

Classification Automatique d'Images

Application à l'Imagerie du Poumon Profond

Chesner Desir

Membres du Jury

Mme Isabelle BLOCH
M. Frédéric JURIE
M. Lionel PREVOST
Mme Caroline PETITJEAN
M. Luc THIBERVILLE
M. Laurent HEUTTE




PR, Télécom ParisTech
PR, Université de Caen
PR, Université Antilles-Guyane
MCF, Université de Rouen
PU-PH, Université de Rouen
PR, Université de Rouen

Présidente
Rapporteur
Rapporteur
Encadrante
Encadrant
Directeur



Établissement d'une nouvelle technique d'imagerie

- **Alvéoscopie** par Microscopie Confocale Fibrée en Fluorescence (MCFF), technologie brevetée : *Prof. Luc Thiberville & Maunakea Technologies*
- Imagerie 3D in-vivo temps réel des structures alvéolaires du poumon profond [Thiberville, CJ2007]
- Possible remplacement à terme de la biopsie



Patient sain

(a) Patient sain

Patient malade

(b) Patient malade

Patient sain

(a) Patient sain non-fumeur

Patient sain

(b) Patient sain fumeur

- Essai clinique, études et expertise en cours
[Thiberville (ERJ2009, ERM2010, RMRA2012, IPM2013)]
- Absence de description univoque

Objectif de la thèse

Apport d'une aide au diagnostic médical

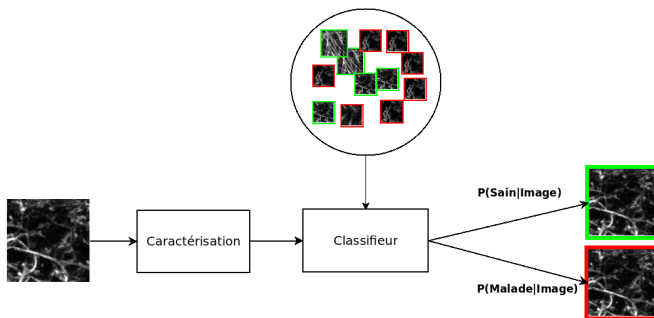
- Caractériser de façon pertinente les images MCFF
- Distinguer automatiquement les cas sains des cas pathologiques
- Fournir au praticien des données quantitatives liées à la décision

- 1 Contexte médical
- 2 Un premier système complet de classification
 - Caractérisation des images
 - Pilotage du rejet
- 3 La classification one-class
 - Gestion de l'out-of-class
 - Une approche discriminante par méthodes d'ensemble
- 4 Conclusion & Perspectives


- 1 Contexte médical
- 2 **Un premier système complet de classification**
 - Caractérisation des images
 - Pilotage du rejet
- 3 La classification one-class
 - Gestion de l'out-of-class
 - Une approche discriminante par méthodes d'ensemble
- 4 Conclusion & Perspectives

Système de classification automatique

Classification d'images classification d'images médicales [Martins, CVIA09] [Marée, CVBIA05], **détection de véhicules** [Negri, JASP08], **piétons** [Papageorgiou, ICIP99], **visages** [Viola, CVPR01], **identification d'objets divers** [Moosmann, PAMI08], **analyse de scènes** [Duda et al., 2000]




Système de classification automatique



Caractérisation

- Haut-niveau ou bas-niveau
- Globale ou locale
- Dédicée au contenu ou générique


Système de classification automatique



Caractérisation

- pixels bruts [Marée, CVPR05], ondelettes [Papageorgiou, ICCV98], opérateur de Harris [Schmid, IJCV00], statistiques d'histogrammes, de co-occurrence [Haralick, SMC73], LBP [Ojala, PAMI02], SIFT [Lowe, IJCV04]
- points d'intérêt [Mikolajczyk, PAMI05], fenêtres [Marée, CVPR05], vocabulaire visuel [Nowak, ECCV06]

