


# Diffusion sur graphes, construction de classificateurs parcimonieux : deux approches pour le traitement d'images microscopiques

Olivier Lezoray

`olivier.lezoray@unicaen.fr`

Université de Caen Basse-Normandie, GREYC UMR CNRS 6072, Caen, France

Paris, 22-23 Janvier 2009



- 1 Introduction
- 2 Construction de classificateurs parcimonieux
- 3 Diffusion sur graphes
- 4 Vers de nouvelles modalités




- 1 Introduction
- 2 Construction de classificateurs parcimonieux
- 3 Diffusion sur graphes
- 4 Vers de nouvelles modalités

La pathologie est une discipline de la médecine dédiée à l'étude des causes et des mécanismes des maladies.




L'anatomie pathologique est l'étude morphologique des maladies par l'examen macroscopique ou l'examen microscopique. Il s'agit principalement de l'étude des lésions créées par les maladies et les phénomènes pathologiques.

La pathologie diagnostique a pour but d'analyser des liquides biologiques (cytologie) ou des prélèvements tissulaires (histologie) dans le but d'identifier une maladie ou une tumeur (diagnostic), de caractériser sa cause ou son pronostic.

# Cytologie et Histologie




Gynécologie (Papanicolaou x20), Hématologie (H&E x100) , ADN (Feulgen x60)



Sein (Immuno x33), Sein (Feulgen x33), Colon (Feulgen x33)

