

RCP211 - Modèles génératifs

Flow matching

Arnaud Breloy *arnaud.breloy@lecnam.net*

8 décembre 2025

Conservatoire national des arts & métiers

Rappels et introduction

Flow matching

Objectif : générer de nouvelles données similaires à celles existantes

Point de vue probabiliste : les données sont des réalisations de variables aléatoires

Ce qu'on veut :

- la densité de probabilité (d.d.p.) des données $p(\mathbf{x})$
- un moyen d'échantillonner selon $p(\mathbf{x})$

Ce qu'on a :

- Des échantillons $\{\mathbf{x}_i\}_{i=1}^n$
- Différentes approches pour en tirer une approximation de l'idéal

Méthodes vues précédemment

- **Modèles paramétriques classiques**
 - PCA probabiliste, GMM, Modèles AR
- **Auto-encodeurs variationnels**
 - Auto-encodeur + échantillonnage de code latent \mathbf{z}
 - Les paramètres modélisent les lois $q_\phi(\mathbf{z}|\mathbf{x})$ et $p_\theta(\mathbf{x}|\mathbf{z})$
 - Approx. le max. de vraisemblance (ELBO)
- **Réseaux génératifs antagonistes**
 - Deux modèles (générateur, discriminateur), jeu min-max
 - plaque implicitement la d.d.p. des données générées sur $p(x)$
- **Modèles de diffusion**
 - Longue séquence de débruiteurs
 - Plusieurs points de vue : score, débruitage, Langevin, H-VAE, ...
 - Transforme $\mathcal{N} \rightarrow p$ via une SDE

Interprétable comme une **equation différentielle stochastique** (SDE)

$$d\mathbf{x}_t = f(\mathbf{x}_t, t)dt + g(t)d\mathbf{w}_t$$

échantillonner \Leftrightarrow inverser le processus

Peut on **interpoler entre deux ddp de manière déterministe** ? (ODE)

- Approximation déterministe avec le score (DDIM)
- Transport optimal
- **Flow matching**

Articles

Lipman, Y. (2024). Flow Matching Guide and Code. arXiv [\[pdf\]](#)

Blog posts

Gagneux A., et al. (2025). “A Visual Dive into Conditional Flow Matching” [\[html\]](#)

Vidéos

Plénière de Julie Delon au GRETSI 2025 [\[yt\]](#)

Rappels et introduction

Flow matching

On cherche une interpolation régulière p_t entre


- p_0 distribution d'origine généralement $\mathbf{x} \sim \mathcal{N}$
- p_1 distribution cible celle des données p_{data}

Il y en existe beaucoup! [\[anim\]](#)

On va se restreindre à celles régies par un **champ de vitesse**

Champ de vitesse

$$\begin{aligned} v: \mathbb{R}^d \times \mathbb{R} &\rightarrow T_x \mathbb{R}^d \ (\sim \mathbb{R}^d) \\ (x, t) &\mapsto v_t(x) \end{aligned}$$






Le **flow** ϕ d'un champ de vitesse v est défini via

$$\frac{d\phi_t}{dt}(x) = v_t(\phi_t(x)), \quad \phi_0(x) = x$$

- l'intégrale du champ de vitesse
- Dit où se trouve le point x s'il suit le champ v du temps 0 à t

Flow d'une distribution ?



Flow d'une distribution ?

Supposons que x soit tiré d'une distribution $X_0 \sim p_0$

Soit $p_t = \text{"loi de } \phi_t(X_0)\text{"}$: elle vérifie une **équation de continuité**

$$\frac{dp_t}{dt} + \operatorname{div}(p_t v_t) = 0 \quad (\text{CE})$$

Proposition 1 (réciproque)

$X_0 \sim p_0$ et $(p_t, v_t) \sim (\text{CE})$ + hypothèses de régularité

$$\Rightarrow \quad \forall t \in [0, 1], \quad \phi_t(X_0) \sim p_t$$

Exemple : le **transport optimal** (OT) donne une solution particulière

"ligne droite + vitesse constante"

$$v_t((T^*(x) + (1-t)x) = T^*(x) - x$$

avec T^* plan de transport optimal en coût $\|\cdot\|^2$

Cependant, le OT n'est pas tractable en grande dimension

Le **flow matching** permet de définir un champ v_t "plus simple"

Il donnera un algorithme pour trouver des correspondances point à point entre deux distributions

Définissons

- $X_0 \sim p_0, X_1 \sim p_1$ les deux distributions
- $X_t = tX_0 + (1 - t)X_1$ l'interpolation entre les deux v.a.

aussi une v.a. suivant la loi p_t

- Le champ

$$v_t(x) = \mathbb{E}[X_1 - X_0 \mid X_t = x]$$

directions moyenne de tous les chemins de X_t t.q. $X_t = x$

Proposition 2

Le couple (p_t, v_t) ainsi définit vérifie (CE)

Visualisation ici [\[blog-post\]](#) ou là [\[playground\]](#) (+ détails au tableau)

Précédemment :

- On a défini un couple (p_t, v_t) qui suit (CE)
- on sait échantillonner $X \sim p_0$
- Proposition 1 $\Rightarrow \phi_1(X_0)$ donne un moyen d'échantillonner p_1

Reste à traiter :

- #1 apprendre v_t à partir des données suivant $p_1 = p_{\text{data}}$
- #2 échantillonner avec v_t appris en pratique (intégrer l'ODE)

#1 Conditional flow matching : apprentissage en pratique

Definir un modèle $v_\theta(x, t) : \mathbb{R}^d \times [0, 1] \rightarrow T_x \mathbb{R}^d$

Apprendre le modèle avec la loss

$$\mathcal{L}_{\text{FM}}(\theta) = \mathbb{E}_{x_t, t} \|v_t(x_t) - v_\theta(x_t, t)\|^2$$

mais $v_t(x_t)$ est défini implicitement via une esperance + loi de x_t inconnue

Theoreme (interpolation linéaire)

Le problème de regression $\mathcal{L}_{\text{FM}}(\theta)$ est équivalent à

$$\mathcal{L}_{\text{CFM}}(\theta) = \mathbb{E}_{(x_0, x_1), t, x_t | (x_0, x_1, t)} \|v_t(x_t) - v^{\text{cond}}(x_t | x_0, x_1, t)\|^2$$

avec $v^{\text{cond}}(x_t | x_0, x_1, t) = x_1 - x_0$

Détails et autres possibilités dans Gagneux et al. 2025

#2 Flow matching : échantillonnage en pratique

Echantillonner un point selon p_1

$$\hat{x}_1 = \varphi_{t=1}(x_0) = \text{EDO}^{v_\theta}(x_0, 0 \rightarrow 1), \quad x_0 \sim p_0$$

ou $\text{EDO}^{v_\theta}(\cdot, t_0 \rightarrow t_1)$ résoud le flow (intégration du champ de vitesse) $v_\theta(t, \cdot)$

Méthode d'Euler (K pas)

$$x_{k+1} = x_k + \frac{1}{K} v_\theta(t_k, x_k)$$

ou méthodes plus avancées (Runge-Kutta)

Un exemple visuel