
Intelligence artificielle et médecine

N. Hascoët – Prof. F. Chinesta

ENSAM

17 juin 2019

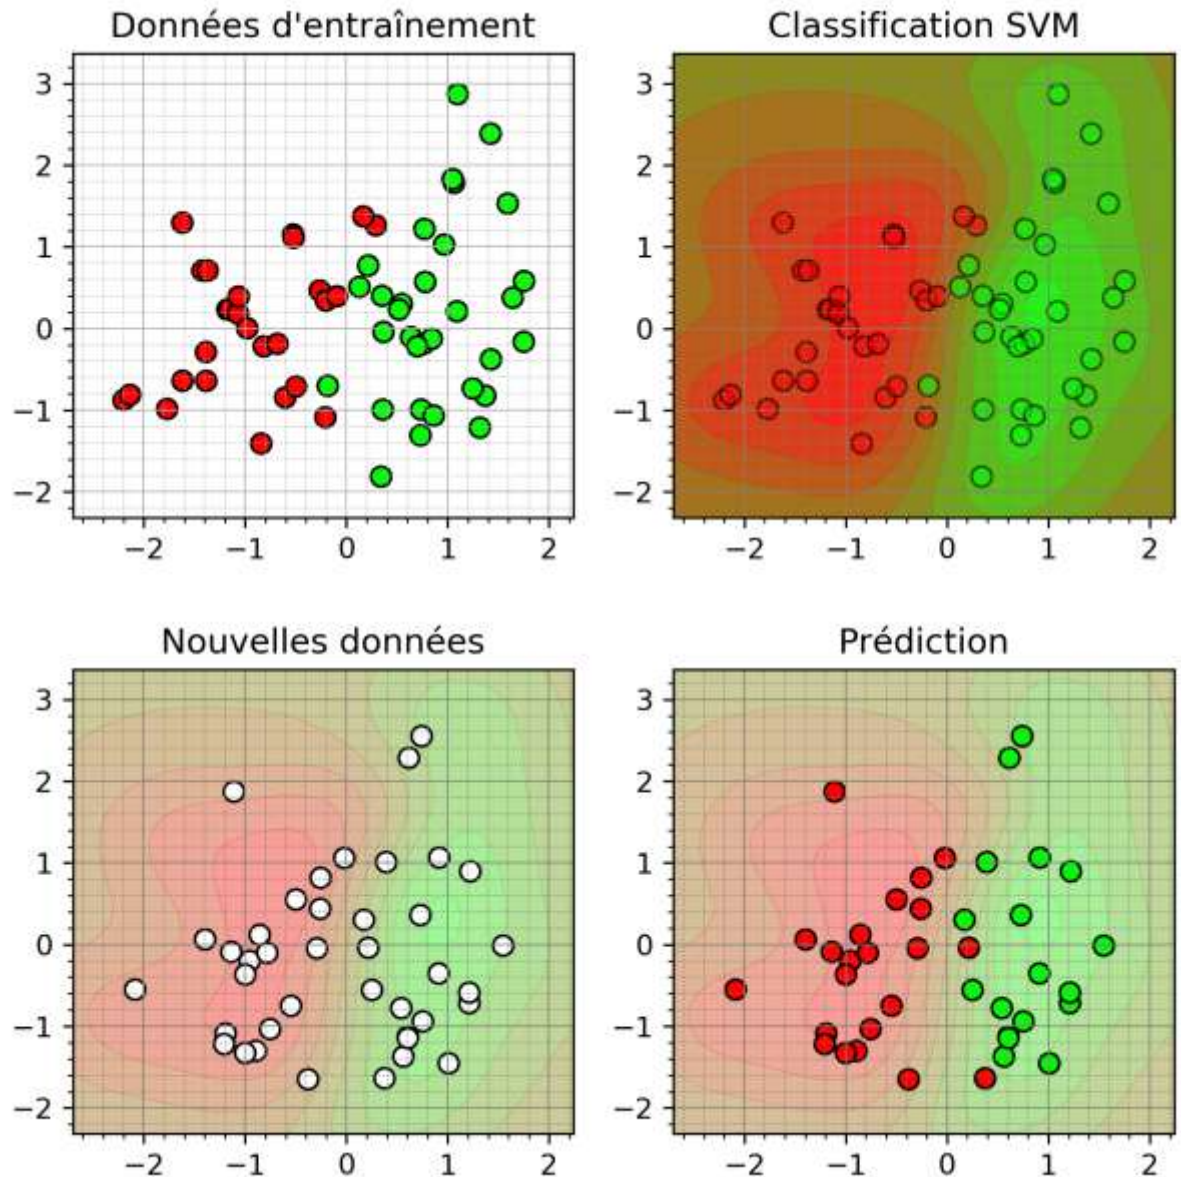
Sommaire

1. Machine Learning
2. Imagerie et reconnaissance d'objets
3. Code2Vect
4. Réduction de modèles

1. Machine Learning

→ Apprentissage supervisé
(ex : classification avec SVM)

