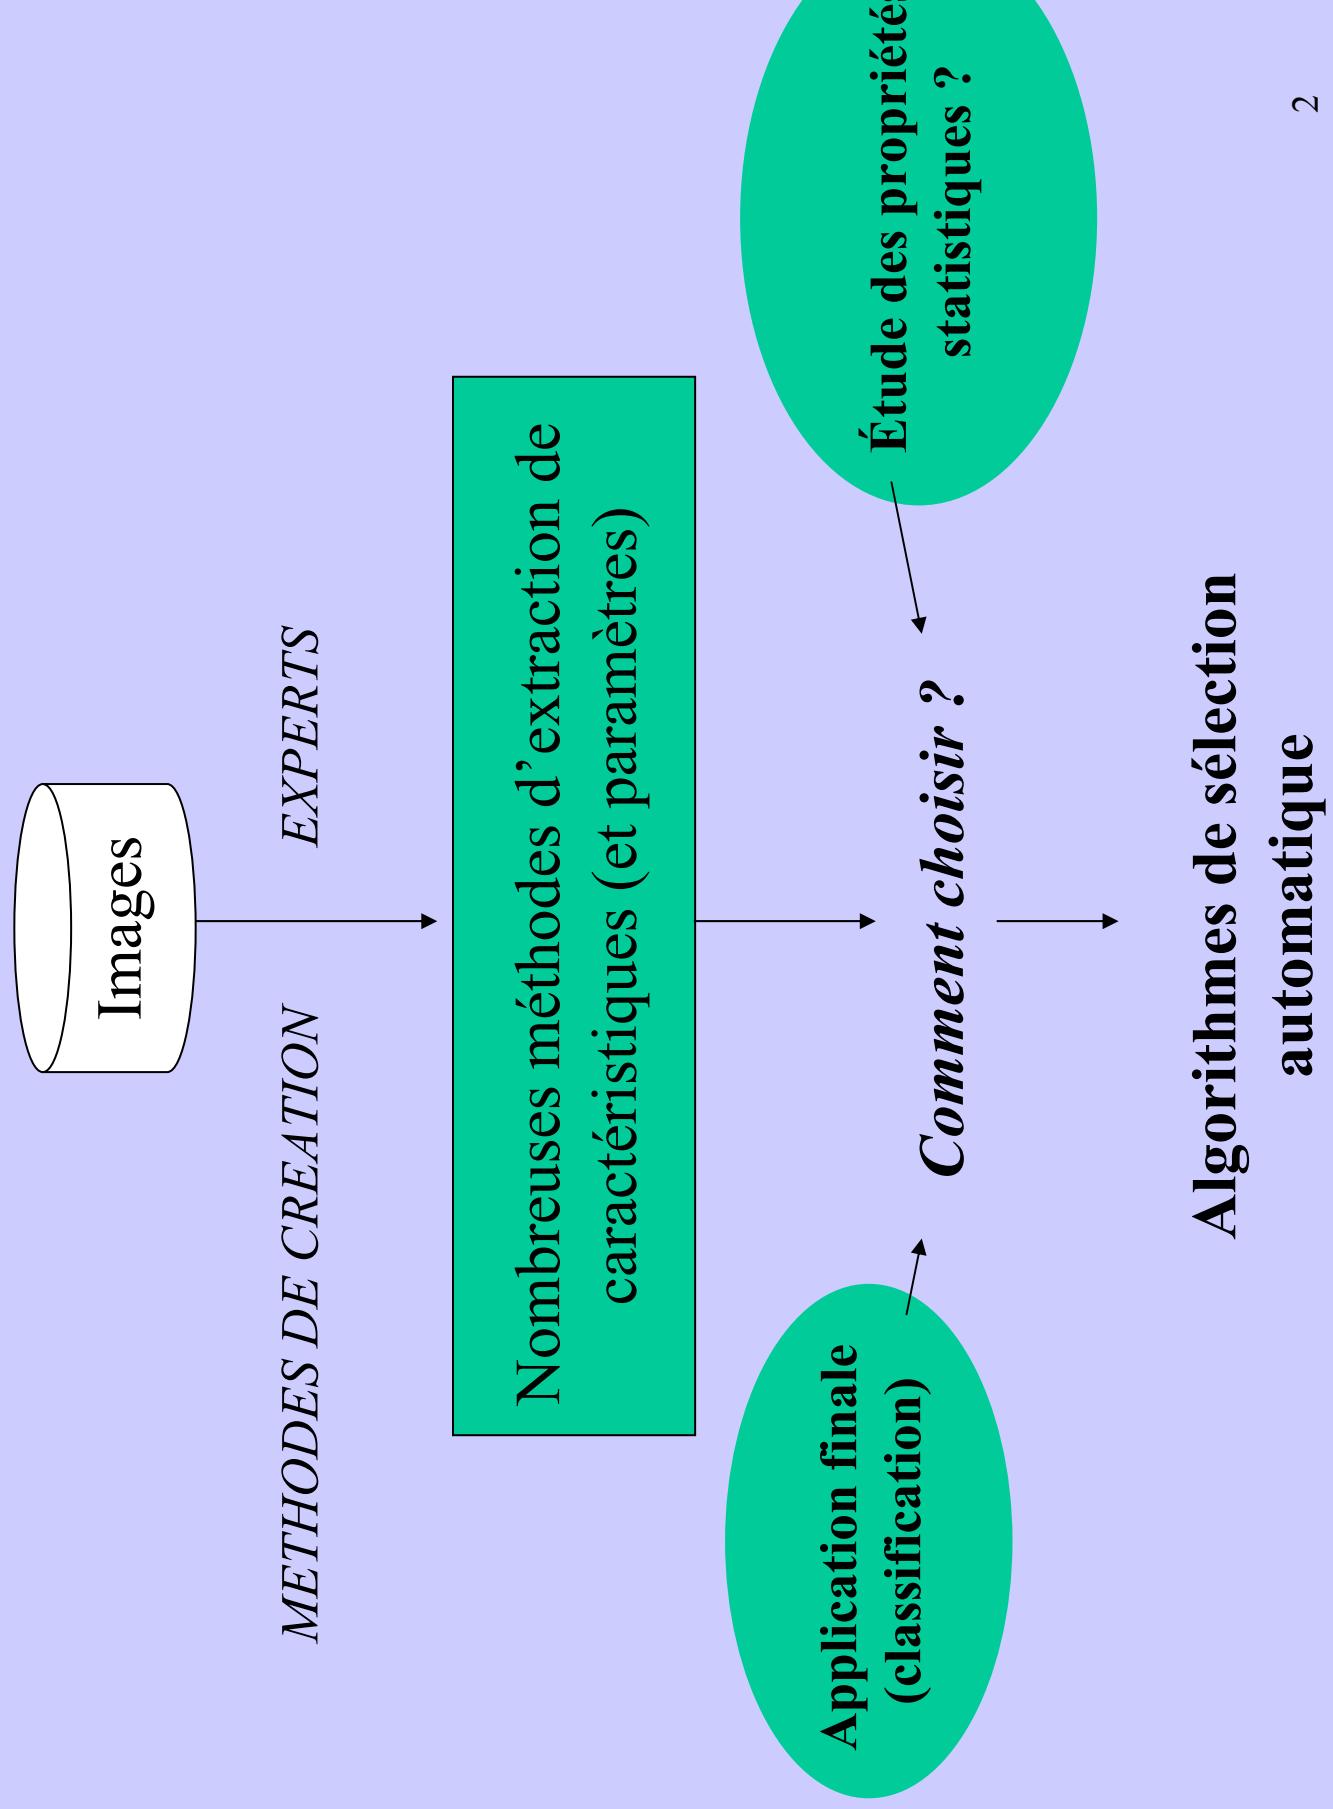


Sélection et classification

Marine Campedel
29 novembre 2004

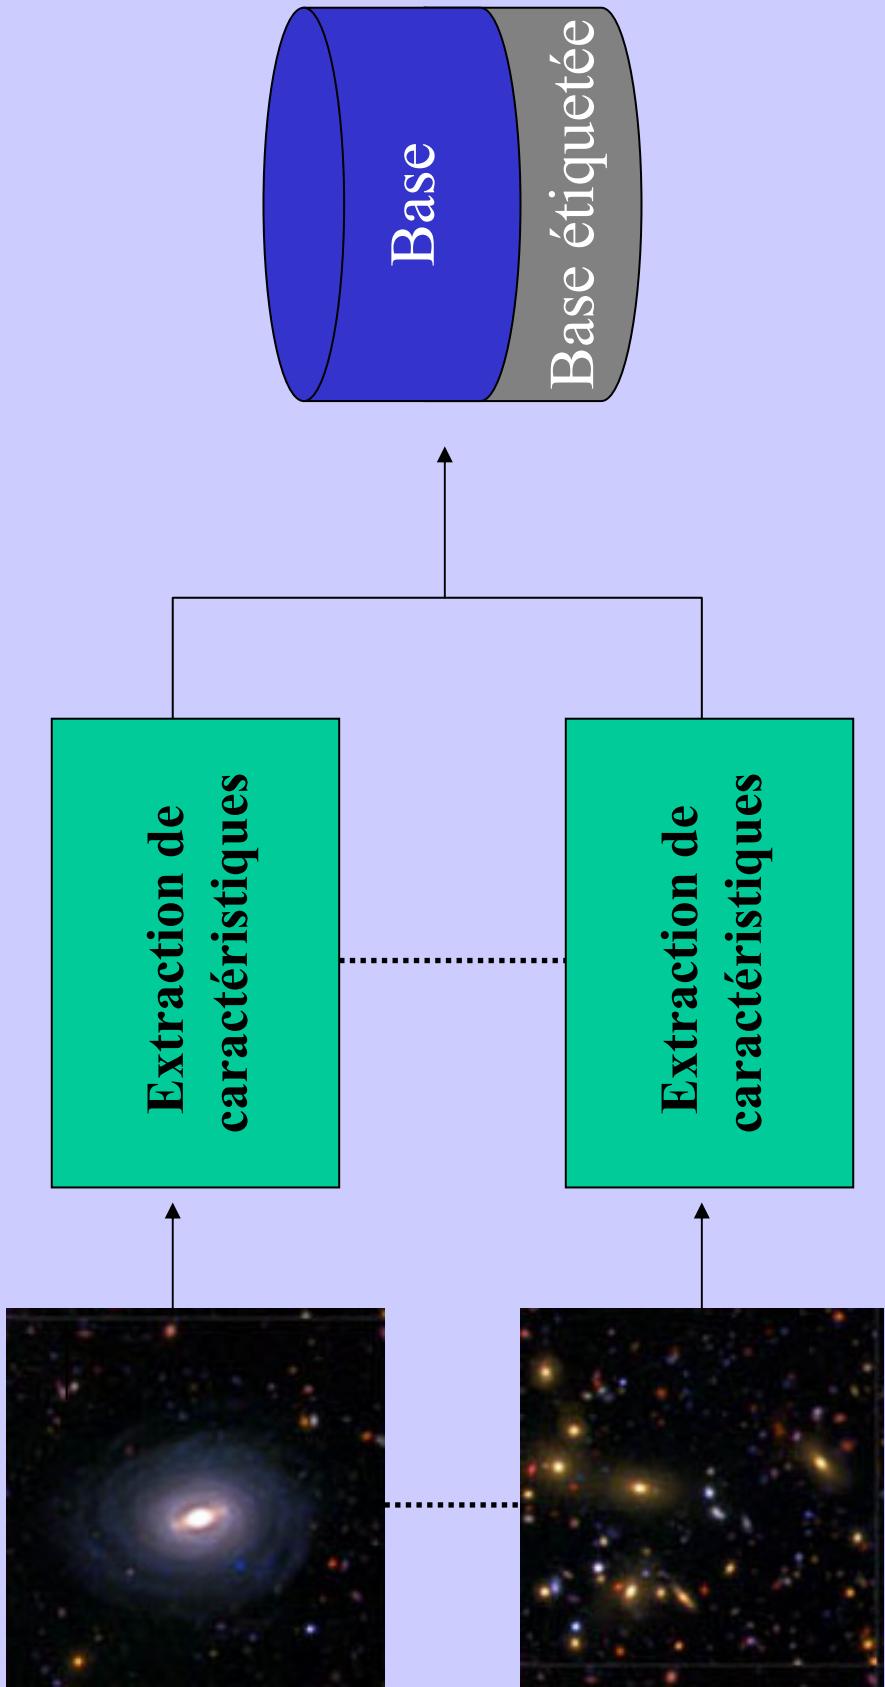




