), \nu) - \mathcal{T}_0(\mu(\theta^*), \nu) \right] \lesssim n^{-2/d} \log(n)$$

Simulation




- $K = 10, d = 10$ et $n \in [10^5, 10^6]$
- Distributions source et cible différentes

Simulation







- Comparaison avec des méthodes de classification
- Avec l'objectif d'estimer les proportions

Simulation : résultats




- Calcul de 100 estimateurs $\hat{\theta}_{\lambda, \tau}^{[1]}, \dots, \hat{\theta}_{\lambda, \tau}^{[100]}$
- Estimation stable

Résultats cytométrie (HIPC)



Résultats cytométrie (OptimalFlow, Del Barrio et al. 2020)



Bilan

- Développement d'une nouvelle méthode d'estimation des poids dans un modèle de mélange.
- Minimisation efficace d'un coût de transport régularisé par algorithme stochastique.
- Poursuite des travaux existants sur l'impact statistique du paramètre de régularisation λ .
- Choix du paramètre de régularisation dans des méthodes basées sur la minimisation d'une distance de transport.

Bilan

- Développement d'une nouvelle méthode d'estimation des poids dans un modèle de mélange.
- Minimisation efficace d'un coût de transport régularisé par algorithme stochastique.
- Poursuite des travaux existants sur l'impact statistique du paramètre de régularisation λ .
- Choix du paramètre de régularisation dans des méthodes basées sur la minimisation d'une distance de transport.

Valorisation scientifique

- Freulon, Bigot, Hejblum, 2022, AOAS
(participation au développement du package associé avec K.Ba)
- Bigot, Freulon, Hejblum, Leclaire, 2022, soumis

Conclusion et perspectives

Bilan

- Développement d'une nouvelle méthode d'estimation des poids dans un modèle de mélange.
- Minimisation efficace d'un coût de transport régularisé par algorithme stochastique.
- Poursuite des travaux existants sur l'impact statistique du paramètre de régularisation λ .
- Choix du paramètre de régularisation dans des méthodes basées sur la minimisation d'une distance de transport.

Valorisation scientifique

- Freulon, Bigot, Hejblum, 2022, AOAS
(participation au développement du package associé avec K.Ba)
- Bigot, Freulon, Hejblum, Leclaire, 2022, soumis

Merci pour votre attention !