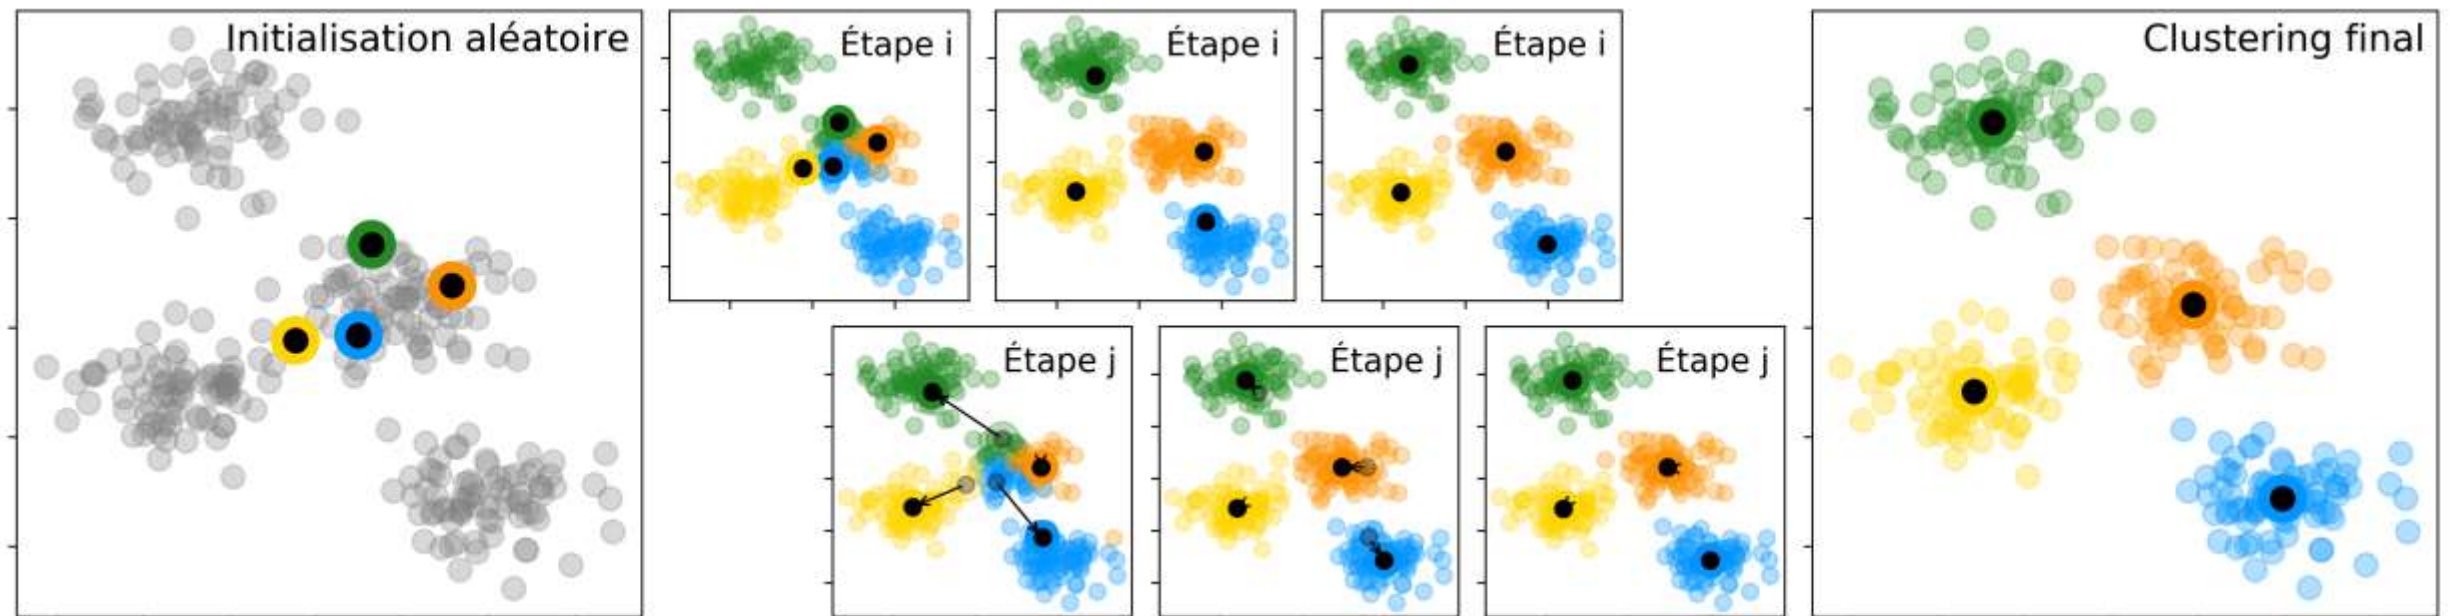
- Les données sont connues et étiquetées
- Étape 1 : entraînement (offline)
 - Calcul d'une frontière
- Étape 2 : prédiction (online)



