

# DISTANCES

Pr: stabilité/continuité des constructions présentées par Clément et Florel:  
Données initiales "proches"  $\Rightarrow$  Résultats finaux "proches" ?

$X, Y$  esp. métriques  
(nuages de points)

Filtrations de  
complexes simpliciaux  
(Céch ou VR)

Diagrammes de  
Persistance  
 $dgm(X), dgm(Y)$

Théorème:  $D_b(dgm(X), dgm(Y)) \leq 2 \cdot D_{GH}(X, Y)$

distance Bottleneck

distance de Gramou-Hausdorff.

## 1 - Distances de Hausdorff & Gramou-Hausdorff. (BBI, chap. 7)


Définition:  $(M, d)$  esp. métrique,  $\mathcal{K}(M) = \{\text{compacts de } M\}$ ,  $X, Y \in \mathcal{K}(M)$ .

$$D_H(X, Y) = \inf \{ t > 0 \mid X \subset Y_t \text{ et } Y \subset X_t \}$$
$$= \max \left( \max_{x \in X} (d(y, x)), \max_{y \in Y} (d(x, y)) \right)$$

où  $X_t = \{ d(x, \cdot) < t \}$


$= \bigcup_{x \in X} B(x, t)$   $t$ -voisinage de  $X$ .

Thm:  $D_H$  est une distance sur  $\mathcal{K}(M)$



Exemples:  $(M, d) = \mathbb{R}^2$ , euclidien.

•  $X = [0, 1]^2$ ,  $x_1, \dots, x_N \in X$



$X_k = X \setminus \bigcup_{i=1}^N B(x_i, \frac{1}{k})$

$D_H(X, X_k) = \frac{1}{k}$  donc  $X_k \xrightarrow{D_H} X$

Pas de continuité de la topologie.

• "La convergence Hausdorff est une c.v.  $C^0$ "

$f, f_k : [0, 1] \rightarrow \mathbb{R}$  continues




$G, G_k$  graphes de  $f, f_k$



$G_k \xrightarrow{D_H} G$  n'est pas  $f_k \xrightarrow{C^0} f$

(On a  $D_H(G_f, G_g) \leq \|f - g\|_\infty$ , mais pas d'inégalité dans l'autre sens  $f_k \xrightarrow{C^0} f, G_k \rightarrow \dots$ )

• Ex: Pas de continuité de la mesure de Hausdorff 1-dim.



$\|f_k\|_\infty \rightarrow 0$  donc  $G_k \xrightarrow{D_H} [0, 1] \times \{0\}$

$\mathcal{H}^1(G_k) = \frac{\pi}{2}$  et  $\mathcal{H}^1(G) = 1$ .

•  $X = [0, 1]^2$ ,  $X_k = \frac{1}{k} \mathbb{Z}^2 \cap [0, 1]^2 = \left\{ \left( \frac{i}{k}, \frac{j}{k} \right) \mid i, j \in [0, k] \right\}$

$D_H(X_k, X) = \frac{1}{k\sqrt{2}}$ , donc  $X_k \xrightarrow{D_H} X$

et  $\mathcal{H}^2(X_k) = 0$ ,  $\mathcal{H}^2(X) = 1$ .

Pas de continuité du volume.

## Propriétés:

- $\begin{cases} \mathcal{K}(M) \longrightarrow \mathbb{R} \\ x \longmapsto \text{diam} \end{cases}$  est 2-lipschitzienne.
- Si  $(M, d)$  est compact (resp. complet) alors  $(\mathcal{K}(M), D_H)$  est compact (resp. complet)
- Dans  $\mathbb{R}^n$  euclidien,  $x \mapsto \mathcal{H}^n(x)$  est s.c.s.  
 $\limsup(\mathcal{H}^n(x_k)) \leq \mathcal{H}^n(x)$  si  $x_k \xrightarrow{D_H} x$

La bonne nouvelle: le dernier exemple montre qu'un réseau de points "assez serrés" est  $D_H$ -proche de  $X$

## Distance de Gromov-Hausdorff:

Dans  $\mathbb{R}^2$ ,  $\tau_u$  translation de vecteur  $u$ .