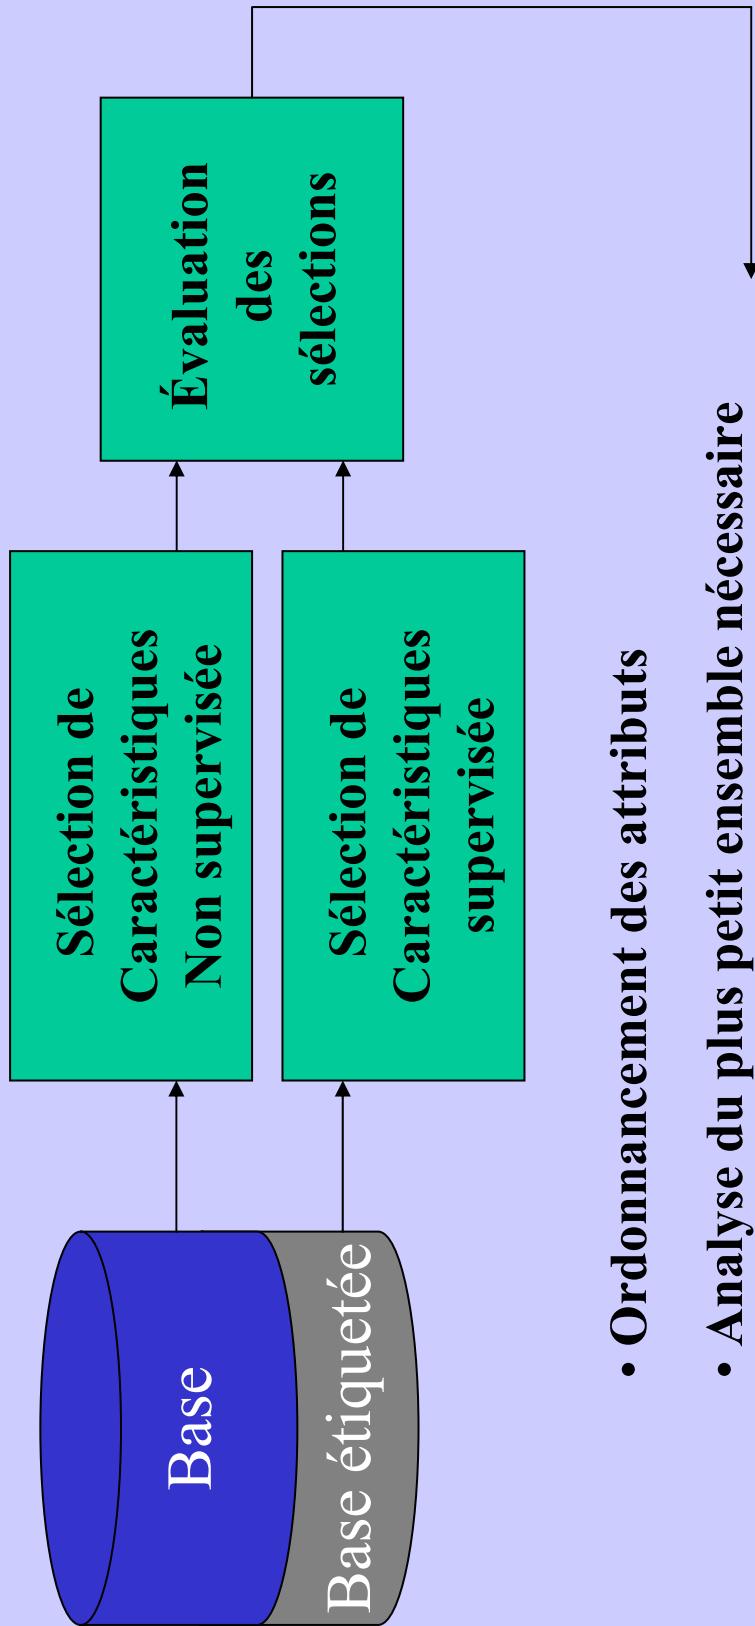
Sélection de caractéristiques

- Motivation : mise au point d'une méthodologie objective pour sélectionner les caractéristiques *pertinentes* ;
- Objectif :
 - Réduction du nombre de caractéristiques stockées ;
 - Conservation/Amélioration de la performance de classification.