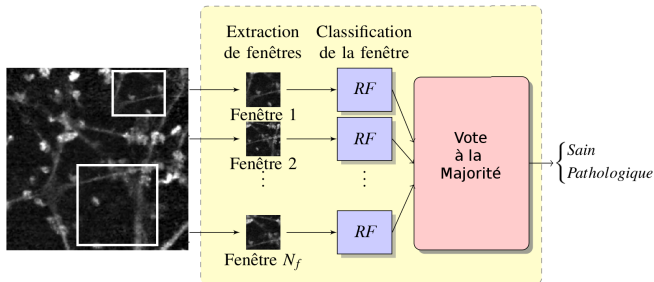
Système de classification automatique



Apprentissage de la fonction de décision

- Classifieurs : **KPPV**, **arbre de décision** [Breiman, 1984], **SVM** [Vapnik, 1998], **MLP** [Bishop, 1995], **Gauss**, **GMM**
- Ensemble de classifieurs : **Adaboost** [Freund, ICML96], **Bagging** [Breiman, ML96], **Random Subspace Method** [Ho, PAMI98], **Randomized Trees (RFS)** [Dietterich, ML00], **Random Forests** [Breiman, ML01]

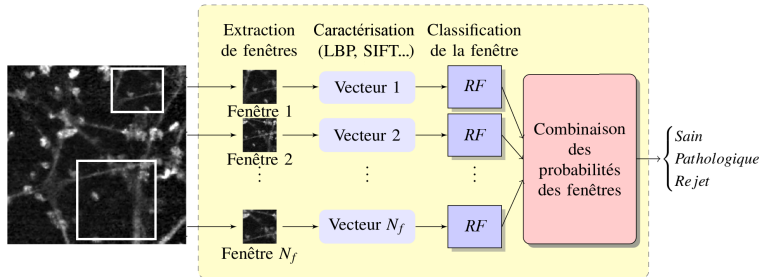
Système de classification automatique



Random subwindows + Extra-Trees [Marée, CVPR05]

- Extraction locale avec des **fenêtres aléatoires**
- Caractérisation par **pixels bruts**
- Classification : **Extremely-Randomized Trees** [Geurts, ML06]


Mise en place d'un premier système de classification




- 1 Quels descripteurs ?
- 2 Quel niveau de caractérisation ?
- 3 Quel mécanisme de pilotage du rejet ?

Base d'images alvéoloscopiques


Classes \ Groupes	Non-fumeur	Fumeur
	Sain	31
Pathologique	102	33
Total	133	93




Sain NF



Patho. NF



Sain F




Patho. F

1) Comparaison des descripteurs

- Local Binary Patterns (LBP) [Ojala, PAMI02]
- Scale Invariant Feature Transform (SIFT), Dense-SIFT [Lowe, IJCV04]
- Statistiques de co-occurrence [Haralick, SMC73]

	SIFT	Cooccurrence	LBP
Dimension	128	140	28



Évaluation du pouvoir discriminant par **1-PPV** en leave-one-out

Comparaison des descripteurs : résultats & analyses

TABLE: Performances pour la base non-fumeur

Descripteur	accr	tpr	tnr
Co-occurrence	79.69	89.21	48.38
SIFT	83.45	92.15	54.83
Dense-SIFT	73.68	83.33	41.93
LBP	92.48	95.09	83.87

TABLE: Performances pour la base fumeur

Descripteur	accr	tpr	tnr
Co-occurrence	88.17	87.87	88.33
SIFT	78.49	72.72	81.66
Dense-SIFT	66.66	51.51	75
LBP	93.54	93.93	93.33

2) Caractérisation locale vs globale

Procédure 10-fold

- Extra-trees ($L = 30$, $K_{RFS} = \sqrt{M}$)
- SVM (noyau polynomial, $C = 10^5$)

Caractérisation locale

- 10K fenêtres en apprentissage
- 100 fenêtres par image de test

Performances pour la base non-fumeur

	Globale	Locale
ET	91.53 ± 8.46%	93.84 ± 7.06%
SVM	91.82 ± 8.24%	90.76 ± 8.73%

Performances pour la base fumeur

	Globale	Locale
ET	94.44 ± 7.85%	97.77 ± 4.68%
SVM	94.44 ± 7.85%	98.88 ± 3.51%

2) Caractérisation locale vs globale

Performances pour la base non-fumeur

	Globale	Locale
ET	91.53 ± 8.46%	93.84 ± 7.06%
SVM	91.82 ± 8.24%	90.76 ± 8.73%

Performances pour la base fumeur


	Globale	Locale
ET	94.44 ± 7.85%	97.77 ± 4.68%
SVM	94.44 ± 7.85%	98.88 ± 3.51%

Complexités avec N exemples

- $T_{ET} = L \cdot N \cdot \log_2 N$, avec L arbres
- $T_{SVM} = N^3 + (M + 1) \cdot N^2$, en dimension M