$X$  et  $\tau_u(X)$  "sont les mêmes" mais  $D_H(X, \tau_u(X)) = |u|$

Définition:  $(X_1, d_1)$  et  $(X_2, d_2)$  espaces métriques compacts

$$D_{GH}(X_1, X_2) = \inf \left\{ t > 0 \mid \begin{array}{l} \exists (M, d) \text{ esp. métrique, } \phi_i: X_i \rightarrow M \text{ injections} \\ \text{t.q. } D_{GH}^M(\phi_1(X_1), \phi_2(X_2)) < t \end{array} \right.$$

isométriques

$X_1 = X$ ,  $X_2 = \tau_u(X)$ ,  $(Y, d) = (\mathbb{R}^2, \|\cdot\|_2)$ ,  $\phi_1 = +\text{Id}$ ,  $\phi_2 = \tau_{-u}$

$$D_H(\phi_1(X_1), \phi_2(X_2)) = D_H(X, \tau_{-u}(\tau_u(X))) = D_H(X, X) = 0.$$

Donc  $D_{GH}(X_1, X_2) = 0$ .

Théorème:  $D_{GH}$  est une "distance":

- Positive, symétrique, inégalité triangulaire.
- $D_{GH}(X_1, X_2) = 0$  ~~est~~ si  $X_1$  et  $X_2$  isométriques.

Rq: Si  $X_1, X_2 \subset (M, d)$ ,  $D_{GH}(X_1, X_2) \leq D_H^M(X_1, X_2)$   
les exemples précédents sont aussi des exemples de c.v. G-H.

## L'importance des images de points


•  $(X, d)$  est un  $\varepsilon$ -réseau si  $X = \bigcup_{x \in S} B(x, \varepsilon)$

En particulier,  $D_{GH}(S, X) \leq \varepsilon$  ou  $\forall x \in X \quad d(S, x) < \varepsilon$ .

•  $(X, d_x)$  et  $(Y, d_y)$  sont des  $\varepsilon$ -approx. l'un de l'autre s'il existe des  $\varepsilon$ -réseaux  $S_\varepsilon = \{x_1, \dots, x_N\} \subset X$  et  $T_\varepsilon = \{y_1, \dots, y_N\} \subset Y$  t.q.  $\forall i, j \quad |d_x(x_i, x_j) - d_y(y_i, y_j)| < \varepsilon$

### Proposition:

1. Si  $X$  et  $Y$  sont  $\varepsilon$ -approx l'un de l'autre, alors  $D_{GH}(X, Y) \leq 3\varepsilon$ .
2. Si  $D_{GH}(X, Y) \leq \varepsilon$  alors  $X$  et  $Y$  sont des  $5\varepsilon$ -approx l'un de l'autre.



$$D_b(d_{GH}(T_\varepsilon), d_{GH}(S_\varepsilon)) \leq 2 \cdot D_{GH}(T_\varepsilon, S_\varepsilon) \leq 2 \cdot D_{GH}(X, Y) + 4\varepsilon$$

Critère de compacité:  $(X_n, d_n)_{n \in \mathbb{N}}$  esp. métriques compacts.

- Si
1.  $\exists D \quad \forall n \quad \text{diam}(X_n) \leq D$
  2.  $\forall \varepsilon > 0 \quad \exists N \quad \forall n \quad X_n$  admet une  $\varepsilon$ -<sup>réseau</sup>approx.
- $S_n \subset X_n$  t.q.  $\#(S_n) \leq N$ .

Alors  $(X_n, d_n)_{n \in \mathbb{N}}$  admet une s.ète qui c.v. G.H.

## 2 - Distances entre diagrammes de persistance.

Les diagrammes de persistance sont des familles de points de  $\mathbb{R}^2$  qui encodent les changements de l'homologie de  $\check{Cech}_t(X_0)$  ou  $Rip_t(X_0)$  quand  $t$  évolue. On les note comme des  $n$ -uplets pour tenir compte des multiplicités.

$$dgm(X) = (x_1, \dots, x_n) \subset \left\{ (s, t) \in \mathbb{R}^2 \mid 0 \leq s < t \right\} =: \mathcal{D}$$


$\left\{ \begin{array}{l} \uparrow \\ \text{apparition} \end{array} \right.$        $\left\{ \begin{array}{l} \leftarrow \\ \text{disparition} \end{array} \right.$

Il y a un diagramme par dimension d'homologie, et chacun des  $x_i$  correspond à une barre du code-barre

Pour définir une distance entre diagrammes, on "marie" leurs points.

$$dgm_1 = (x_1, \dots, x_n)$$

$$dgm_2 = (y_1, \dots, y_p)$$



Un "mariage partiel" de  $n$  et  $p$  éléments est  $\Pi \subset \llbracket 1, n \rrbracket \times \llbracket 1, p \rrbracket$  t.q.