Méthodologie (1/2)



Méthodologie (2/2)



- Ordonnancement des attributs
- Analyse du plus petit ensemble nécessaire
- Comparaison des méthodes de sélection
- Analyse des propriétés bruit/redondance

Algorithmes de sélection

- Recherche du sous-ensemble (le plus petit) de caractéristiques le plus apte à refléter la structure des données -> élimination du bruit et de la redondance ;
- Filter / Wrapper / Embedded ;
- Supervisés / non supervisés.

Algorithmes supervisés

	Type	Description
Relieff	Filter	Score d'autant plus élevé que la caractéristique permet de discriminer les données de classes différentes.
Fisher	Wrapper	Analyse discriminante de Fisher.
RFE	Wrapper	Élimination récursive des caractéristiques de poids faible, à l'aide d'une SVM.
AROM	Wrapper	Approximation de la norme 10 des poids associés à chaque caractéristique, par une procédure récursive faisant intervenir une L1-SVM ou une SVM classique.

Algorithmes supervisés (suite)

- SVM (quadratique)

$$\min_{\mathbf{w}, b} \|\mathbf{w}\|_2^2$$

avec $y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1$

- L1-SVM (linéaire)

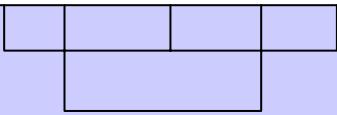
$$\min_{\mathbf{w}, b} |\mathbf{w}|$$

avec $y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1$

- AROM -> L1-AROM et L2-AROM
- Sélection L1 : une boucle de sélection L1-AROM

Principe de la sélection non supervisée

- Approche classique



**Data
NxD**

- Notre approche



**Data
NxD**

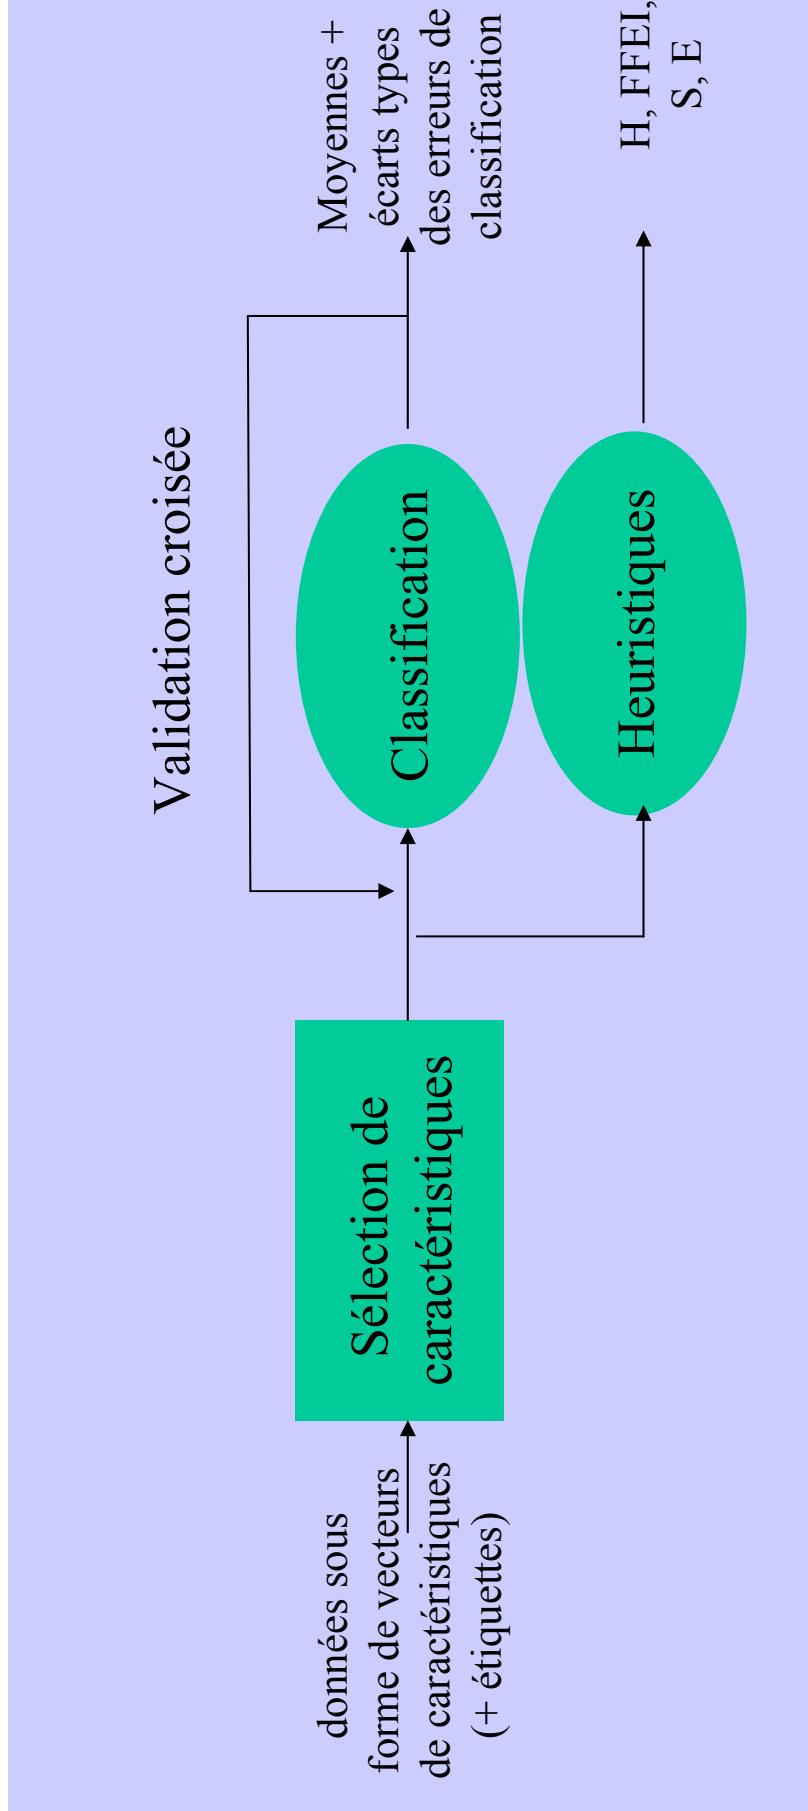
=> Recherche du sous-ensemble donnant la meilleure clusterisation des exemples