Influence de la taille des fenêtres extraites

Comparaison entre une taille fixe et une taille aléatoire



Influence de la taille des fenêtres extraites

Comparaison entre une taille fixe et une taille aléatoire



	Non-fumeur	Fumeur
ET	93.84 ± 7.06%	97.77 ± 4.68%

3) Réduction de la non-détection


- Erreur de **non-détection** : **8%** (non-fumeur), **3%** (fumeur)
- Approches de pilotage du rejet **seuil sur la probabilité a posteriori** [Antal, AIM2003] [Bishop, ISP94], **seuil sur le voisinage** [Jain, PAMI1999]

Mécanisme de rejet avec les extra-trees

- 1 **Seuil sur la mesure de confiance** (remplacement du vote à la majorité)
- 2 **Vote fréquentiel avec élagage des arbres** pour mieux rendre compte du consensus pour la décision

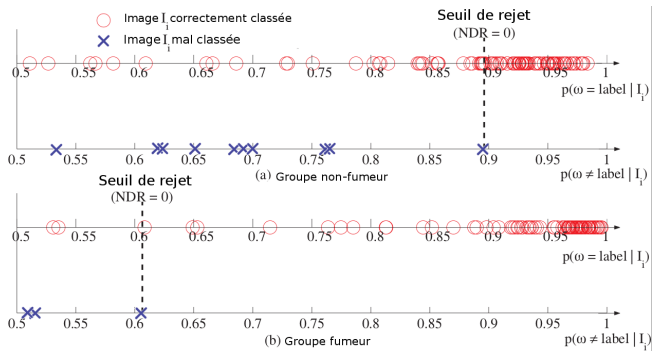
1) Seuillage sur la probabilité a posteriori

$$\text{Mesure de confiance : } p(\omega_S | I) = \frac{1}{N_f} \cdot \sum_i \frac{I_i^S}{L}$$



1) Seuillage sur la probabilité a posteriori

$$\text{Mesure de confiance} : p(\omega_S | I) = \frac{1}{N_f} \cdot \sum_i \frac{I_i^S}{L}$$




- Annulation du taux de non-détection avec un seuil adapté
- Faux rejet (36.1% non-fumeur, 5.4% fumeur)


2) Mesure de confiance fréquentielle

$$p(\omega_S | x_i) = \frac{I_i^S}{L}, I_i^S = \sum_{k=1}^L f_{ik}^S \text{ (par élagage des arbres)}$$

Vote binaire




Vote fréquentiel



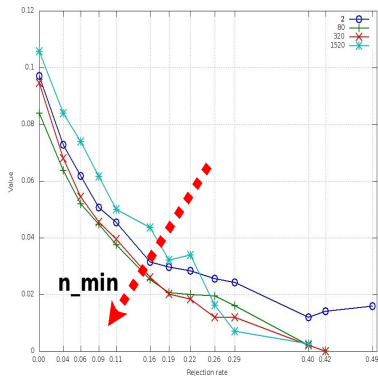
2) Mesure de confiance fréquentielle

$$p(\omega_S | x_i) = \frac{I_i^S}{L}, I_i^S = \sum_{k=1}^L f_{ik}^S \text{ (par élagage des arbres)}$$

Vote binaire



Vote fréquentiel



Conclusion

Un système complet de classification des images MCFF

- Une approche **locale** d'extraction du contenu
- Une description **riche et générique**
- Un classifieur performant et robuste : les **extra-trees**
- Un mécanisme de **pilotage du rejet**
- **Seuil de rejet à fixer**
- **Faux rejet important**

Conclusion

Un système complet de classification des images MCFF

- Une approche **locale** d'extraction du contenu
- Une description **riche et générique**
- Un classifieur performant et robuste : les **extra-trees**
- Un mécanisme de **pilotage du rejet**
- **Seuil de rejet à fixer**
- **Faux rejet important**

Perspectives

- Extraction de "fenêtres d'intérêt"
- Post-élagage vs pré-élagage des arbres
- Élagage de la **forêt**

Conclusion

- Difficultés d'étiquetage des images de patients malades
Territoires sains traversés lors de l'exploration de territoires malades
- Seules les images de patients sains peuvent être étiquetées comme **saines** avec certitude par les experts et servir de référence

Conclusion

- Difficultés d'étiquetage des images de patients malades
Territoires sains traversés lors de l'exploration de territoires malades
- Seules les images de patients sains peuvent être étiquetées comme **saines** avec certitude par les experts et servir de référence
- Apprentissage d'un modèle avec uniquement les éléments des cas sains \Rightarrow **classification one-class**