1. Machine Learning

→ Apprentissage non-supervisé (ex : clustering avec K-Means)

- Données inconnues
- Nécessite une **métrique** ou un critère pour rassembler *les plus proches*




Sommaire

1. Machine Learning
2. Imagerie et reconnaissance d'objets
3. Code2Vect
4. Réduction de modèles

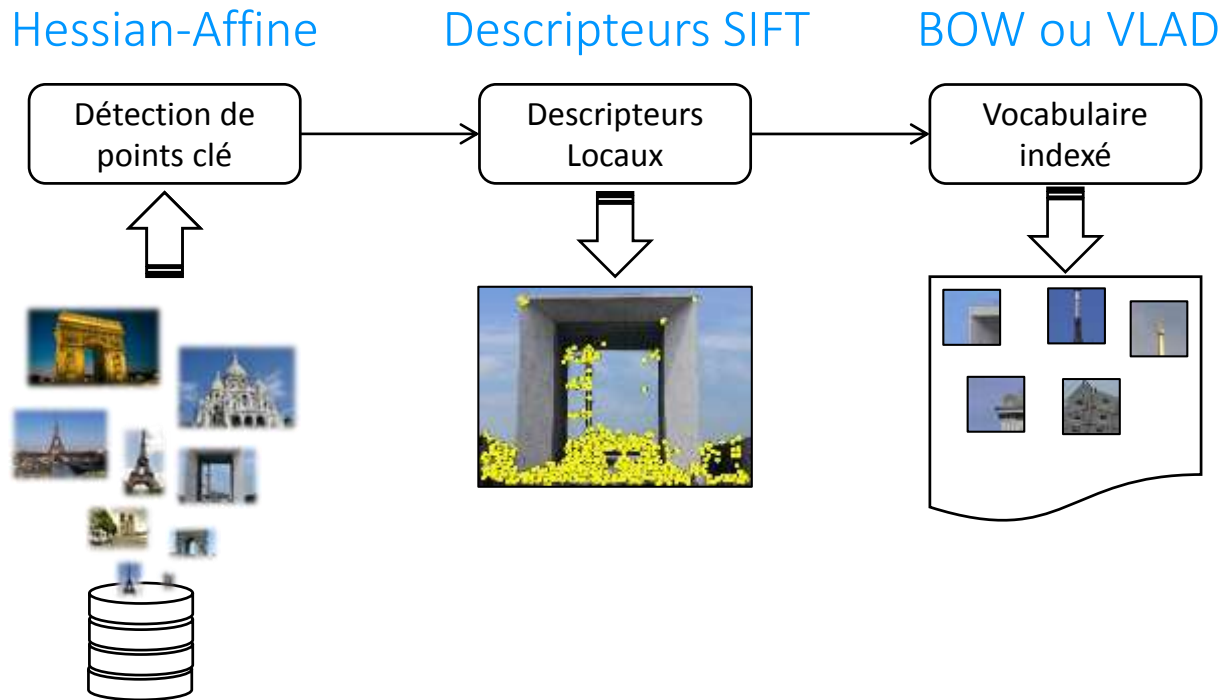
2. Imagerie et reconnaissance d'objets

Reconnaître un **objet d'intérêt** à partir d'une photo requête dans une base de donnée d'images étiquetées