=> Choix des représentants des clusters de caractéristiques

Algorithmes non supervisés

	Type	Description
Schéma général (lourd)	Wrapper ou embedded (non implanté)	Recherche du sous-ensemble guidée par l'évaluation de la qualité d'une clusterisation des données. Utilisation d'algorithmes exploratoires (Greedy ou GA).
MIC	Filter	Utilisation d'une clusterisation KPPV des caractéristiques + choix d'un représentant par cluster.
kMeans-FS	Filter	Utilisation d'une clusterisation KMoyennes des caractéristiques +sélection de la caractéristique la plus proche du centroïde.
SVC-FS	Filter	Utilisation des vecteurs de support issus d'une classification 1-classe (clusterisation SVC)

Évaluation des sélections

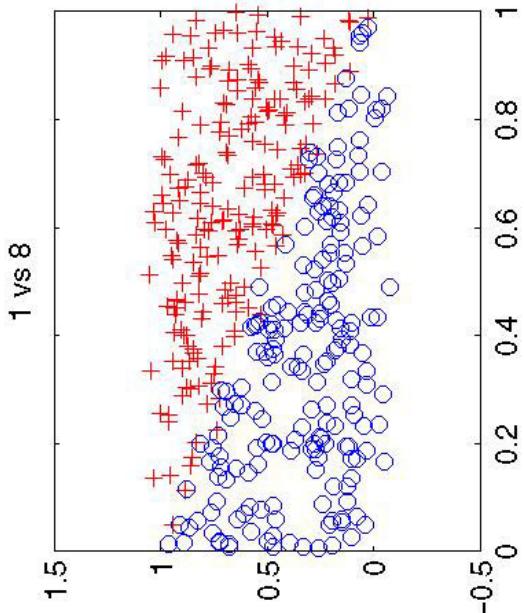
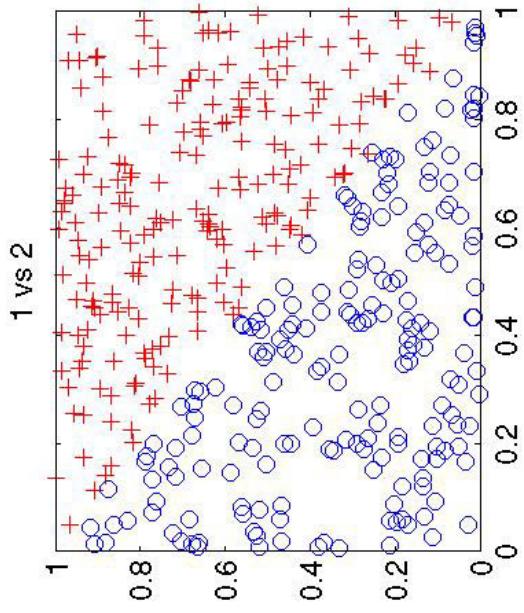
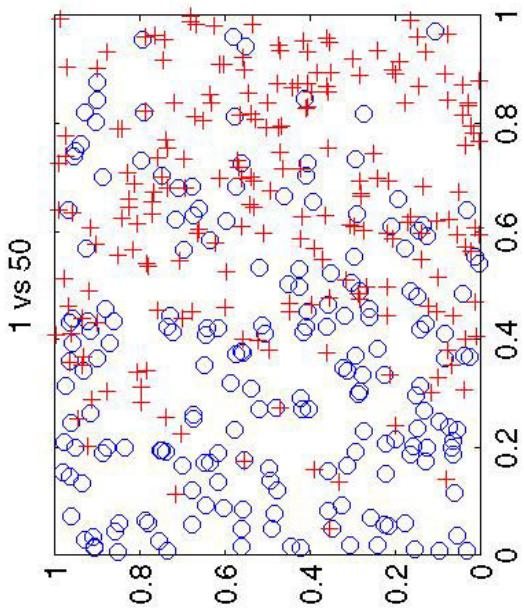
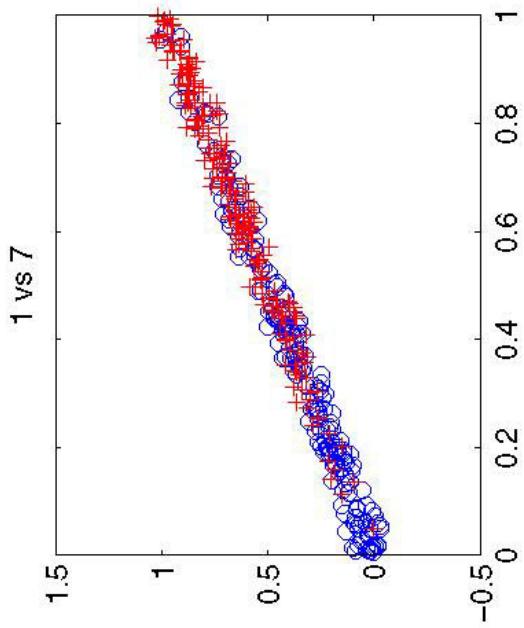