Conclusion

- Difficultés d'étiquetage des images de patients malades
Territoires sains traversés lors de l'exploration de territoires malades
- Seules les images de patients sains peuvent être étiquetées comme **saines** avec certitude par les experts et servir de référence
- Apprentissage d'un modèle avec uniquement les éléments des cas sains \Rightarrow **classification one-class**

Applications "one-class" Identification de patients dépressifs

[Mourao, NI11], **détection de tumeurs en mammographie** [Tarassenko, ANN95], **détection d'infections nosocomiales** [Cohen, SHTI08], **surveillance de l'intégrité des constructions** [Tarassenko, ESHM09], **identification de cibles RADAR** [Moya, NASA93], **analyse de documents manuscrits** [Scholkopf, NC01], **reconnaissance d'utilisateurs** [Hempstalk, MLKDD08]

- 1 Contexte médical
- 2 Un premier système complet de classification
 - Caractérisation des images
 - Pilotage du rejet
- 3 **La classification one-class**
 - Gestion de l'out-of-class
 - Une approche discriminante par méthodes d'ensemble
- 4 Conclusion & Perspectives

La classification one-class : gestion de l'out-of-class

Catégorisation classique [Tax, ML2004]

Estimateurs de densité, reconstruction, frontière

Gestion de l'out-of-class

- Approches sans hypothèses sur les données outliers
- Approches simulant les données outliers
- Approches générant les données outliers

La classification one-class : gestion de l'out-of-class

Catégorisation classique [Tax, ML2004]

Estimateurs de densité, reconstruction, frontière

Gestion de l'out-of-class

- Approches sans hypothèses sur les données outliers
Estimateurs de densité [Bishop, ISP94] [Tarassenko, ICANN95],
"data description" SVDD/NNDD [Tax, ML2004], reconstruction
[Japkowicz, IJCAI95]
- Approches simulant les données outliers
- Approches générant les données outliers

La classification one-class : gestion de l'out-of-class

Catégorisation classique [Tax, ML2004]

Estimateurs de densité, reconstruction, frontière

Gestion de l'out-of-class

- Approches sans hypothèses sur les données outliers
Estimateurs de densité [Bishop, ISP94] [Tarassenko, ICANN95],
"data description" SVDD/NNDD [Tax, ML2004], reconstruction
[Japkowicz, IJCAI95]
- Approches simulant les données outliers One-class SVM
[Scholkopf, NC01], CLTrees [Liu, ICIKM00], simulation par
mesure de sparsité [Aggarwal, ICMD01]
- Approches générant les données outliers

La classification one-class : gestion de l'out-of-class

Catégorisation classique [Tax, ML2004]

Estimateurs de densité, reconstruction, frontière

Gestion de l'out-of-class

- Approches sans hypothèses sur les données outliers
Estimateurs de densité [Bishop, ISP94] [Tarassenko, ICANN95],
“data description” SVDD/NNDD [Tax, ML2004], **reconstruction**
[Japkowicz, IJCAI95]
- Approches simulant les données outliers **One-class SVM**
[Scholkopf, NC01], **CLTrees** [Liu, ICIKM00], **simulation par
mesure de sparsité** [Aggarwal, ICMD01]
- Approches générant les données outliers **Approches
discriminantes** [Fan, KIS04][Hempstalk, MLKDD08]

Notre contribution : les méthodes d'ensemble

Approches discriminantes

- Instances de la seconde classe : **génération des outliers**
- Malédiction de la dimensionalité : **mécanismes de randomisation des méthodes d'ensemble**

Notre contribution : les méthodes d'ensemble

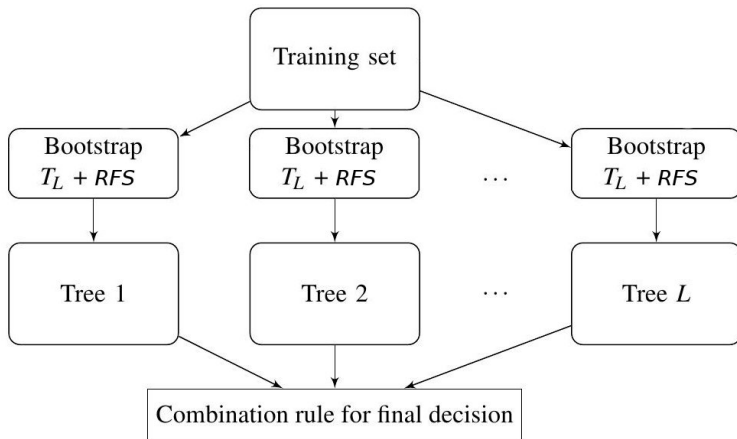
Approches discriminantes

- Instances de la seconde classe : **génération des outliers**
- Malédiction de la dimensionalité : **mécanismes de randomisation des méthodes d'ensemble**