# Éléments de modélisation d'images microscopiques

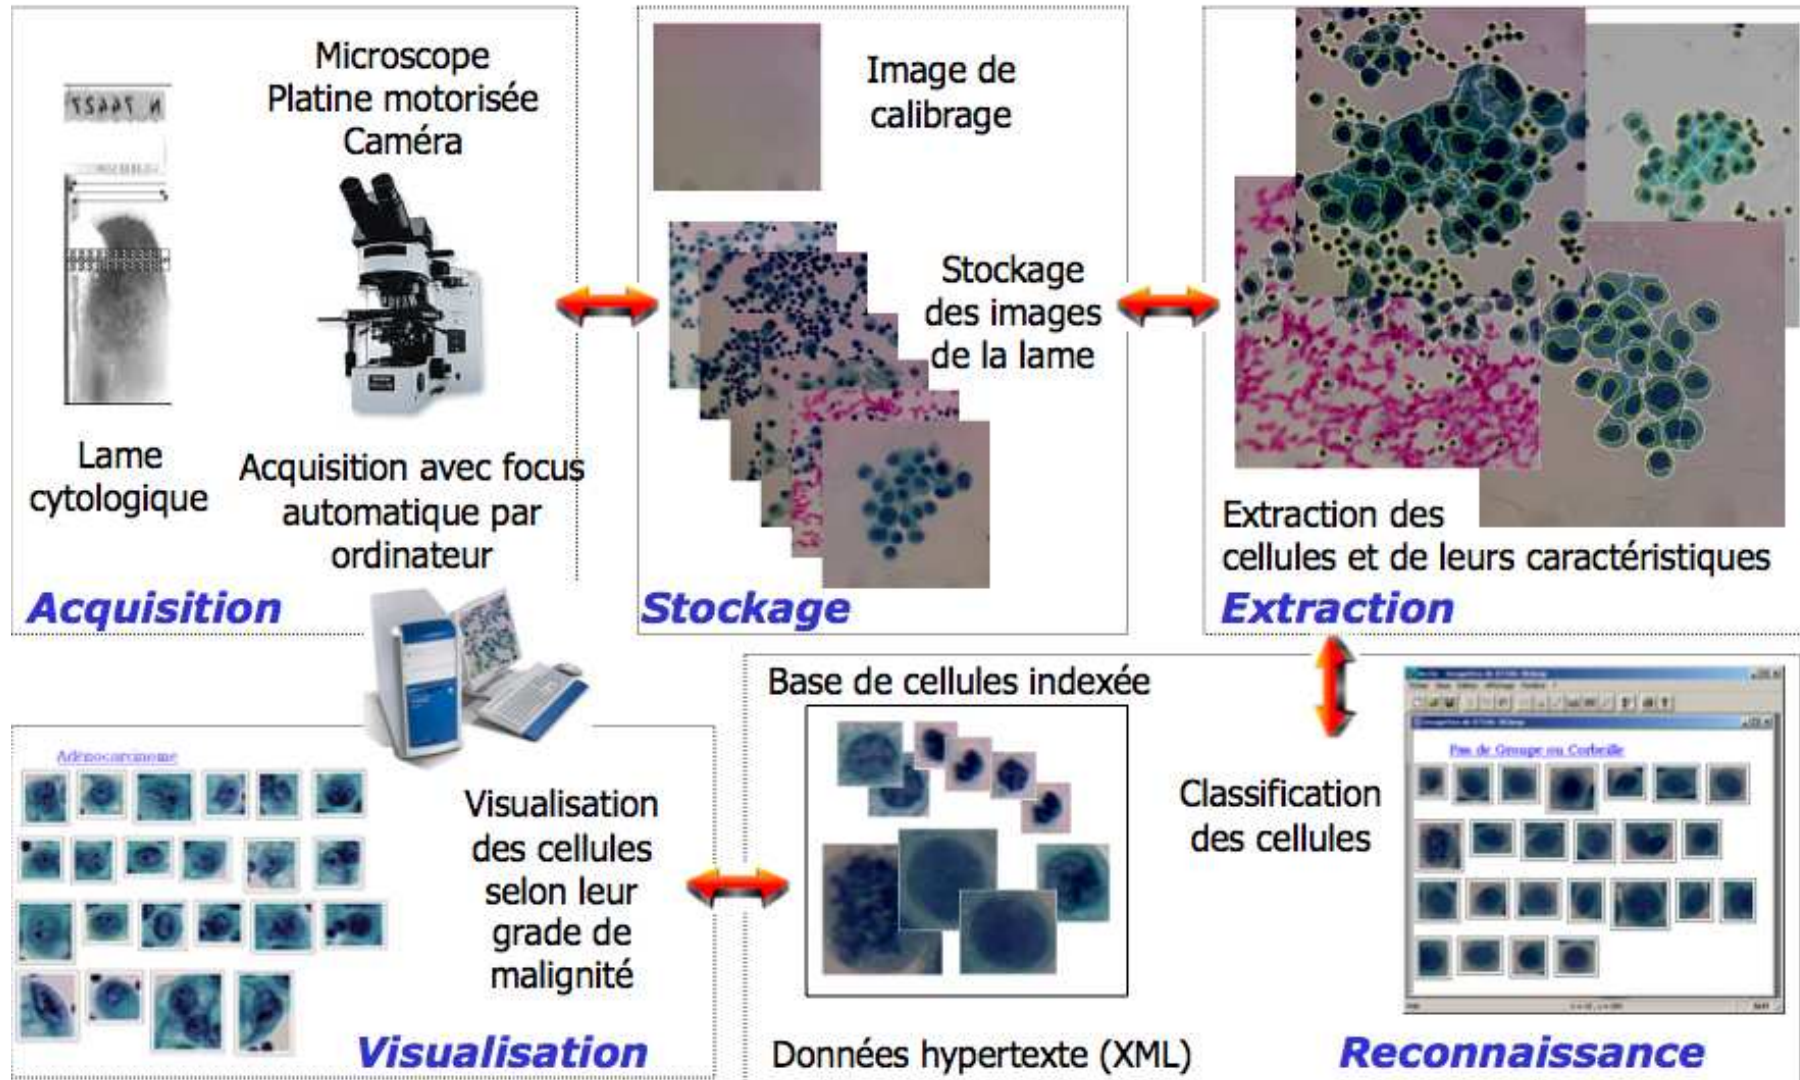


Nous parlerons uniquement de Classification/Segmentation :

- Automatique basée sur des classificateurs parcimonieux,
- Semi-automatique basée sur une diffusion sur graphes.



# Traitement et analyse d'images microscopiques




- 1 Introduction
- 2 Construction de classificateurs parcimonieux
- 3 Diffusion sur graphes
- 4 Vers de nouvelles modalités



# Traitement et analyse d'images en cytopathologie

Le traitement et l'analyse d'images sont des outils d'aide au diagnostic pour le screening automatique en cytopathologie. La quantité d'information visuelle exploitée par un cytopathologiste est énorme (beaucoup de cellules par image et beaucoup d'image par lame). Un pathologiste va cependant mettre quelques dizaines de minutes pour analyser une lame.


## Contraintes



Environ 20000 images par lame.  
➔ Un schéma de segmentation d'images microscopiques doit être efficace et rapide afin de permettre une analyse d'un grand nombre d'images.

# Cytologie bronchique





Nous nous intéressons à la cytologie bronchique pour l'aide au diagnostic du cancer du poumon.



# Schéma de segmentation

Nous avons adopté le schéma de segmentation général suivant pour l'extraction des cellules (cytoplasme et noyau) :


- 1 Changement éventuel d'espace couleur de représentation des couleur des pixels,
- 2 Classification supervisée des pixels en trois classes (fond, cytoplasme, noyau),
- 3 Rafinement des frontières par segmentation morphologique (érosion des frontières et ligne de partage des eaux).



# Classification supervisée de pixels d'images microscopiques


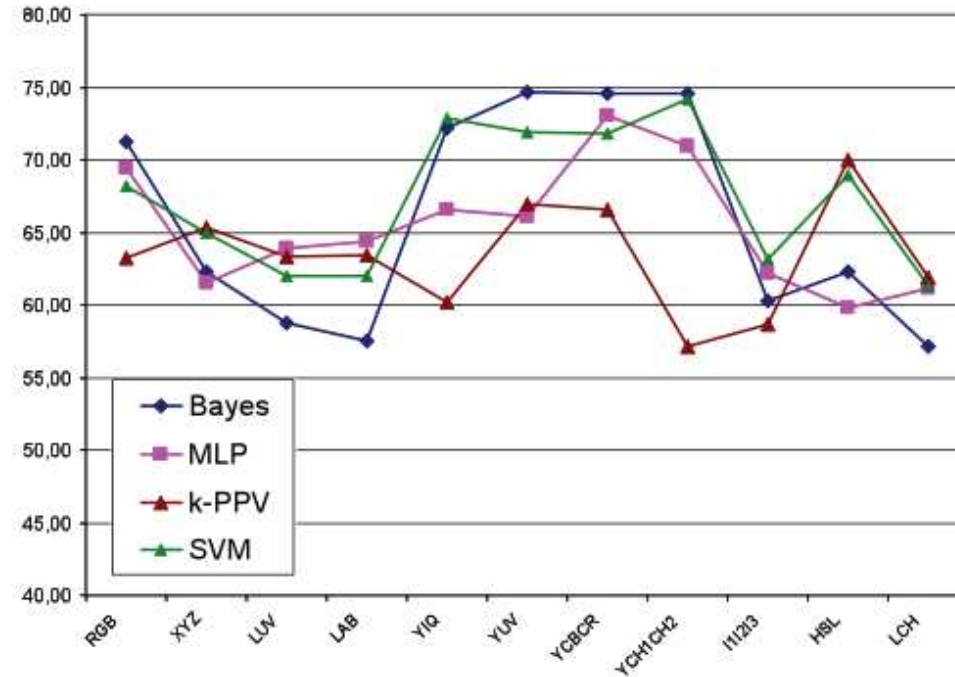



Nous disposons d'une base de 10 images manuellement annotées par un pathologiste ou les pixels sont répartis en trois classes.

Ces images sont représentatives des différentes configurations cellulaires.



Une image couleur fait 752x576 pixels, soit une base d'apprentissage de plus de 4 millions d'exemples !

# Exemples de résultats de classification de pixels





# Classification de pixels par SVM

## Premier bilan

Les SVM sont des classificateurs efficaces pour la classification de pixels en microscopie.

Le temps d'apprentissage est très consommateur de temps.

Il faut régler deux paramètres ( $\sigma$  et  $C$ ).