Évaluation des sélections

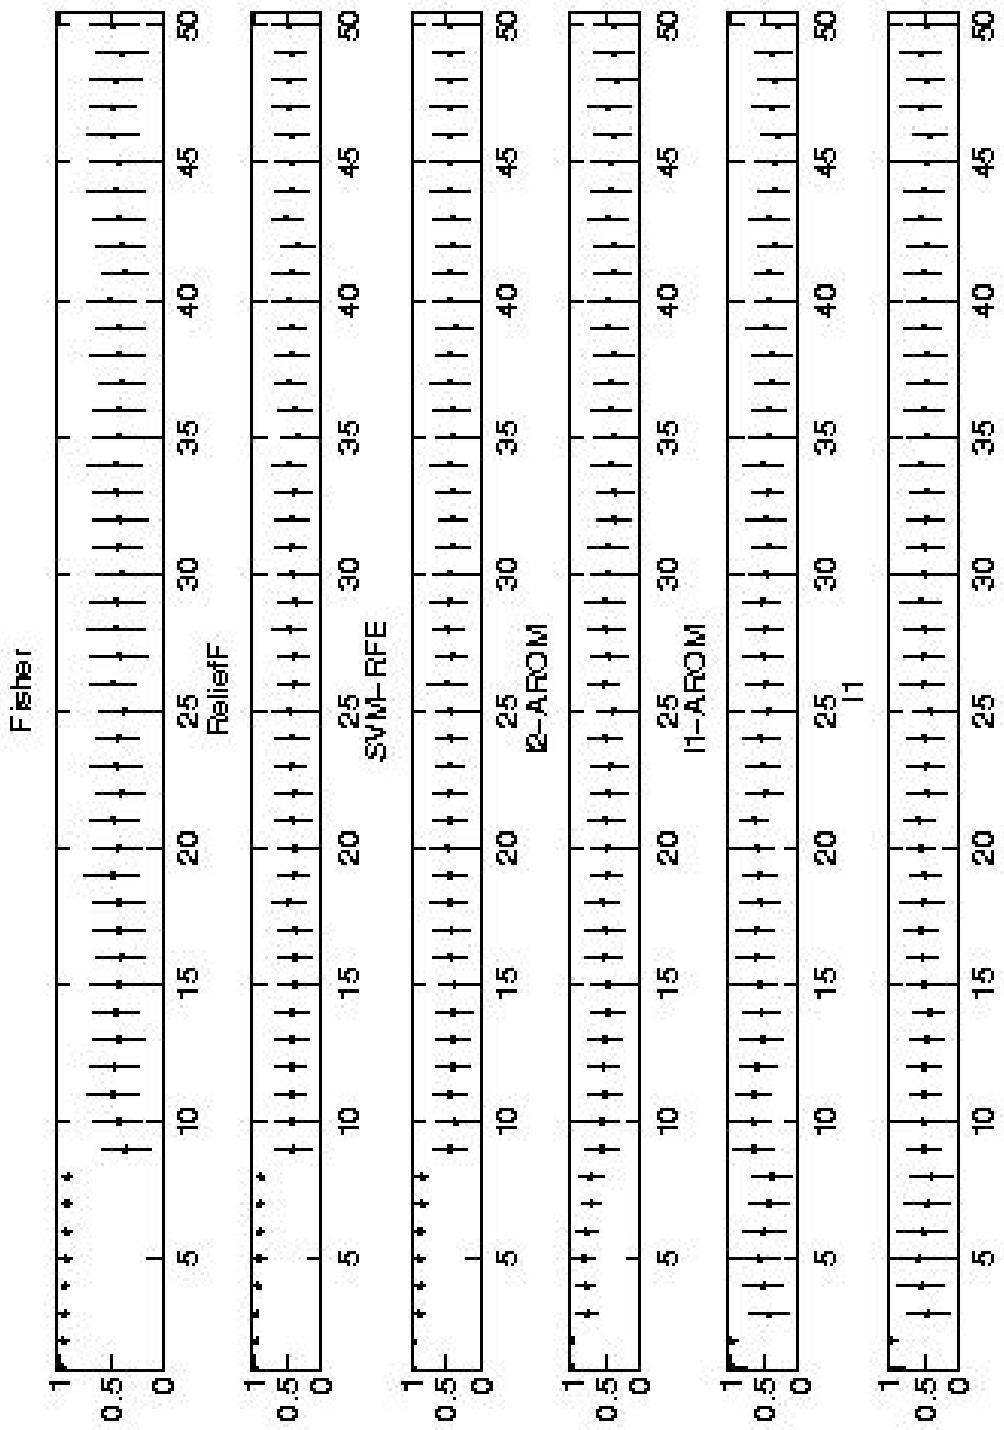
Classificateurs	KNN	K = $\text{sqrt}(N_{\text{train}})$
	Fisher	
SVM		Noyau linéaire (svmlib2.5, C=1000)
L1-SVM		
Heuristiques	H	Entropie de représentation
	S	Séparabilité des classes
FFEI		Indice de flou
E		Entropie