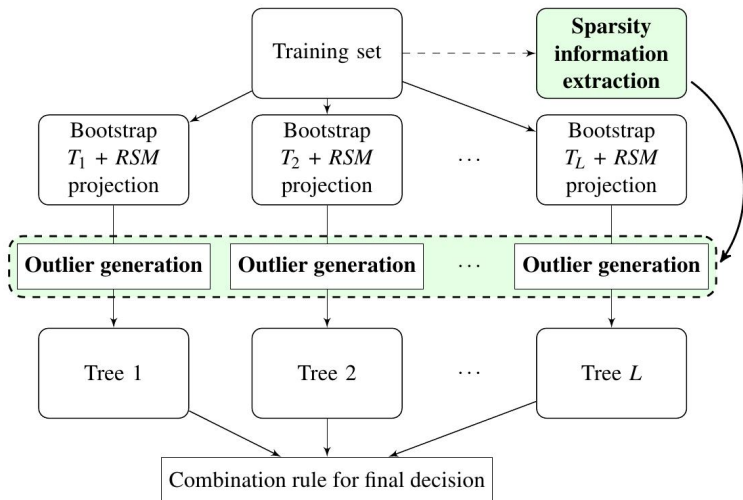
Contribution : **“one-class random forest”** (OCRF)

- Nouvelle approche discriminante one-class
- Par méthode d'ensemble d'arbres
- Avec un mécanisme efficace de génération des outliers

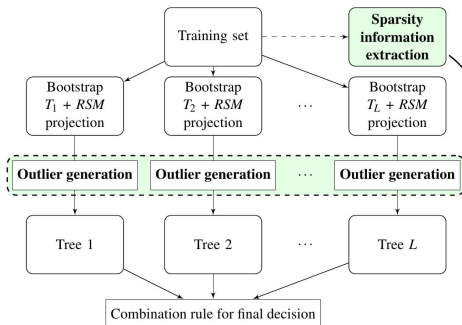
Oneclass Random Forest



Oneclass Random Forest




Oneclass Random Forest

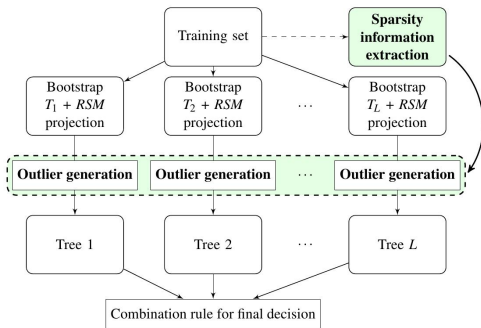


Génération artificielle

- Distributions régulières
(uniforme, gaussienne)
- Basée sur les targets
(distribution-based)




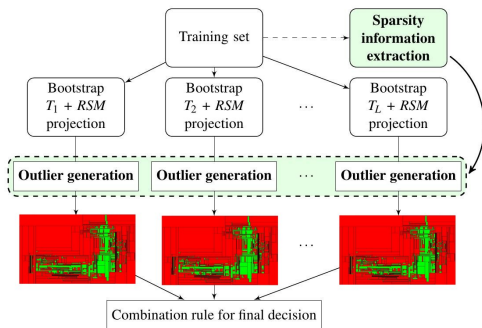
Oneclass Random Forest



À quel moment ?