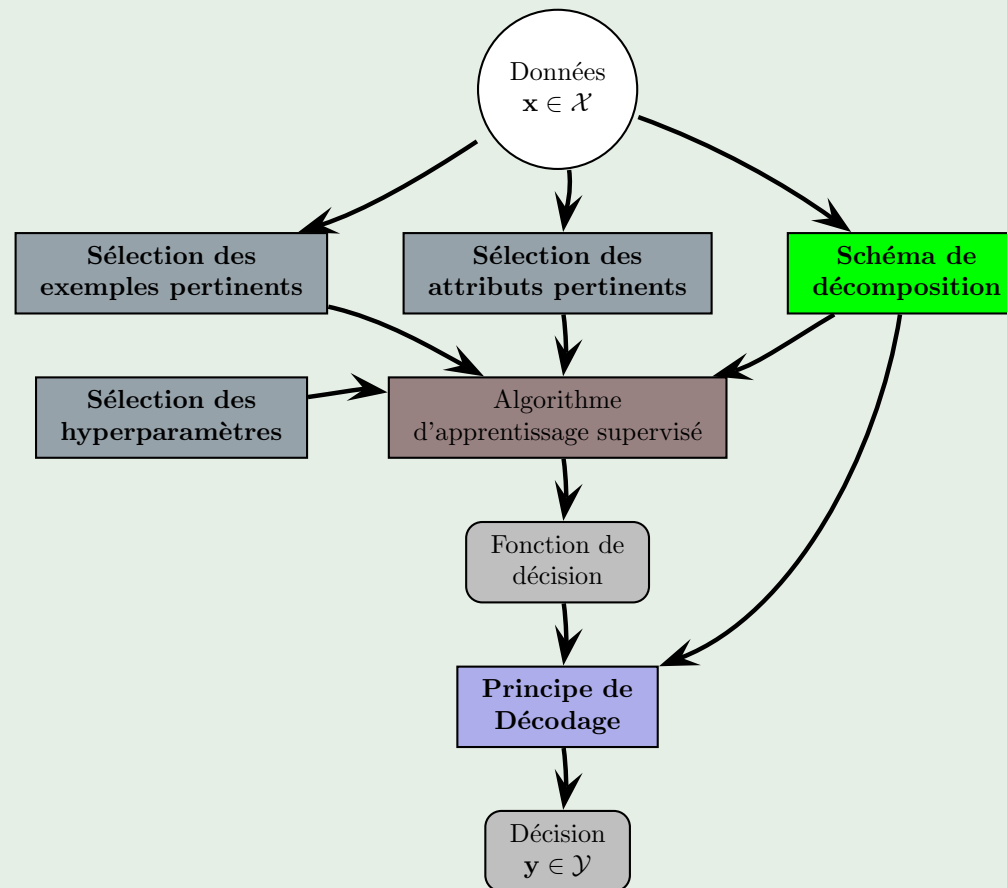
La complexité de la fonction de décision augmente avec la taille de la base d'apprentissage, mais pas forcément l'efficacité de la fonction de décision.

- Beaucoup de redondance parmi les exemples de la base d'apprentissage
- Le choix de l'espace couleur a une grande influence sur les résultats
- La contrainte imposée de rapidité d'analyse est mise à mal avec :
  - Des temps d'apprentissage prohibitifs,
  - Des temps de classification trop longs (10 minutes pour classer une image avec un SVM ayant appris sur la base d'apprentissage complète).

➤ Nécessité de disposer de classificateurs efficaces et de complexité réduite (parcimonieux).



## Les composants usuels



# Vers des classificateurs parcimonieux

## Le problème

- Une base de pixels étiquetée de taille importante en terme de volume (nombre d'exemples) et de dimension (nombre d'attributs).
- Cette grande taille s'accompagne d'une redondance au niveau des exemples et des attributs (qui peuvent alors être non pertinents).
- Ceci a deux conséquences : des temps d'apprentissage longs et des fonctions de décision de grande complexité.