$$\forall i \in \llbracket 1, n \rrbracket \quad \#(\Pi \cap \{i\} \times \llbracket 1, p \rrbracket) \leq 1$$

$$\forall j \in \llbracket 1, p \rrbracket \quad \#(\Pi \cap \llbracket 1, n \rrbracket \times \{j\}) \leq 1$$

"Pas de polygamie"

Si  $\Pi$  est un mariage partiel, on note

$$C_1(\Pi) = \{ i \in \llbracket 1, n \rrbracket \mid \Pi \cap \{i\} \times \llbracket 1, p \rrbracket = \emptyset \}$$

$$C_2(\Pi) = \{ j \in \llbracket 1, p \rrbracket \mid \Pi \cap \llbracket 1, n \rrbracket \times \{j\} = \emptyset \}$$

"les célibataires"

Le coût du mariage est

$$J_{\infty}(\Pi) = \text{Max} \left[ \left\{ \|x_i - y_j\| \mid (i, j) \in \Pi \right\} \cup \left\{ \|x_i - \pi_{\Delta}(x_i)\| \mid i \in C_1(\Pi) \right\} \cup \left\{ \|y_j - \pi_{\Delta}(y_j)\| \mid j \in C_2(\Pi) \right\} \right]$$

où  $\pi_{\Delta}$  est la proj.  $\perp$  sur  $\Delta$ .

Définition:  $D_b(dg_{m_1}, dg_{m_2}) = \sqrt[b]{\liminf \{ J_b(M) \mid M \text{ nuage partiel} \}}$

De façon analogue on définit pour  $r \geq 1$

$$J_r(M) = \sum_{(i,j) \in \Gamma} \|x_i - y_j\|^r + \sum_{i \in C_1(M)} \|x_i - \pi_D(x_i)\|^r + \sum_{i \in C_2(M)} \|y_i - \pi_D(y_i)\|^r$$

$$\text{et } W_r(dg_{m_1}, dg_{m_2}) = \left[ \liminf (J_r(M)) \right]^{1/r}$$




"distance de Wasserstein" ~~est~~ Des résultats de stabilité existent aussi pour  $W_n$ , mais il faut des hypothèses. ??

Un exemple:

$$X = \{a, b\} \subset \mathbb{R}^2 \quad \text{avec } \|a - b\| = 2$$

$X_n = 8$  points à dist.  $\frac{1}{n}$  de  $a$  ou  $b$ .  
comme sur le dessin.

Codes-barres pour ~~les mesures~~  $H_0(\check{C}_t(x))$  et  $H_0(\check{C}_t(x_n))$



$$D_b(dg_m(x), dg_m(x_n)) = \frac{1}{n}$$

$$W_1(dg_m(x), dg_m(x_n)) = \frac{1}{n} + 6 \cdot \frac{1}{2n}$$

$$D_{GH}(X, X_n) = \frac{1}{n}$$

Le nombre de point du nuage  $X_n$  apparaît dans le calcul de  $W_1$ . Possibilité dans l'esp. de Hilbert  $\ell^2$  de construire  $X_n, X = \{a, b\}$  tels que  $X_n \xrightarrow{G.H.} X$  et  $\lim_{n \rightarrow \infty} W_1(dg_m(x), dg_m(x_n)) = c > 0$ .

Une autre façon d'écrire  $D_b$  et  $W_r$ .

$$\bar{\mathcal{D}} = \mathcal{D} \cup \{\Delta\} \quad (\text{où } \mathcal{D} = \{(s, t) \mid 0 \leq s < t\})$$

$$d: \bar{\mathcal{D}} \rightarrow \mathbb{R}$$

$$d(x, y) = \|x - y\| \quad \text{si } x, y \in \mathcal{D}$$

$$d(x, \Delta) = d(\Delta, x) = \|x - \pi_\Delta(x)\| \quad \text{si } x \in \mathcal{D}$$


$$d(\Delta, \Delta) = 0.$$

WARNING:  $d$  n'est pas une distance sur  $\bar{\mathcal{D}}$ :

$$d(x, z) \leq d(x, y) + d(y, z) \quad \text{si } x, y, z \in \mathcal{D}$$

$$d(x, \Delta) \leq d(x, y) + d(y, \Delta) \quad \text{si } x, y \in \mathcal{D}, y \neq \Delta$$

$$\text{mais } d(x, z) \not\leq d(x, \Delta) + d(\Delta, z) \quad \text{si } x, z \in \mathcal{D}$$



$$dgm_1 = (x_1, \dots, x_m) \in \mathcal{D}_1^m \quad dgm_2 = (y_1, \dots, y_p) \in \mathcal{D}_2^p$$