- En amont de l'apprentissage
- Dans le set bootstrap
- Après RSM (bootstrap projeté)

Oneclass Random Forest



Oneclass Random Forest : algorithme

Require: Set d'apprentissage T , nombre d'arbres L , α , β , K_{RSM}

Ensure: Classifieur OCRF

- 1: (A) **Extraction d'informations a priori**
- 2: $H_{outlier} = 1 - H_{target}$, complémentaire de H_{target} , histogramme normalisé
- 3: (B) **Génération des outliers et induction de la forêt**
- 4: **for** $l = 1$ à L **do**
- 5: (i) Set bootstrap T_l à partir de T
- 6: (ii) Projection de T_l dans le sous-espace RSM (dim. K_{RSM})
- 7: (iii) Génération de $N_{outlier} = \beta \cdot N_{target}$ données outliers selon $H_{outlier}$ dans le domaine $\Omega_{outlier} = (1 + \alpha) \cdot \Omega_{target}$
- 8: (iv) Induction d'un arbre de décision standard
- 9: **end for**
- 10: **return** Modèle OCRF

Évaluation des OCFR

- 1 Étude du comportement des OCFR
 - Paramètres "critiques" α (domaine) et β (quantité)
 - Bases artificielles
 - Comparaison avec des approches de l'état de l'art
- 2 Comparaison avec les approches de l'état de l'art
 - Bases publiques
 - Robustesse à la dimension
- 3 Classification one-class des images alvéoscopiques : apports du one-class





1) Étude du comportement des OCFR

5 bases artificielles : Gauss, 3_gauss, banana, ellipse, donut




- $m \in [2; 160]$
- $N_{target-app} = 2000$ données targets en apprentissage ;
- $N_{outlier-test} = N_{target-test} = 10000$ en test ; outliers dans un hyperbox englobant

Paramétrisation des OCFR

- $L = 200$, $K_{RSM} = 10$ ou $K_{RSM} = M$ si $M < 10$,
 $K_{RFS} = \sqrt{K_{RSM}}$

(a) Résultats : influence de α (domaine)

Résultats : influence de β (quantité d'outliers)



Comparaison avec les approches de l'état de l'art

Classifieurs comparés : Gauss, one-class SVM (OCSVM), Parzen, MoG

Distrib. gauss.	OCRF	OCSVM	Gauss	Parzen	MoG
	Accr T O	Accr T O	Accr T O	Accr T O	Accr T O
2D	87.7 91.1 84.2	94.9 89.9 100	88.5 94.8 82.2	88.3 93.8 82.7	88.4 94.6 82.3
3D	92.4 94.2 90.6	95.0 90.1 100	92.6 94.7 90.5	92.4 93.2 91.5	92.5 94.4 90.7
5D	97.2 97.8 96.6	94.9 89.9 100	97.0 95.9 98.1	94.0 89.2 98.8	96.7 95.1 98.2
10D	99.3 99.4 99.2	94.4 88.8 99.9	97.3 94.6 99.9	65.9 31.9 100	96.3 92.6 99.9
20D	99.9 99.9 99.9	93.5 87.0 100	96.6 93.2 100	50.0 00.0 100	92.9 85.9 100
40D	100 100 100	93.9 87.8 100	96.4 92.8 100	50.0 00.0 100	90.1 80.2 100
60D	100 100 100	94.4 88.9 100	95.7 91.5 100	50.0 00.0 100	89.8 79.6 100
80D	100 100 100	93.7 87.5 100	95.2 90.4 100	50.0 00.0 100	77.6 55.2 100
100D	100 100 100	93.2 86.4 100	93.2 86.5 100	50.0 00.0 100	72.3 44.7 100
120D	100 100 100	93.4 86.8 100	92.4 84.8 100	50.0 00.0 100	84.1 68.3 100
140D	100 100 100	93.7 87.5 100	90.8 81.6 100	50.0 00.0 100	76.6 53.2 100

- OCRF supporte la dimension
- Difficultés pour Parzen, MoG

2) Comparaison avec les approches de l'état de l'art

Paramètres des OCRF :

- $\beta = 10, \alpha = 1.2$
- $L = 200, K_{RSM} = 10$ ou $K_{RSM} = M$ si $M < 10$,
 $K_{RFS} = \sqrt{K_{RSM}}$

Classifieurs : Gauss, OCSVM, Parzen, MoG

Apprentissage : 10-fold stratifiés x 5


Mesures de performances : Accr, tpr, tnr, [Matthews](#)

[Correlation Coefficient](#) (MCC) [Matthews, BBKA-PS75]

$$\text{MCC} = \frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}}$$


2) Comparaison avec les approches de l'état de l'art

Matthews Correlation Coefficient (MCC) [Matthews, BBKA-PS75]



2) Comparaison avec les approches de l'état de l'art

Matthews Correlation Coefficient (MCC) [Matthews, BBKA-PS75]



	OCRf	OCSVM	Gauss	Parzen	MoG
#MCC < 0	0	1	2	2	1
#MCC = 0	0	32	0	37	12
#MCC > 0.5	45	12	60	8	39
# Rang=1	23	7	35	4	9