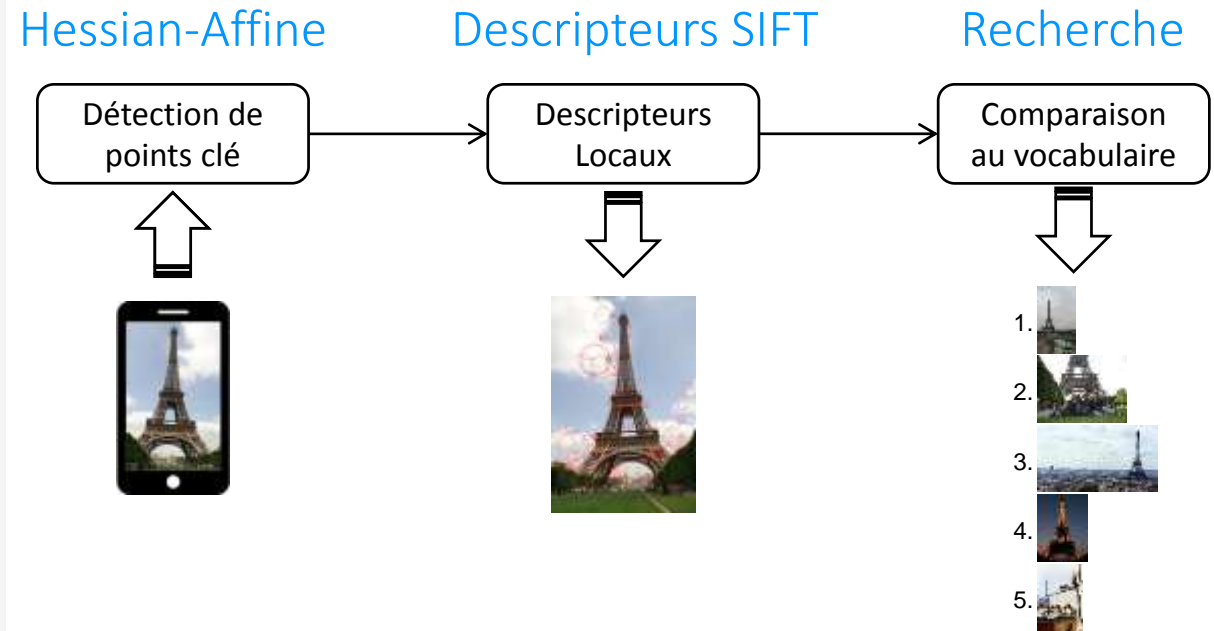


2. Imagerie et reconnaissance d'objets

Construction d'un vocabulaire (OFFLINE)



Requête d'une image (ONLINE)



2. Imagerie et reconnaissance d'objets

→ Point d'intérêt

- Maximum de variation de **gradient d'image** (\approx direction de la variation d'intensité)
- Maximum d'information **discriminante**

→ Détecteur Hessian-affine \Rightarrow Matrice Hessienne normalisée

- Analyse dans un espace échelle Gaussien
- Bonnes propriétés de **répétabilité** et **invariance** par rapports à **l'échelle** et à **la pose**

$$\mathcal{H}_\sigma(x, y) = \begin{bmatrix} \frac{\partial I_\sigma(x, y)}{\partial x^2} & \frac{\partial I_\sigma(x, y)}{\partial x \partial y} \\ \frac{\partial I_\sigma(x, y)}{\partial y \partial x} & \frac{\partial I_\sigma(x, y)}{\partial y^2} \end{bmatrix}$$

2. Imagerie et reconnaissance d'objets

→ Descripteurs locaux d'image **SIFT** (Scale Invariant Feature Transform)


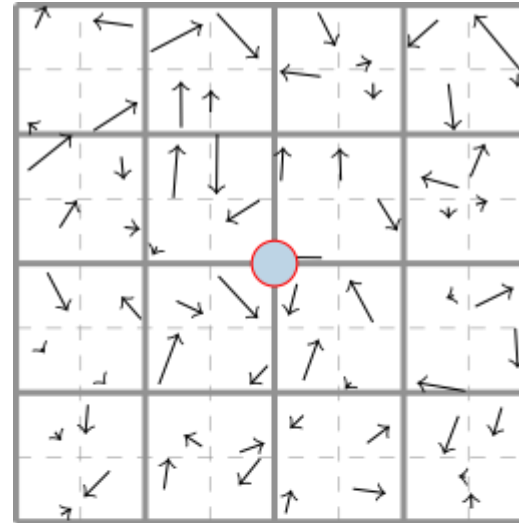
- \forall point d'intérêt détecté \Rightarrow gradient d'image \mathcal{L}
- \mathcal{L} défini par son amplitude m et son orientation θ

$$\mathcal{L}(x, y) : \begin{cases} m(x, y) = \sqrt{\Delta_x^2 + \Delta_y^2} \\ \theta(x, y) = \tan^{-1}\left(\frac{\Delta_y}{\Delta_x}\right) \end{cases}$$

$$\text{avec : } \begin{cases} \Delta_x = \mathcal{L}(x + 1, y) - \mathcal{L}(x - 1, y) \\ \Delta_y = \mathcal{L}(x, y + 1) - \mathcal{L}(x, y - 1) \end{cases}$$


2. Imagerie et reconnaissance d'objets

- Voisinage de (16×16)
- 16 sous-zones de 4×4
- **Histogramme de gradient orienté (HOG)** de 8 intervalles pour chaque sous-zone
- HOG pour chacune des 16 sous-zones $\Rightarrow 16 \times 8 = 128$
- Un mot visuel \Leftrightarrow vecteur de **128 composantes**