$$\bar{dgm}_1 = (x_1, \dots, x_m, \underbrace{\Delta_1, \Delta_2, \dots, \Delta_p}_{\substack{p \\ x_{m+1}, \dots, x_{m+p}}}) \in (\bar{\mathcal{D}})^{m+p}$$

$$\bar{dgm}_2 = (y_1, \dots, y_p, \underbrace{\Delta_1, \dots, \Delta_m}_{\substack{m \\ y_{p+1}, \dots, y_{p+m}}})$$

$$\text{Si } \sigma \in \mathcal{J}_{m+p} \quad \bar{J}_\infty(\sigma) = \max_{i \in \{1, \dots, m+p\}} (d(x_i, y_{\sigma(i)})) \quad , \quad \bar{J}_r(\sigma) = \left( \sum_{i=1}^{m+p} d(x_i, y_{\sigma(i)})^r \right)^{1/r}$$

$$\sigma \in \mathcal{J}_{m+p} \xrightarrow{\Phi} \text{ mariage partiel } M \text{ de } dgm_1 \text{ et } dgm_2 \quad (\text{on oublie les } \Delta \leftrightarrow \Delta)$$

$$\text{et } \bar{J}_\infty(\sigma) = J_\infty(M)$$

$$\bar{J}_r(\sigma) = J_r(M)$$

$$\text{Si } M \text{ est un mariage partiel, } \forall \sigma \in \Phi^{-1}(M) \quad \bar{J}_\infty(\sigma) = J_\infty(M) \text{ et } \bar{J}_r(\sigma) = J_r(M).$$

$$D_b(dgm_1, dgm_2) = \min_{\sigma \in \mathcal{J}_{m+p}} (\bar{J}_\infty(\sigma)) = \min_{\sigma \in \mathcal{J}_{m+p}} \left[ \max_{i \in \{1, \dots, m+p\}} (d(x_i, y_{\sigma(i)})) \right]$$

$$W_r(dgm_1, dgm_2) = \left[ \min_{\sigma \in \mathcal{J}_{m+p}} \left( \sum_{i=1}^{m+p} d(x_i, y_{\sigma(i)})^r \right) \right]^{1/r}$$

Ecrites comme ça, ces distances ressemblent beaucoup à des distances de Wasserstein sur des espaces de mesures  $\rightarrow$  utile pour les calculs.

## Preuve de l'inégalité triangulaire.

$$dgm_1 = (x_1, \dots, x_n) \quad , \quad dgm_2 = (y_1, \dots, y_p) \quad , \quad dgm_3 = (z_1, \dots, z_q)$$

$$\begin{array}{l} \overline{dgm}_1 = \overbrace{\Delta, \dots, \Delta}^q, x_1, \dots, x_n, \overbrace{\Delta, \dots, \Delta}^p \\ \downarrow \qquad \qquad \qquad \downarrow \\ \overline{dgm}_2 = \overbrace{\Delta, \dots, \Delta}^q, y_1, \dots, y_p, \overbrace{\Delta, \dots, \Delta}^m \\ \downarrow \qquad \qquad \qquad \downarrow \\ \overline{dgm}_3 = \overbrace{\Delta, \dots, \Delta}^p, z_1, \dots, z_q, \overbrace{\Delta, \dots, \Delta}^m \end{array} \quad \left. \begin{array}{l} \sigma \\ \tau \end{array} \right\}$$

On choisit  $\sigma \neq \tau \in \mathcal{Y}_{n+p+q}$  t.q.  $D_b(dgm_1, dgm_2) = \overline{J}_\infty(\sigma)$

et  $D_b(dgm_2, dgm_3) = \overline{J}_\infty(\tau)$

$$D_b(dgm_1, dgm_3) \leq \overline{J}_\infty(\tau \circ \sigma) = \max_{i \in \llbracket 1, n+p+q \rrbracket} (d(x_i, z_{\tau \circ \sigma(i)}))$$

Rque:  $y_{\sigma(i)} = \Delta \iff (x_i = \Delta \text{ ou } z_{\tau \circ \sigma(i)} = \Delta)$

on évite le cas problématique d' l'ind. triangulaire.

D'où  $\forall i \in \llbracket 1, n+p+q \rrbracket \quad d(x_i, z_{\tau \circ \sigma(i)}) \leq d(x_i, y_{\sigma(i)}) + d(y_{\sigma(i)}, z_{\tau \circ \sigma(i)})$

$$\begin{aligned} D_b(dgm_1, dgm_3) &\leq \max_i (d(x_i, y_{\sigma(i)})) + \max_i (d(y_{\sigma(i)}, z_{\tau \circ \sigma(i)})) \\ &\leq \overline{J}_\infty(\sigma) + \overline{J}_\infty(\tau) = D_b(dgm_1, dgm_2) + D_b(dgm_2, dgm_3) \end{aligned}$$

Liens avec la distance de Wasserstein usuelle:

$(E, d_E)$  esp. métrique,  $c(x, y) = d_E(x, y)^2$  coût de transport d'une unité de masse de  $x$  à  $y$ .