Nombre total de bases : 78

Tests statistiques

Comparaison statistique [Demsar, JMLR06]

$$\chi_{F(k-1)}^2 = \frac{12N}{k(k+1)} \left(\sum_{j=1}^k R_j^2 - \frac{k(k+1)^2}{4} \right) \quad [\text{Friedman, AMS1940}]$$


$$F_{F((k-1);(k-1)(N-1))} = \frac{(N-1)\chi_F^2}{N(k-1) - \chi_F^2} \quad [\text{Iman and Davenport, 1979}]$$

$$CD_{Nemenyi} = q_\alpha \sqrt{\frac{k(k+1)}{6N}} \quad [\text{Nemenyi, 1963}]$$

	Gauss	OCRF	MoG	Parzen	OCSVM
Gauss		0	+	+	+
OCRF	0		0	+	+
MoG	-	0		+	+
Parzen	-	-	-		0
OCSVM	-	-	-	0	

Robustesse de OCRF par rapport à la dimension

Base MFeat-FKZM [Jain, Duin, Mao, PAMI00] 333 dimensions
 Factors (216) + Karhunen (64) + Zernike (47) + Morphological (6)



Classification one-class des images alvéoscopiques

	OCRF	OCSVM	Gauss	Parzen	MoG
MCC	0.71±0.03	0.51±0.07	0.00±0.00	0.00±0.00	0.00±0.00
Accr	0.88±0.02	0.82±0.03	0.76±0.00	0.76±0.00	0.76±0.00
T	0.81	0.27	0.00	0.00	0.00
O	0.91	1.00	1.00	1.00	1.00

Base non-fumeur

MCC	0.42±0.03	0.50±0.01	0.76±0.00	0.31±0.00	0.36±0.04
Accr	0.63±0.02	0.67±0.01	0.89±0.00	0.50±0.00	0.54±0.04
T	0.48	0.49	0.90	0.23	0.30
O	0.93	1.00	0.87	1.00	1.00

Base fumeur

		$\beta = 10$	$\beta = 1$
<i>Alveo_S</i>	MCC	0.42±0.03	0.56±0.09
	Accr	0.63±0.02	0.80±0.04
	T	0.48	0.86
	O	0.93	0.85

Conclusion sur les OCRF

- OCFR générique, robuste à la dimension
- OCFR performant par rapport à l'état de l'art
- Paramètre β : compromis à approfondir

Conclusion sur les OCRF

- OCFR générique, robuste à la dimension
- OCFR performant par rapport à l'état de l'art
- Paramètre β : compromis à approfondir

Perspectives

- Remplacer les arbres par des MLP, SVM ou estimateurs de densité
- Génération parcimonieuse des outliers
- Détection de sous-espaces RSM pertinents en amont
- Simulation en chaque nœud de l'arbre

- 1 Contexte médical
- 2 Un premier système complet de classification
 - Caractérisation des images
 - Pilotage du rejet
- 3 La classification one-class
 - Gestion de l'out-of-class
 - Une approche discriminante par méthodes d'ensemble
- 4 Conclusion & Perspectives

Conclusion

Outil d'aide au diagnostic médical mise en place de 2 systèmes complets de classification

Un système complet de classification binaire

- Caractérisation locale et riche des images
- Mécanisme d'amélioration de la fiabilité de la décision

Une approche discriminante one-class OCRF

- Traitement de problèmes variés et en grande dimension
- Approche nouvelle, existence de compromis à approfondir, des optimisations à l'étude

Perspectives

Perspectives pour la classification binaire standard

- Incorporation de critères médicaux visuels
- Traitement de séquences vidéos, incorporation d'informations temporelles

Perspectives

Perspectives pour la classification binaire standard

- Incorporation de critères médicaux visuels
- Traitement de séquences vidéos, incorporation d'informations temporelles

Perspectives pour les forêts aléatoires one-class

- Extension aux problématiques de données déséquilibrées
- Extension aux problèmes de clustering
- Sélection de caractéristiques pour le one-class

Sources principales de financement de la thèse

- **ADIR** : financement de la 1ère année
Association d'Assistance à Domicile aux Insuffisants Respiratoires
- **Ligue contre le Cancer** : financement de la 2ème et la 3ème année