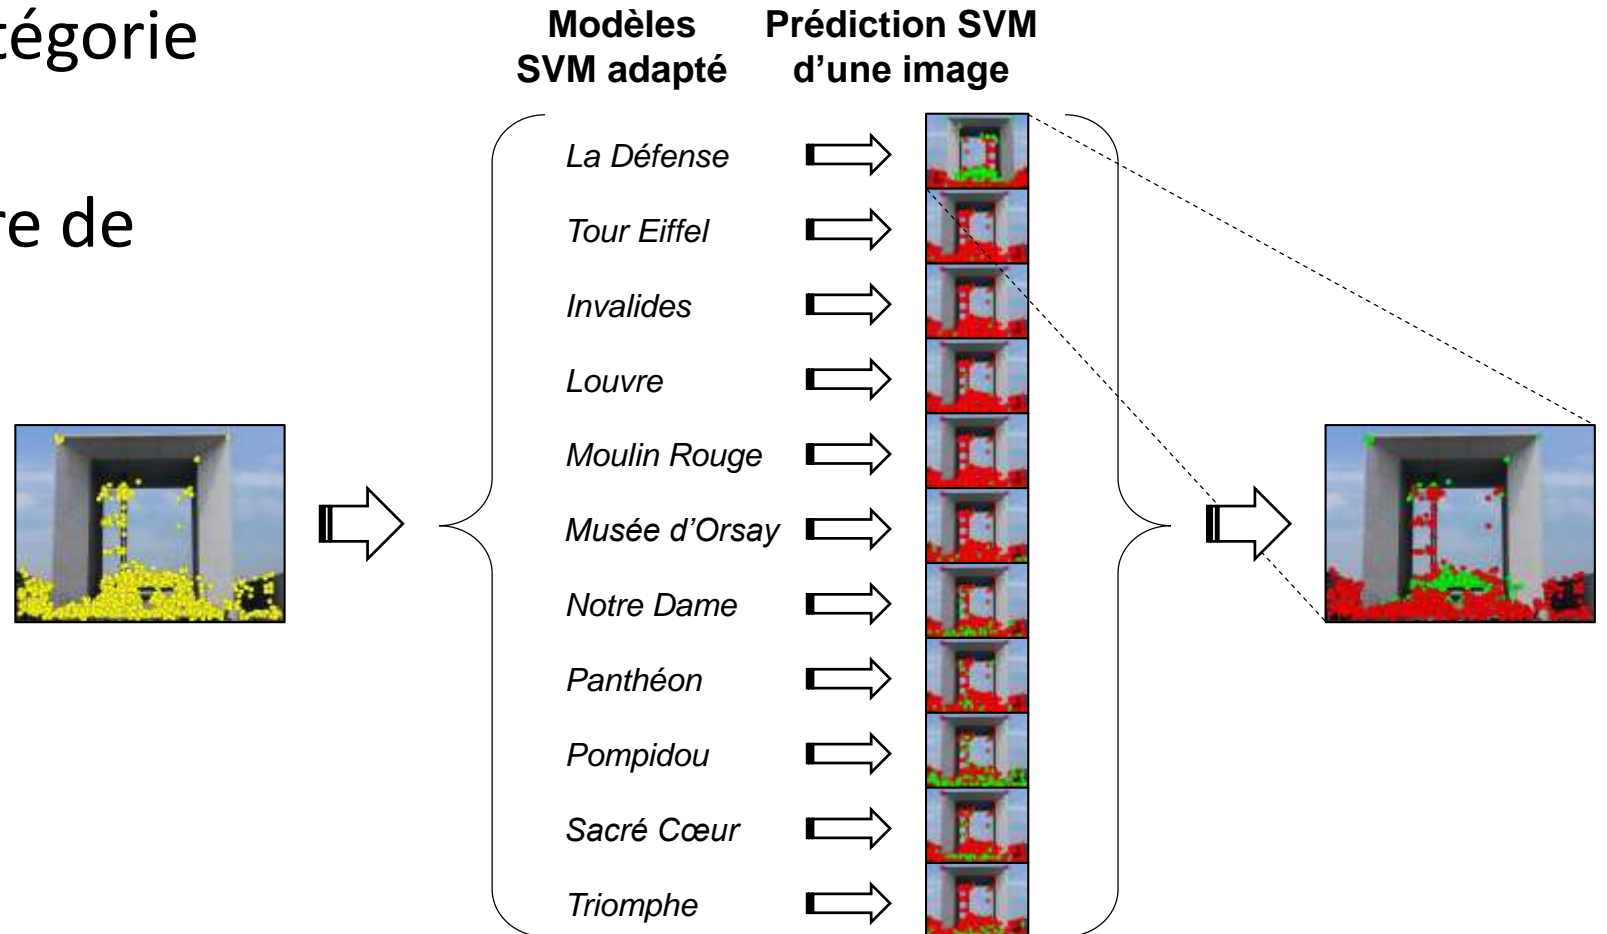
2. Imagerie et reconnaissance d'objets

Approche de description par points d'intérêt avec **filtrage binaire** des points d'intérêts locaux en **bâtiment/non-bâtiment**