$\mu, \nu \in \mathcal{P}(E) = \{ \text{mesures de proba sur } E \}$

Un "transport"  $\gamma$  de  $\mu$  à  $\nu$  a un coût global  $\overline{J}_r(\gamma)$

qui est une "somme des coûts ponctuels".

$\widetilde{W}_r(\mu, \nu) = \left[ \inf_{\gamma} (\overline{J}_r(\gamma)) \right]^{1/r}$  est une distance <sup>de Wasserstein</sup> sur  $\mathcal{P}(E)$

(Il faut une bonne notion de "transport" pour que l'inf soit fini.)



cas particulière:  $\mu = \frac{1}{N} \sum_{i=1}^N \delta_{x_i}$  et  $\nu = \frac{1}{N} \sum_{j=1}^N \delta_{y_j}$

On montre dans ce cas que

$$\tilde{W}_r(\mu, \nu) = \frac{1}{N^{1/r}} \left[ \min_{\sigma \in \mathcal{S}_N} \left( \sum_{i=1}^N d_E(x_i, y_{\sigma(i)})^r \right)^{1/r} \right]$$

Retour aux diagrammes:

$$dgm_1 = (x_1, \dots, x_n) \rightsquigarrow \mu_1 = \frac{1}{n+p} \left( \sum_{i=1}^n \delta_{x_i} + p \delta_D \right)$$

$$dgm_2 = (y_1, \dots, y_p) \rightsquigarrow \mu_2 = \frac{1}{n+p} \left( \sum_{j=1}^p \delta_{y_j} + n \delta_D \right)$$

$$\mu_1, \mu_2 \in \mathcal{P}(\bar{\mathcal{D}})$$

$$W_r(dgm_1, dgm_2) = (n+p)^{1/r} \tilde{W}_r(\mu_1, \mu_2)$$

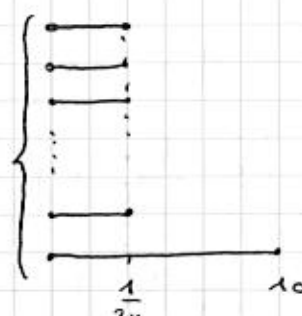
Deux remarques:


- $d$  n'est pas une distance sur  $\bar{\mathcal{D}}$ , donc le  $\tilde{W}_r$  construit à partir de  $d$  n'est pas une distance sur  $\mathcal{P}(\bar{\mathcal{D}})$ .
- La mesure  $\mu_1$  dépend de  $dgm_1$  et  $dgm_2$  (à travers  $p$ ). De même pour  $\mu_2$ . En particulier, on ne plonge pas l'espace des diagrammes dans un espace de mesures.

Un autre exemple:  $H_0(\check{C}_t(x))$  et  $H_0(\check{C}_t(x_n))$  où

$$X = [0, 1] \quad , \quad X_n = \left\{ \frac{k}{n} \mid k \in \mathbb{I}0, 1\mathbb{I} \right\}$$

$dgm(x)$ : 

$dgm(x_n)$ : 



$$D_b(dgm(x), dgm(x_n)) = \frac{1}{n \cdot 2\sqrt{2}} \quad \text{et} \quad W_1(dgm(x), dgm(x_n)) = n \times \frac{1}{n \cdot 2\sqrt{2}} = \frac{1}{2\sqrt{2}}$$

$$D_{GH}(x_n, x_{2n}) = \frac{1}{2n}$$

• Pour comparer deux nuages de points: le mariage optimal pour  $D_b$  et  $W_1$  consiste à envoyer les  $n$  points  $(0, \frac{1}{2n})$  de  $dgm(x_n)$  sur  $n$  points  $(0, \frac{1}{4n})$  de  $dgm(x_{2n})$ , ce qui donne

$$D_b(dgm(x_n), dgm(x_{2n})) = \frac{1}{4n} \quad \text{et} \quad W_1(dgm(x_n), dgm(x_{2n})) = \frac{1}{4} + \frac{1}{4\sqrt{2}}$$

mais  $\lim_{n \rightarrow \infty} D_{GH}(x_n, x_{2n}) = 0$