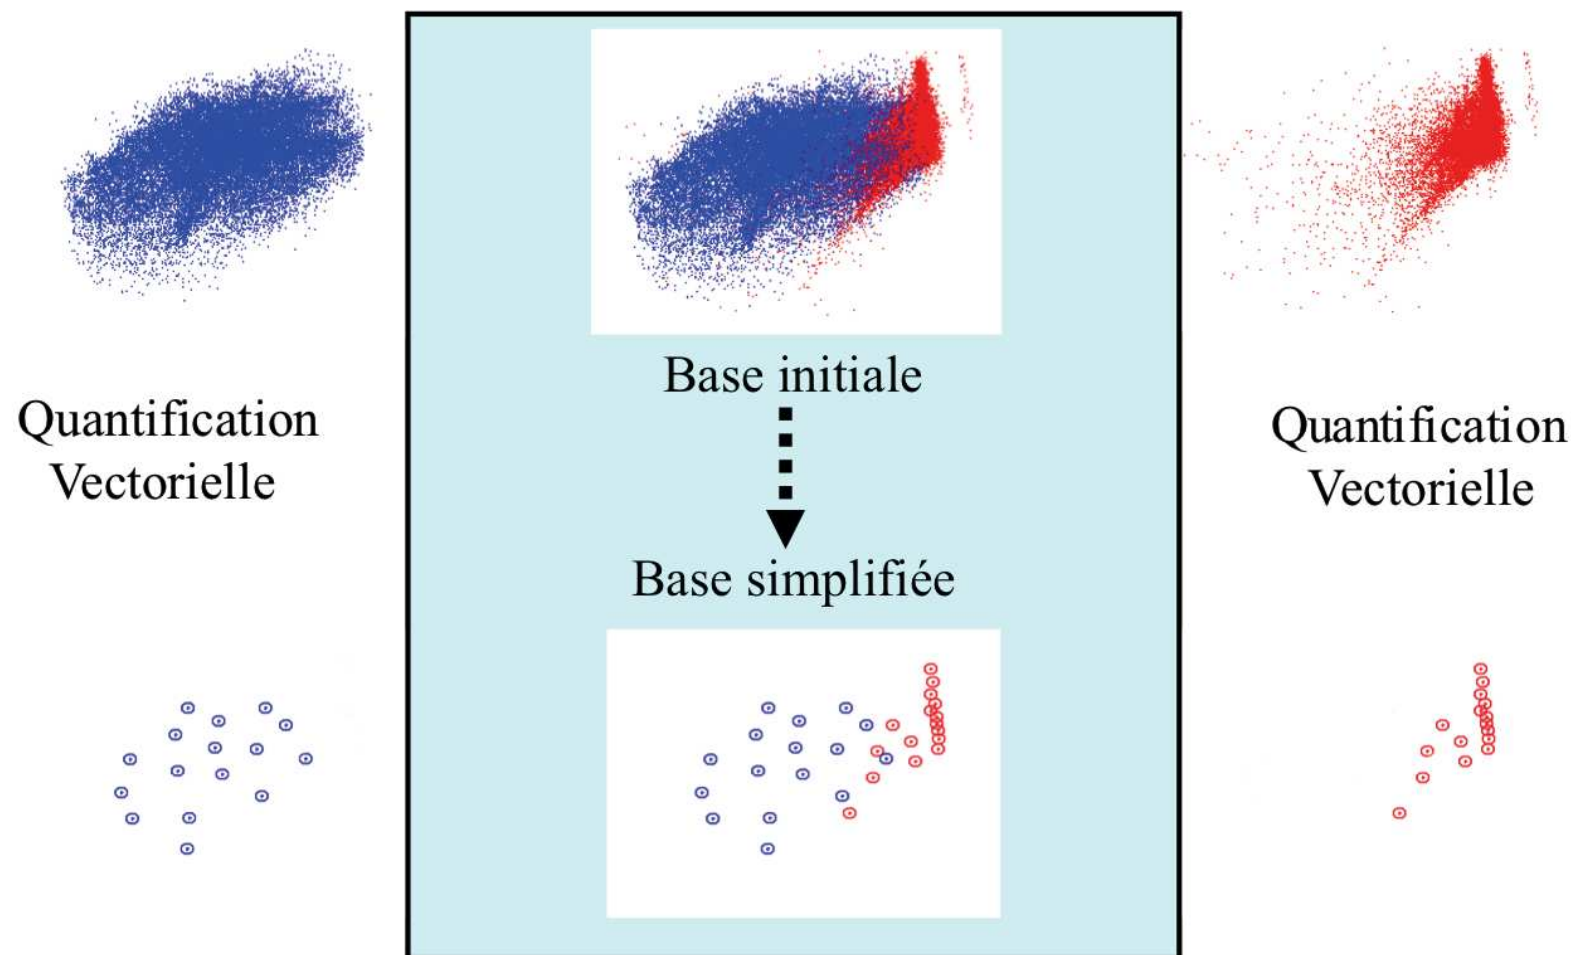
## Notre point de vue

Nous voulons

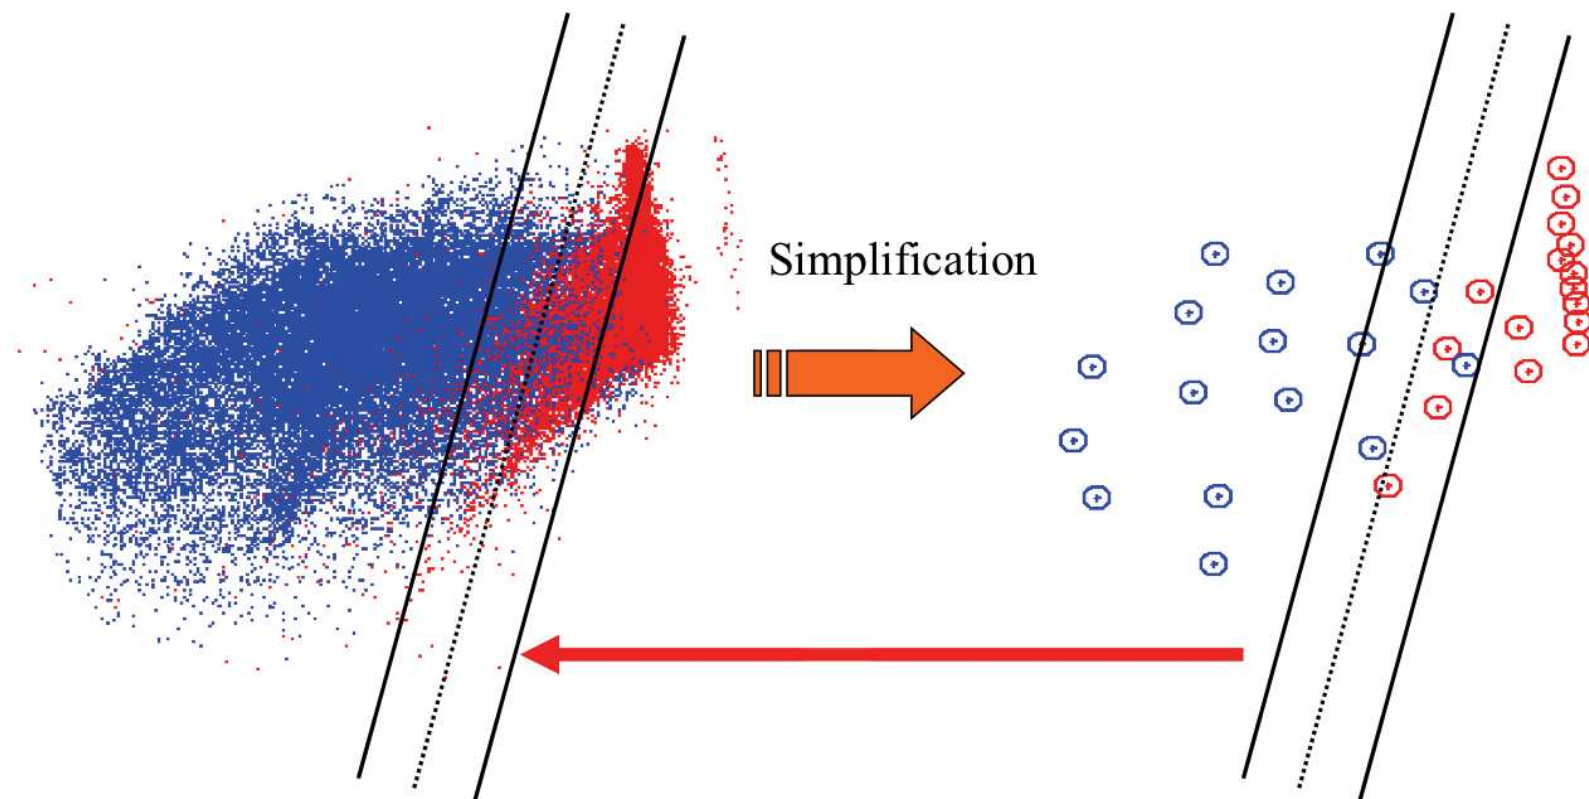
- Avoir des fonctions de décision parcimonieuses qui ont de bonnes performances en généralisation tout en restant efficaces.
- ↻ Il nous faut disposer d'un sélection de modèle qui peut simultanément de :
  - Sélectionner les exemples pertinents,
  - Sélectionner les attributs pertinents,
  - Sélectionner les hyper-paramètres du classificateur.

# Sélectionner des exemples pertinents (1)

Pour réduire la taille de la base d'apprentissage, nous utilisons un algorithme de quantification vectorielle (LBG).




## Sélectionner des exemples pertinents (2)



⇒ L'hyperplan trouvé avec l'algorithme des SVM sur la base simplifiée est une bonne approximation de celui produit avec une base non simplifiée.


# Sélectionner des exemples pertinents (3)

Base non simplifiée



Base fortement simplifiée

Taux  
d'erreurs




## Avantages de la sélection des exemples pertinents


- Temps d'apprentissage réduit pour évaluer un couple d'hyper-paramètres
- Complexité réduite de la fonction de décision (peu de vecteurs supports)
- Possibilités d'obtenir de bonnes capacités en généralisation (relativement à une plus grande sensibilité aux valeurs des hyper-paramètres).

# Sélectionner des exemples pertinents (4)

## Fond versus cytoplasme



## Nombre de vecteurs support








# Sélection de modèle pour un SVM

## Éléments pour une sélection de modèle d'un SVM

- Utiliser la quantification vectorielle pour trouver  $2^k$  prototypes pertinents.
- Modifier la fonction noyau pour intégrer la prise en compte d'une sélection d'attributs (utiliser un vecteur d'entiers  $\beta$  spécifiant la sélection ou non d'un attribut).
- Sélectionner les hyper-paramètres ( $C$  and  $\sigma$ ).



$$K_{\beta}(\mathbf{u}, \mathbf{v}) = \exp\left(\frac{-\sum_{i=1}^n \beta_i (u_i - v_i)^2}{2\sigma^2}\right)$$



## Probleme

- L'espace de recherche est trop grand.
- Nous utilisons une sélection de modèle à l'aide d'une méta-heuristique : la recherche tabou.