2. Imagerie et reconnaissance d'objets

- Un classifieur par catégorie de bâtiment
- Définition d'un critère de sélection *a priori*



2. Imagerie et reconnaissance d'objets




2. Imagerie et reconnaissance d'objets




defense



eiffel



invalides



louvre




moulinrouge




museedorsay




notredame



pantheon



pompidou



sacrecoeur



trionphe

2. Imagerie et reconnaissance d'objets







- Choix du classifieur SVM avec le plus haut score de confiance

$$\hat{P}_I = \frac{\sum_{x \in \text{building}} P(x)}{|\text{x} \in \text{building}|}$$

avec $P(x)$ le score de confiance SVM pour un point d'intérêt donné :

$$P(x) = \frac{1}{1 + \exp(-|\Delta|)}$$

2. Imagerie et reconnaissance d'objets



Sommaire

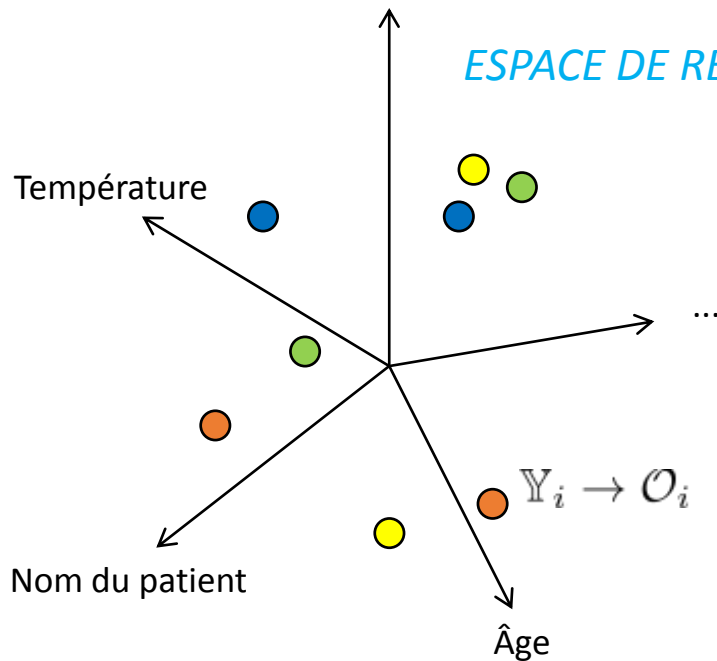
1. Machine Learning
2. Imagerie et reconnaissance d'objets
- 3. Code2Vect**
4. Réduction de modèles

3. Code2Vect

- Espace de représentation hétérogène
- Corrélation entre paramètres et résultat


Durée des soins

ESPACE DE REPRÉSENTATION



$$\mathbb{X} = W_Y \mathbb{Y}$$


ESPACE VECTORIEL



$$W(\mathbb{Y}_i - \mathbb{Y}_j)^2 = (\mathbb{X}_i - \mathbb{X}_j)^2 = |\mathcal{O}_i - \mathcal{O}_j|^2$$

3. Code2Vect

- Prédiction d'un résultat (classification, régression, etc.)
- Corrélations entre paramètres et résultats



Sommaire

1. Machine Learning
2. Imagerie et reconnaissance d'objets
3. Code2Vect
4. Réduction de modèles

4. Réduction de modèles

→ PGD (Proper Generalized Decomposition)