Cas synthétique

- 50 attributs (distribution uniforme sur $[0,1]$)
- 2 classes, 2 attributs pertinents ;
- 6 attributs corrélés à l'un ou l'autre des attributs pertinents ;
- Les méthodes non supervisées non adaptées car ne peuvent que réduire la redondance ;
- Fiabilité des sélections supervisées étudiées sur 50 tirages de données synthétiques



Cas synthétique - Stabilité



Cas synthétique - Évaluation

Pour un tirage synthétique		Composantes sélectionnées
Fisher		4,6
RelieFF		2,4
SVM-RFE		1,2
Sélection de 2	L2-AROM	1,2
	L1-AROM	1,2
	L1	1,2

Cas synthétique – Heuristiques

Synthétique	E	H	S	FFEI
Sélection de 2	Fisher	0.566	0.030	0.498
	ReliefF	0.563	0.017	0.403
	SVM-RFE	0.629	0.691	1.932
	L2-AROM	0.629	0.691	1.932
	L1-AROM	0.629	0.691	1.932
	L1	0.629	0.691	1.932
				0.467

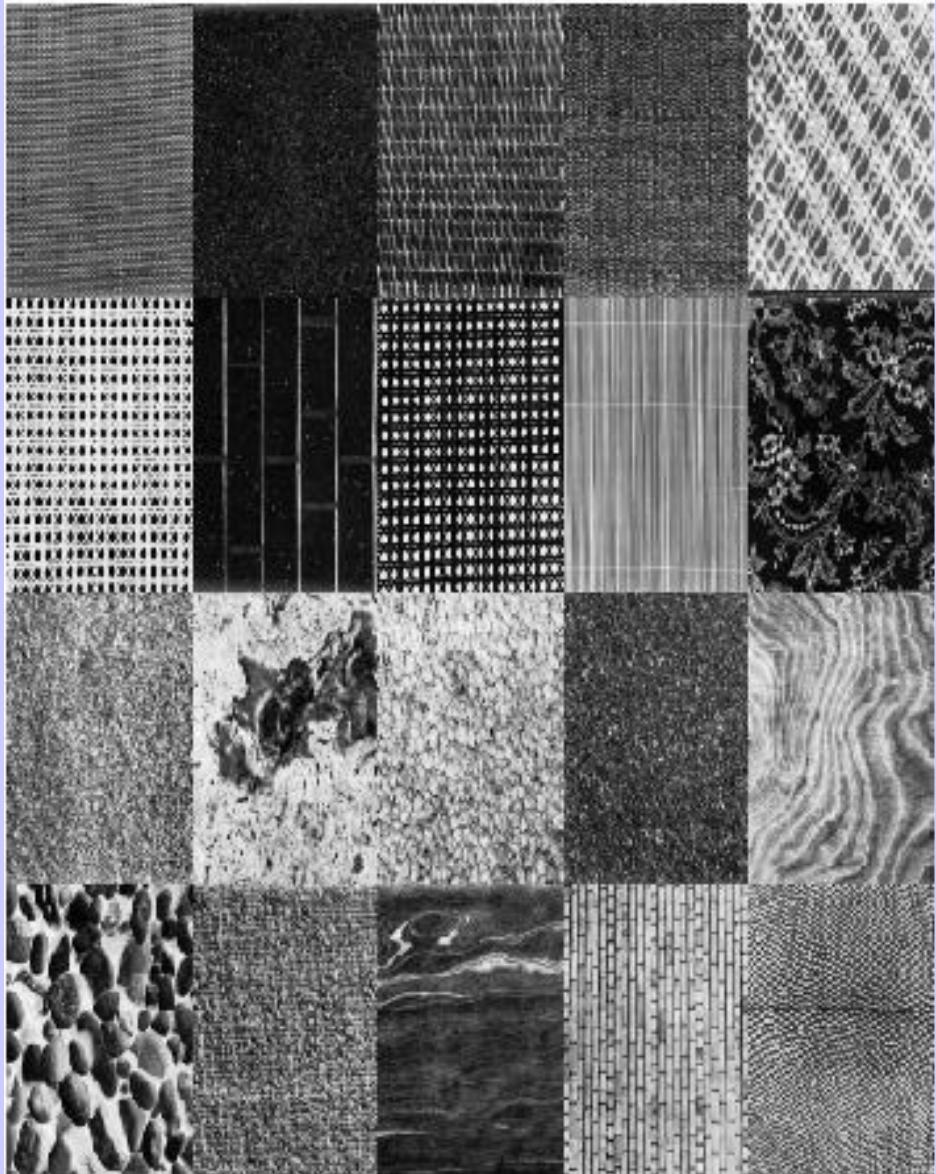
Cas synthétique – Classificateurs

Synthétique	kppv	fisher	svm	L1-svm
Tous les attributs	12.3±3.8	5.3±1.0	7.0±2.2	3.8±2.2
Fisher	30.0±3.9	26.0±3.9	25.8±4.8	26.0±3.6
Relieff	29.8±4.0	26.8±4.0	27.8±4.2	27.8±4.2
SVM-RFE	3.8±3.5	2.8±2.9	0.5±0.6	0.5±0.6
Sélection de 2 attributs				
L2-AROM	3.8±3.5	2.8±2.9	0.5±0.6	0.5±0.6
L1-AROM	3.8±3.5	2.8±2.9	0.5±0.6	0.5±0.6
L1	3.8±3.5	2.8±2.9	0.5±0.6	0.5±0.6
Fisher	4.8±2.9	3.3±2.9	0.8±0.5	0.5±0.6
Relieff	4.8±2.9	3.3±2.9	0.8±0.5	0.5±0.6
SVM-RFE	6.3±0.5	13.5±3.3	0.0±0.0	0.5±0.6
Sélection de 8 attributs				
L2-AROM	10.3±2.2	3.3±2.1	0.3±0.5	0.0±0.0
L1-AROM	10.5±1.7	14.0±2.9	0.0±0.0	0.0±0.0
L1	7.5±1.7	7.8±2.4	1.0±0.8	1.3±1.3

Cas synthétique – 8 attributs

Synthétique	kppv	fisher	svm	L1-svm	H	S
8 premiers attributs	6.0±2.6	4.5±2.4	1.5±2.4	0.3±0.5		
Fisher	30.5±4.0	25.3±3.6	26.5±4.4	26.5±4.4	0.017	0.49
Relieff	3.8±3.5	2.8±2.9	0.5±0.6	0.5±0.6	0.691	1.93
SVM-RFE	3.8±3.5	2.8±2.9	0.5±0.6	0.5±0.6	0.691	1.93
L2-AROM	3.8±3.5	2.8±2.9	0.5±0.6	0.5±0.6	0.691	1.93
L1-AROM	3.8±3.5	2.8±2.9	0.5±0.6	0.5±0.6	0.691	1.93