# Optimization globale par recherche Tabou

## Évaluation de la qualité d'une fonction de décision

Nous la définissons comme un compromis entre fidélité et complexité :

$$q_{\text{FD}} = E_{\text{fidélité}} + E_{\text{complexité}}$$

Une fonction de décision est parcimonieuse et efficace si :

- Le taux de reconnaissance est élevé (Fidélité),
- Peu de vecteurs supports sont nécessaires (Complexité),
- Peu d'attributs sont utilisés (Complexité).

Pour un modèle donné  $\theta = (C_{\theta}, \sigma_{\theta}, k_{\theta}, \beta_{\theta})$

$$q_{\text{FD}} = (1 - e_{\text{BER}}) - c_{\text{VS}} \log_2 (1 + n_{\text{VS}}) - c_{\beta} \log_2 (\sum \beta)$$

## Optimization

Une recherche tabou est réalisée pour effectuer la sélection de modèle :

$$\theta^* = \arg \max_{\theta \in \Theta} q_{\text{FD}}(h_{\theta})$$

# Résultats

Résultats avec  $c_{VS} = 10^{-2}$  sans sélection d'attributs.

CS	FDB1		FDB2		FDB3	
	RR	nsv	RR	nsv	RR	nsv
RGB	95,22%	2	84,35%	13	89,74%	4
XYZ	95,29%	2	84,46%	12	90,10%	5
LAB	94,86%	2	83,58%	7	88,68%	2
LUV	96,41%	4	84,90%	10	89,25%	8
LCH	95,86%	4	84,76%	60	89,25%	4
YCH1CH2	<b>96,00%</b>	2	85,74%	46	89,82%	4
I1I2I3	95,73%	2	<b>85,41%</b>	6	89,76%	4
HSL	95,93%	3	84,94%	6	89,90%	9
YCBCR	95,38%	2	86,17%	149	<b>90,13%</b>	5
	95,63%	2,6	84,92%	34,3	89,62%	5,0

FDB1 : fond vs autres

FDB2 : cytoplasme vs autres

FDB3 : noyau vs autres

- Le nombre de vecteurs supports dépend fortement du problème de discrimination et des attributs,
- Cela permet de réduire le nombre de vecteurs supports sans trop perdre en qualité de reconnaissance.

# Classification de pixels : résultats


Espace couleur multi-spectral de 25 composantes provenant de 11 espaces couleur ( $c_{VS} = c_{\beta} = 10^{-2}$ ).

Image Originale

$\omega_1$ =fond

$\omega_2$ =cytoplasme

$\omega_3$ =noyau




$\omega_1$ VS- $(\omega_2, \omega_3)$

$\beta = (u^*, Ch_1)$

$n_{VS} = 8$

taux: 84,9%




$\omega_2$ VS- $(\omega_1, \omega_3)$

$\beta = (u^*, S)$

$n_{VS} = 2$

taux: 96,2%




$\omega_3$ VS- $(\omega_1, \omega_2)$


$\beta = (B)$

$n_{VS} = 2$


taux: 89,6%



Classification de pixels




Vérité terrain





# Segmentation

Tps de segmentation  $< 2s$  (environ une heure pour segmenter une lame entière).



# Conclusion

- Segmenter des images microscopiques est un problème difficile
- Nous avons détaillé une sélection de modèle pour SVM qui permet de
  - Sélectionner les exemples pertinents,
  - Sélectionner les attributs pertinents,
  - Sélectionner les hyper-paramètres.
- Cela permet de construire des classificateurs de complexité réduite qui sont efficaces et rapides
- La perte en taux de reconnaissance n'a pas quasiment pas d'incidence sur le résultat final en segmentation.




- 1 Introduction
- 2 Construction de classificateurs parcimonieux
- 3 Diffusion sur graphes**
- 4 Vers de nouvelles modalités

# Continu versus Discret

- Les méthodes variationnelles, basées sur la régularisation, fournissent un cadre général pour la conception de méthodes efficaces de traitement d'image.
- Les solutions de tels modèles variationnels peuvent être obtenus en minimisant des fonctions d'énergie appropriées.
- Ceci est habituellement effectué par des Equations aux Dérivées Partielles, dont les solutions sont discrétisées pour correspondre au domaine de l'image (une grille régulière).
- Nous admettons la nature discrète des images et nous utilisons des graphes pour les représenter
- ↻ Nous proposons un analogue discret de la régularisation continue qui opère sur des graphes de topologies arbitraires.

# Topologie d'un graphe en traitement d'image


Une Image



# Topologie d'un graphe en traitement d'image

Une Image

8-voisinage :  $3 \times 3$




# Topologie d'un graphe en traitement d'image

Une Image

8-voisinage :  $3 \times 3$

24-voisinage :  $5 \times 5$




# Topologie d'un graphe en traitement d'image

Une Image

8-voisinage :  $3 \times 3$

24-voisinage :  $5 \times 5$

Interactions locales : une valeur par noeud





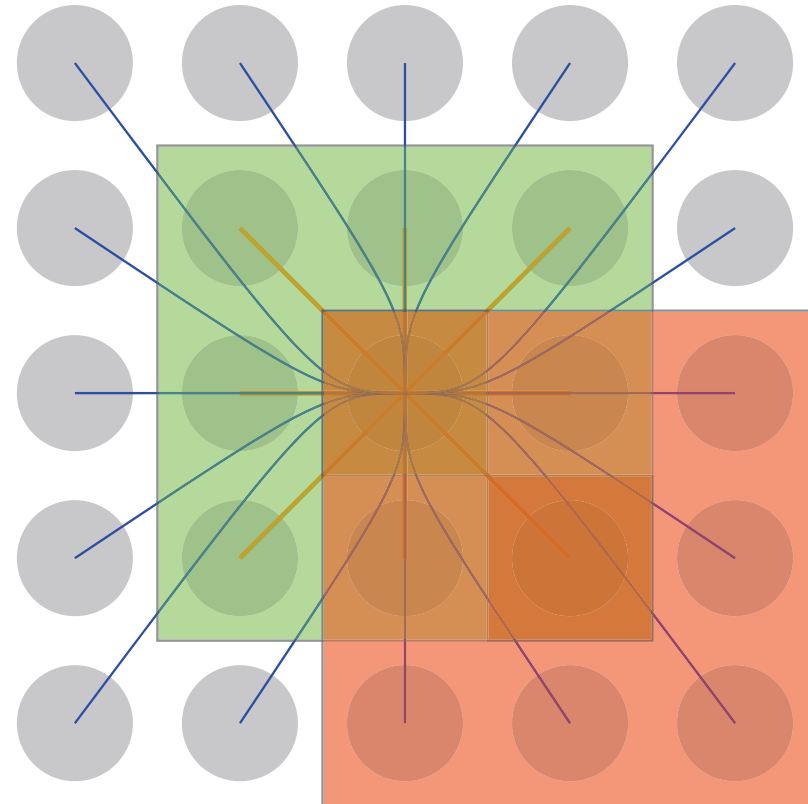
# Topologie d'un graphe en traitement d'image

Une Image

8-voisinage :  $3 \times 3$

24-voisinage :  $5 \times 5$

Interactions nonlocales: un patch (vecteur des valeurs dans un voisinage) par noeud.