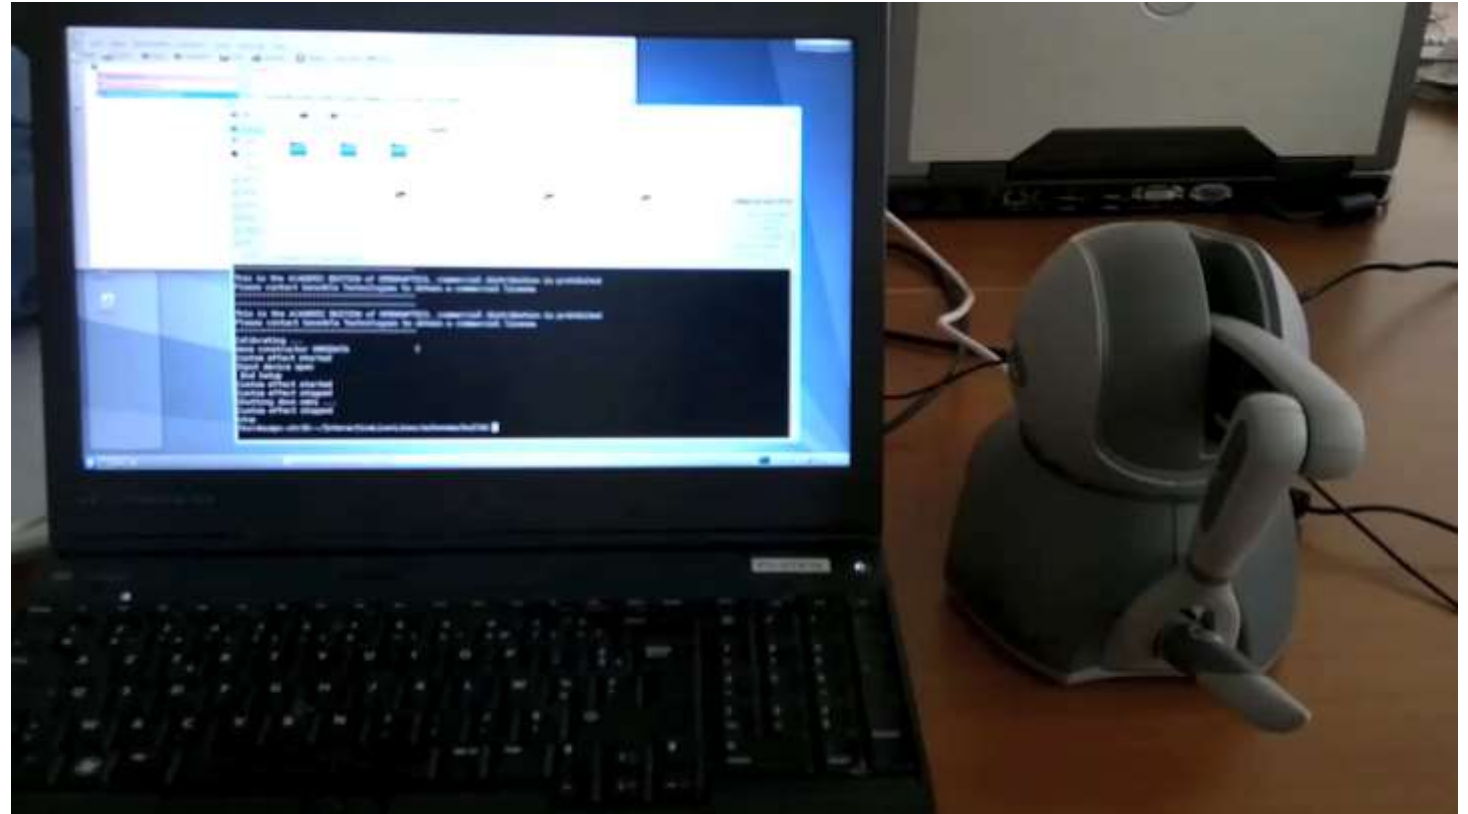
- Paramètres (μ, η, χ) → modèle éléments finis $u(x, t)$

$$u(x, t, \mu, \eta, \chi) = \sum_i X_i(x) T_i(t) M_i(\mu) E_i(\eta) \Xi_i(\chi)$$