L1	3.8±3.5	2.8±2.9	0.5±0.6	0.5±0.6	0.691	1.93
kMeans-FS	6.5±3.1	6.8±2.9	6.0±3.4	6.0±3.4	0.691	1.84
MIC	31.0±4.6	26.5±4.4	27.5±4.5	27.5±4.5	0.016	0.40
SVC-FS	5.0±3.4	3.8±2.1	2.8±1.7	2.8±1.7	0.691	1.92

20 images de Brodatz



Résultats de classification

Brodatz	Nb	kppv	fisher	svm	L1-svm
Tout	180	4.2±1.3	4.4±2.3	2.6±2.1	1.2±1.3
Haralick	78	3.4±2.1	4.6±2.3	1.6±1.7	1.4±0.5
Gabor	24	4.8±1.6	6.4±2.2	6.4±4.0	12.4±1.7
Steer	26	13.8±3.6	8.2±3.6	7.6±1.8	7.8±2.3
Contourlet	26	14.4±1.8	4.4±2.6	8.4±3.8	8.6±3.8
Qmf	26	14.0±5.6	5.0±2.2	13.8±3.5	14.8±1.8

Les coefficients d'Haralick

	Brodatz	kppv	fisher	svm	L1-svm	H	S
78 attributs	3.4±2.1	4.6±2.3	1.6±1.7	1.4±0.5			
Fisher	2.6±2.1	3.4±2.1	1.4 ±1.6				
Relieff	6.6±3.4	12.8±3.6	3.0±1.2	6.4±3.3	1.17	25.66	
SVM-RFE	3.2±1.5	8.8±3.3	2.2±1.5	2.8±0.9	1.28	22.53	
L2-AROM	3.6±1.1	8.4±3.5	1.8±1.5	2.8±1.3	1.50	26.39	
L1-AROM	3.8±0.9	4.6±2.4	1.4±1.5	2.6±1.3	1.69	28.03	
L1	3.4±1.8	5.2±1.6	1.0±1.2	3.0±1.4	1.63	27.97	
KMeans-RS	3.2±1.5	4.6±2.3	2.4±2.9	1.8±2.2	1.64	27.10	
MIC	2.4±1.3	6.8±2.8	2.6±1.8	2.8±1.8	1.69	25.57	
SVC-FS	2.6±1.7	4.4±2.4	2.0±1.4	2.0±1.4	1.82	24.51	

Conclusion

- Les procédures de sélection automatiques permettent une comparaison objective des caractéristiques ;
- Les procédures non supervisées sont rapides et aussi efficaces que les procédures supervisées sur les bases (réelles) testées ;
- Nécessité de coupler les choix de l'algorithme de sélection et du classificateur dans l'application finale.
- S'applique à n'importe quel type de données.

Perspectives à court terme

- Évaluation du nombre minimal de caractéristiques à sélectionner ;
- Extension de SVC-FS et KMeans-FS à la suppression des caractéristiques non pertinentes ;
- Mise au point d'une procédure d'évaluation complètement non supervisée (utilisation de clusterisation des données + heuristiques d'évaluation de la qualité des clusters).