# Topologie d'un graphe en traitement d'image

Une Image

8-voisinage :  $3 \times 3$

24-voisinage :  $5 \times 5$

Interactions nonlocales: un patch (vecteur des valeurs dans un voisinage) par noeud.



## Avec des graphes

Le caractère nonlocal est directement exprimé par la topologie du graphe.  
La similarité entre patchs est utilisée pour pondérer les arêtes.

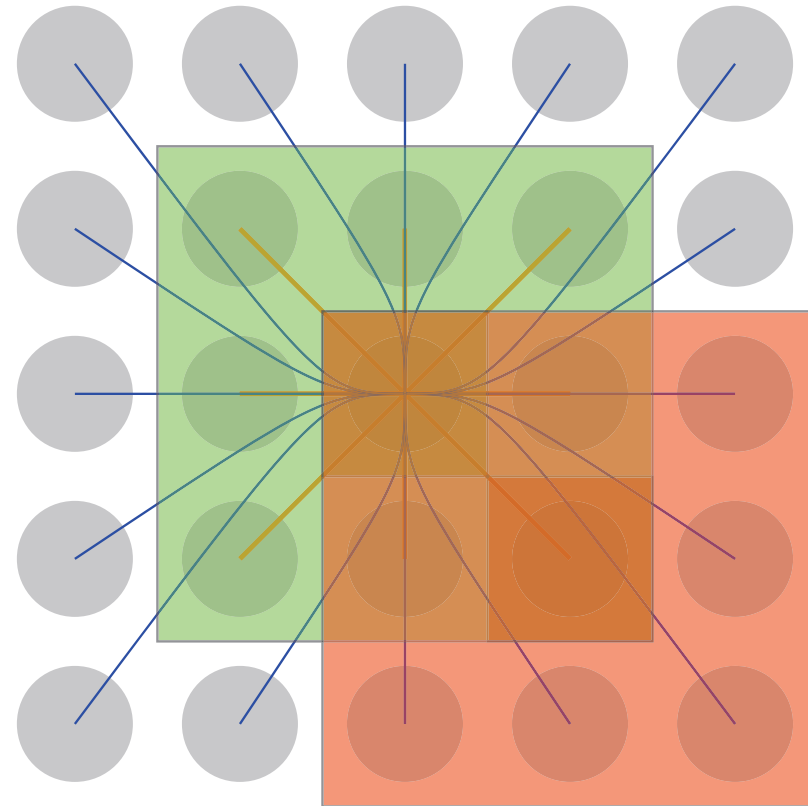
# Topologie d'un graphe en traitement d'image

Une Image

8-voisinage :  $3 \times 3$

24-voisinage :  $5 \times 5$

Interactions nonlocales: un patch (vecteur des valeurs dans un voisinage) par noeud.



## Notre point de vue

Avec cette représentation, nous désirons reformuler des problèmes de traitement d'images sur graphes de topologie arbitraires.

# Éléments de base sur les graphes pondérés

- Un graphe  $\mathcal{G}$  est un couple  $\mathcal{G} = (V, E)$  où  $V$  est un ensemble fini de noeuds et  $E \subseteq V \times V$  est un ensemble d'arêtes.
- Les graphes sont supposés simple, non dirigé et sans boucles.
- Un graphe est dit pondéré si une fonction de pondération lui est associée  $w : E \rightarrow \mathbb{R}^+$  satisfaisant  $w(u, v) = w(v, u)$  et  $w(u, v) > 0 \forall (u, v) \in E$ .
- $u \sim v$  désigne l'ensemble des noeuds connectés au noeud  $u$  par une arête.

# Espace des fonctions sur graphes

- Soit  $\mathcal{H}(V)$  l'espace de Hilbert des fonctions à valeurs réelles sur les noeuds, dans lequel chaque fonction  $f : V \rightarrow \mathbb{R}^+$  associe une valeur réelle  $f(v)$  à chaque noeud  $v$ .
- L'espace des fonctions  $\mathcal{H}(V)$  est muni du produit scalaire usuel  $\langle f, g \rangle_{\mathcal{H}(V)} = \sum_{v \in V} f(v)g(v)$  où  $f$  et  $g$  sont deux fonctions de  $\mathcal{H}(V)$ .
- On définit de manière similaire  $\mathcal{H}(E)$  comme l'espace des fonctions à valeurs réelles sur les arêtes, dans lequel chaque fonction  $h : E \rightarrow \mathbb{R}^+$  associe une valeur réelle à chaque arête  $e \in E$

# Opérateurs différentiels sur graphes

L'opérateur de différence  $d : \mathcal{H}(V) \rightarrow \mathcal{H}(E)$  d'une fonction  $f \in \mathcal{H}(V)$  en une arête  $(u, v)$  est défini par

$$(df)(u, v) = \sqrt{w(u, v)}(f(v) - f(u)) \quad (1)$$

La **dérivée directionnelle** de  $f$ , en  $v \in V$ , le long d'une arête  $e = (u, v)$ , est définie par :

$$\left. \frac{\partial f}{\partial e} \right|_u = \partial_v f(u) = (df)(u, v). \quad (2)$$

L'opérateur **adjoint** de l'opérateur de différence, noté  $d^* : \mathcal{H}(E) \rightarrow \mathcal{H}(V)$ , est un opérateur linéaire défini par :

$$\langle df, H \rangle_{\mathcal{H}(E)} = \langle f, d^* H \rangle_{\mathcal{H}(V)}, \quad (3)$$

pour tout  $f \in \mathcal{H}(V)$  et tout  $H \in \mathcal{H}(E)$ .