- Solution paramétrique calculée OFFLINE
- Utilisable en temps réel ONLINE

4. Réduction de modèles

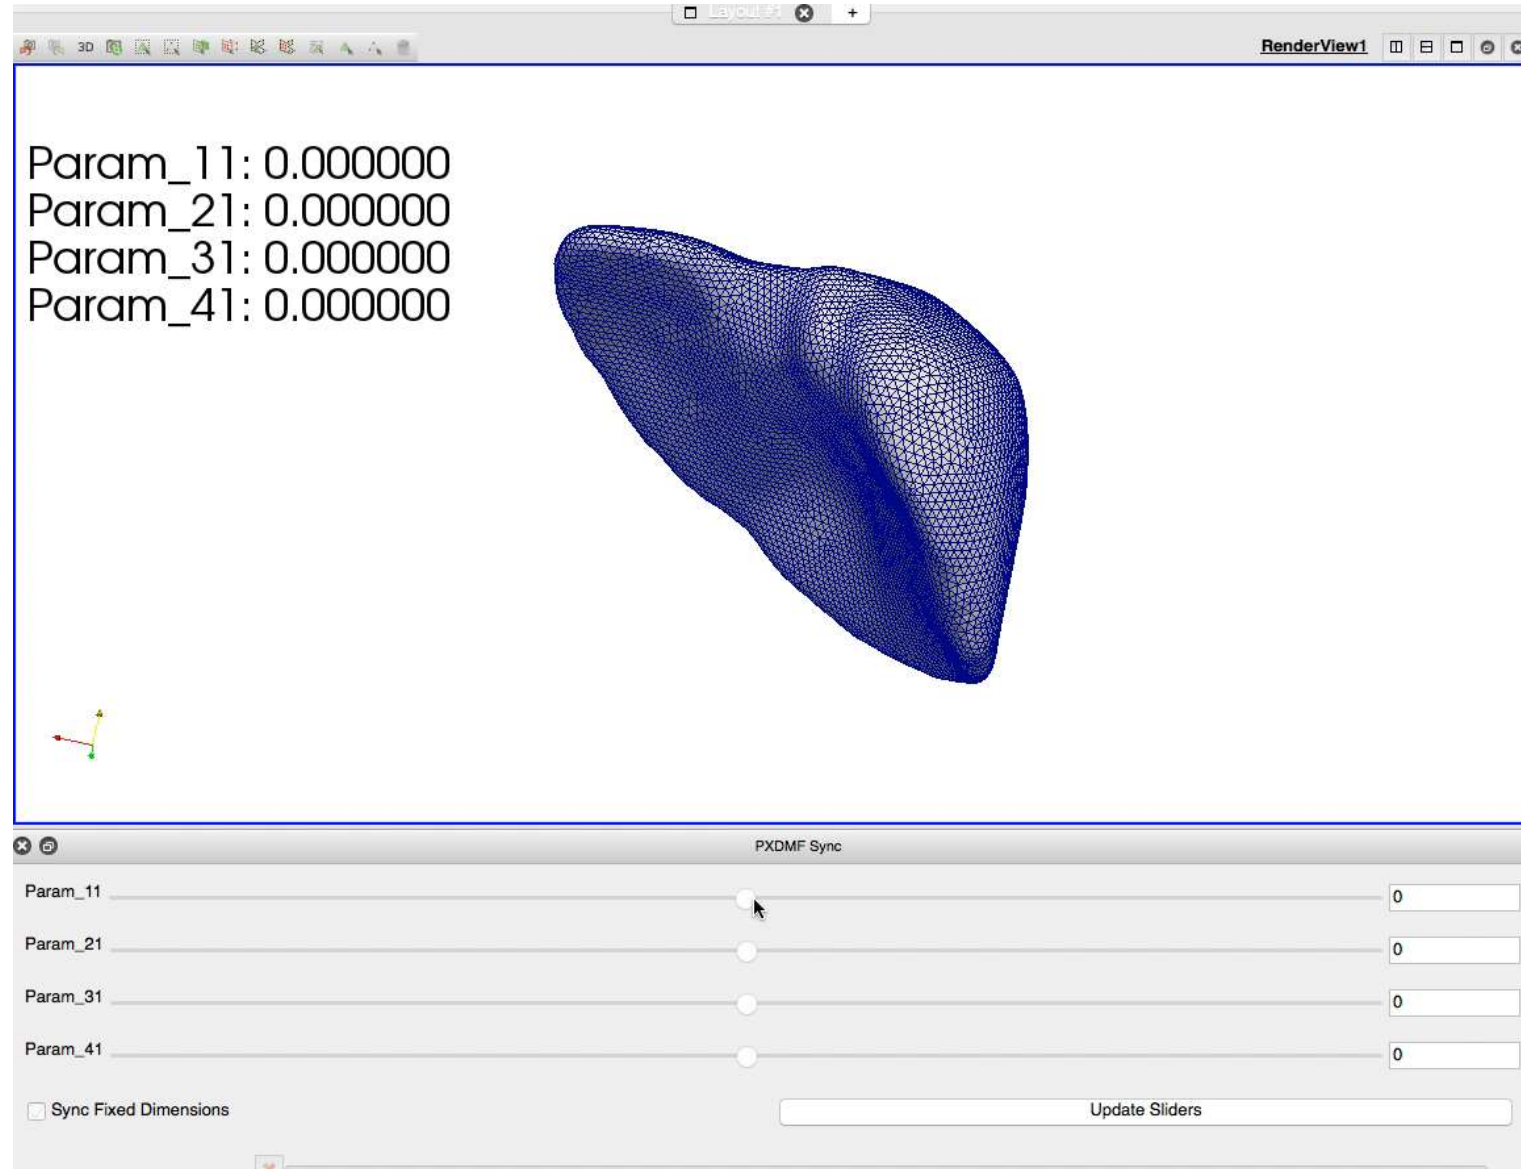
- Simulation de chirurgie sur un foie en **Réalité Augmentée**
- Calcul la force appliquée
- Retour haptique en temps réel



University of Zaragoza

4. Réduction de modèles

- Modèle de la forme d'un foie
- A partir d'une multitude de paramètres \Rightarrow seulement 4 paramètres non-corrélés



Intelligence artificielle et médecine

1. *Classification et clustering*
2. *Reconnaissance d'images*
3. *Code2Vect*
4. *PGD*