L'opérateur adjoint  $d^*$ , d'une fonction  $H \in \mathcal{H}(E)$ , peut s'exprimer pour un noeud  $u \in V$  par l'expression suivante :

$$(d^* H)(u) = (-\operatorname{div}(H))(u) = \sum_{v \sim u} \sqrt{w(u, v)}(H(v, u) - H(u, v)). \quad (4)$$



# Opérateur de gradient pondéré

L'**opérateur de gradient pondéré** d'une fonction  $f \in \mathcal{H}(V)$ , en un noeud  $u \in V$ , est l'opérateur vectoriel défini par :

$$\begin{aligned}\nabla_w f(u) &= [\partial_v f(u) : v \sim u]^T \\ &= [\partial_{v_1} f(u), \dots, \partial_{v_k} f(u)]^T, \quad \forall (u, v_i) \in E.\end{aligned}$$

La norme  $\mathcal{L}_2$  de ce vecteur représente la variation locale de la fonction  $f$  en un noeud du graphe. Elle est définie par :

$$\begin{aligned}|\nabla_w f(u)| &= \sqrt{\sum_{v \sim u} (\partial_v f(u))^2} \\ &\stackrel{(2)}{=} \sqrt{\sum_{v \sim u} w(u, v) (f(v) - f(u))^2}.\end{aligned}\tag{5}$$

# Une famille d'opérateurs $p$ -Laplacien pondérés

Soit  $p \in (0, +\infty)$  un nombre réel. Le  $p$ -Laplacien pondéré d'une fonction  $f \in \mathcal{H}(V)$ , noté  $\Delta_w^p : \mathcal{H}(V) \rightarrow \mathcal{H}(V)$ , est défini par :

$$\Delta_w^p f(u) = \frac{1}{2} d^*(|\nabla_w f(u)|^{p-2} df(u, v)). \quad (6)$$

Le  $p$ -Laplacien d'une fonction  $f \in \mathcal{H}(V)$ , en un noeud  $u \in V$ , est défini par :

$$\Delta_w^p f(u) = \frac{1}{2} \sum_{v \sim u} \gamma_w^f(u, v)(f(u) - f(v)), \quad (7)$$

avec

$$\gamma_w^f(u, v) = w(u, v)(|\nabla_w f(v)|^{p-2} + |\nabla_w f(u)|^{p-2}). \quad (8)$$

# Laplacien et courbure

Pour  $p = 2$ , cela correspond au *combinatorial graph Laplacian*

$$\Delta_w f(u) = \sum_{v \sim u} w(u, v)(f(u) - f(v)). \quad (9)$$

Pour  $p = 1$ , c'est la *courbure pondérée*

$$\kappa_w f(u) = \frac{1}{2} \sum_{v \sim u} \left( \frac{w(u, v)}{|\nabla_w f(v)|} + \frac{w(u, v)}{|\nabla_w f(u)|} \right) (f(u) - f(v)). \quad (10)$$

# Régularisation p-Laplacienne

La régularisation de données discrètes sur un graphe pondéré d'une fonction  $f^0 \in \mathcal{H}(V)$  est formalisée par le problème suivant de minimisation :

$$\min_{f \in \mathcal{H}(V)} \left\{ E_w^p(f, f^0, \lambda) = R_w^p(f) + \frac{\lambda}{2} \|f - f^0\|_2^2 \right\}, \quad (11)$$

où  $p \in (0, +\infty)$  est de le degré de régularité,  $\lambda$  est le paramètre d'attache aux données.

La fonctionnelle de régularisation  $R_w^p : \mathcal{H}(V) \rightarrow \mathbb{R}$  est définie par :

$$R_w^p(f) = \frac{1}{p} \sum_{u \in V} |\nabla_w f(u)|^p = \frac{1}{p} \sum_{u \in V} \left( \sum_{v \sim u} w(u, v) (f(v) - f(u))^2 \right)^{\frac{p}{2}}. \quad (12)$$

Pour obtenir la solution de ce problème de minimisation, nous considérons le système suivant d'équations:

$$\frac{\partial E_w^p(f, f^0, \lambda)}{\partial f(u)} = 0, \quad \forall u \in V, \quad (13)$$

qui est réécrit comme :

$$\frac{\partial R_w^p(f)}{\partial f(u)} + \lambda(f(u) - f^0(u)) = 0, \quad \forall u \in V. \quad (14)$$

De plus, on peut prouver que

$$\frac{\partial R_w^p(f)}{\partial f(u)} = 2\Delta_w^p f(u), \quad \forall u \in V. \quad (15)$$

Alors, on obtient

$$2\Delta_w^p f(u) + \lambda(f(u) - f^0(u)) = 0, \quad \forall u \in V, \quad (16)$$

qui est équivalent à

$$\left( \lambda + \sum_{v \sim u} \gamma_w^f(u, v) \right) f(u) - \sum_{v \sim u} \gamma_w^f(u, v) f(v) = \lambda f^0(u). \quad (17)$$

# Une famille de processus de diffusion discrets

Nous utilisons une méthode itérative pour résoudre le précédent système d'équations. Soit  $t$  le numéro de l'itération, et soit  $f^{(t)}$  la solution à l'itération  $t$ . Alors l'algorithme est le suivant :

$$\begin{cases} f^{(0)} = f^0 \\ f^{(t+1)}(u) = \frac{\lambda f^0(u) + \sum_{v \sim u} \gamma_w^{f^{(t)}}(u, v) f^{(t)}(v)}{\lambda + \sum_{v \sim u} \gamma_w^{f^{(t)}}(u, v)}, \forall u \in V. \end{cases} \quad (18)$$

Cela décrit une famille de processus discrets de diffusion dont les paramètres sont la structure du graphe (topologie et fonction de poids), les paramètres  $p$  et  $\lambda$ .



# Clustering semi-supervisé

Soit  $C = \{c_i\}_{i=1, \dots, k}$  un ensemble des noeuds *labélisés* et  $V \setminus C$  l'ensemble des noeuds *non labélisés* (que l'on cherche à affecter à l'un des  $k$  labels).

Nous considérons  $k$  fonctions d'appartenance (une par classe)  $f_i^0: V \rightarrow \mathbb{R}$ , avec  $i=1, \dots, k$ . Pour un noeud  $u \in V$ , si  $u$  est labélisé alors


$$f_i^0(u) = \begin{cases} +1, & \text{si } u \in c_i \\ -1, & \text{sinon} \end{cases} . \quad (19)$$

Si  $u$  est non labélisé (i.e.  $u \in V \setminus C$ ) alors  $f_i^0(u) = 0$ .

Nous utilisons notre processus de diffusion discret pour estimer les probabilités d'appartenance d'un noeud à chaque classe:  $k$  processus sont effectués en parallèle et, à convergence, la décision finale est prise par:


$$\operatorname{argmax}_i \left\{ f_i(u) / \sum_i f_i(u) \right\} . \quad (20)$$

# Applications en Traitement d'images microscopiques




Segmentation semi-supervisée ( $p = 1, \lambda = 1$ ) avec graphe grille ((d), (h),  $t = 50$ ), RAG avec 98% de réduction ((e), (i),  $t = 5$ ), graphe complet ((f)-(g), (j)-(k),  $t = 2$ ).


# Applications en Traitement d'images microscopiques



(a) 405 150 pixels




(b) Filtered image




(c) 2 068 zones (99% of reduction)




# Applications en Traitement d'images microscopiques




(d) Original+Labels



(e)



(f) Additional labels



(g)

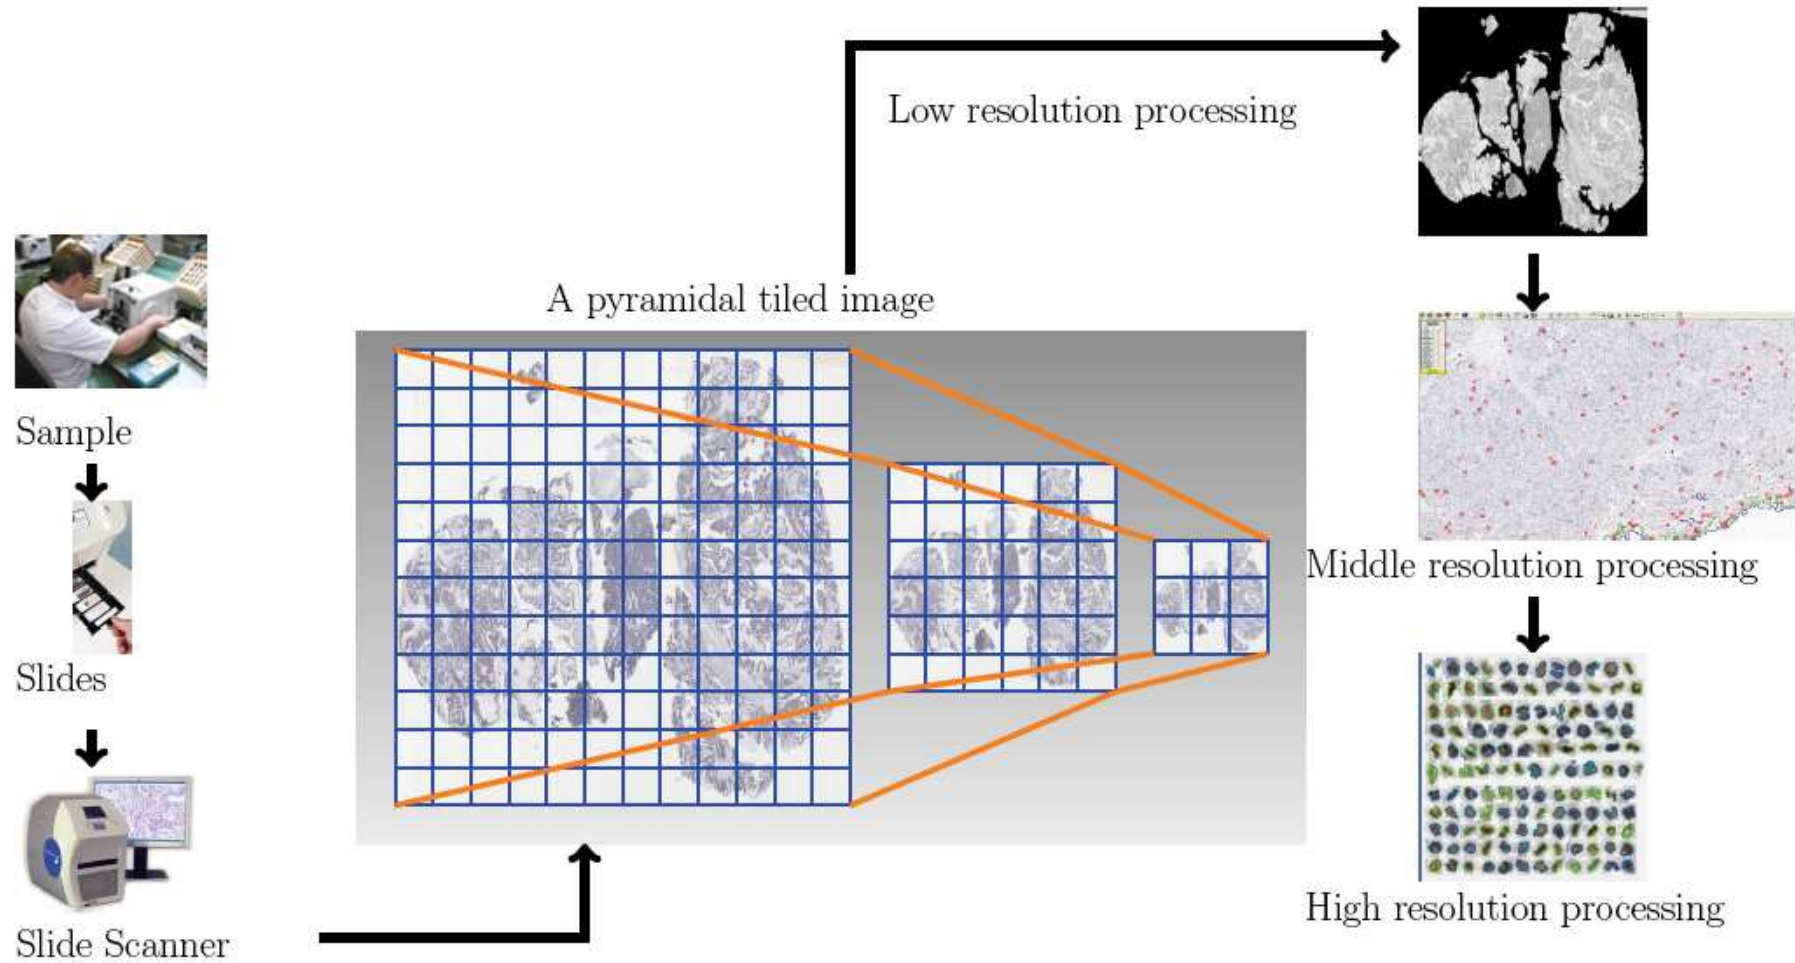
## Intérêt de l'approche proposée

- Formulation discrète de la régularisation p-Laplacienne,
- Expression directe de nombreux filtres de la littérature,
- Unifie, généralise et étend les trois modèles de traitement (local, semi-local, nonlocal),
- Repose sur des graphes de topologies arbitraires,
- Un même formalisme permet d'effectuer filtrage et segmentation.
- L'utilisation de graphes d'adjacence de régions permet d'obtenir des méthodes rapides et efficaces.

- 1 Introduction
- 2 Construction de classificateurs parcimonieux
- 3 Diffusion sur graphes
- 4 Vers de nouvelles modalités**



# Images de lame entière



# Merci de votre attention.

Publications disponibles à :  
<http://www.info.unicaen.fr/~lezoray>