Merci pour votre attention

Publications les plus significatives

- C. Desir, S. Bernard, C. Petitjean, and L. Heutte, Oneclass Random Forest, *Pattern Recognition*, 2013, 10.1016/j.patcog.2013.05.022
- C. Desir, C. Petitjean, L. Heutte, M. Salaun, and L. Thiberville. Classification of endomicroscopic images of the lung based on random subwindows and extra-trees. *IEEE Trans. on Biomedical Engineering*, 59(9) :2677–2683, 2012.
- C. Desir, C. Petitjean, L. Heutte, M. Salaun, and L. Thiberville. An svm distal lung image classification using texture descriptors. *Computerized Medical Imaging and Graphics*, Volume 36, pp. 264-270, 2012.
- C. Desir, S. Bernard, C. Petitjean, and L. Heutte. A random forest based approach for one-class classification in medical imaging. 3rd *MICCAI International Workshop on Machine Learning in Medical Imaging*, MLMI 2012 Nice, France, LNCS 57588, pp 250-257, 2012.
- C. Desir, S. Bernard, C. Petitjean, and L. Heutte. A new random forest method for one-class classification. *IAPR International Workshop on Statistical Techniques in Pattern Recognition*, SPR 2012, Hiroshima, Japan, LNCS 7626, pp 282–290, 2012.
- D. Hebert, C. Desir, C. Petitjean, L. Heutte, and L. Thiberville. Detection of pathological condition in distal lung images. *9th IEEE International Symposium on Biomedical Imaging*, pages 1603–1606. IEEE, 2012.

-  Aggarwal, C. and Yu, P. (2001).
Outlier detection for high dimensional data.
In Proceedings of the 2001 ACM SIGMOD international conference on Management of data, page 46. ACM.
-  Antal, P., Fannes, G., Timmerman, D., Moreau, Y., De Moor, B., et al. (2003).
Bayesian applications of belief networks and multilayer perceptrons for ovarian tumor classification with rejection.
Artificial intelligence in medicine, 29(1) :39–60.
-  Bishop, C. (1994).
Novelty detection and neural network validation.
IEE Proceedings-Vision, Image and Signal processing, 141(4) :217–222.
-  Bishop, C. M. (1995).
Neural Networks for pattern recognition.

Clarendon Press Oxford.



Breiman, L. (1996).

Bagging predictors.

Machine Learning, 26(2) :123–140.



Breiman, L. (2001).

Random forests.

Machine Learning, Vol. 45 (1) :5–32.



Breiman, L., Friedman, J., Olshen, R., and Stone, C.
(1984).

Classification and regression trees.

Wadsworth and Brooks, Monterey, CA.



Cohen, G., Sax, H., Geissbuhler, A., et al. (2008).

Novelty detection using one-class parzen density estimator.
an application to surveillance of nosocomial infections.

volume 136, page 21. IOS Press ; 1999,



Demsar, J. (2006).

Statistical comparisons of classifiers over multiple data sets.

The Journal of Machine Learning Research, 7 :1–30.



Dietterich, T. (2000).

An experimental comparison of three methods for constructing ensembles of decision trees : Bagging, boosting, and randomization.

Machine learning, 40(2) :139–157.



Duda, R. O., Hart, P. E., and Stork, D. G. (2000).

Pattern classification.

Wiley-interscience.



Fan, W., Miller, M., Stolfo, S., Lee, W., and Chan, P. (2004).

Using artificial anomalies to detect unknown and known network intrusions.

Knowledge and Information Systems, 6(5) :507–527.



Freund, Y. and Schapire, R. (1996).

Experiments with a new boosting algorithm.

In International Conference on Machine Learning, pages 148–156.



Friedman, M. (1940).

A comparison of alternative tests of significance for the problem of m rankings.

The Annals of Mathematical Statistics, 11(1) :86–92.



Geurts, P., Ernst, D., and Wehenkel, L. (2006).

Extremely randomized trees.

Machine Learning, 63(1) :3–42.



Haralick, R. M., Shanmugam, K., and Dinstein, I. (1973).

Textural features for image classification.

IEEE Transactions on Systems, Man and Cybernetics,
3(6) :610–621.



Hempstalk, K., Frank, E., and Witten, I. (2008).

One-class classification by combining density and class probability estimation.

Machine Learning and Knowledge Discovery in Databases,
pages 505–519.



Ho, T. (1998).

The random subspace method for constructing decision forests.

IEEE Transactions on Pattern Analysis and Machine Intelligence, 20(8) :832–844.



Iman, R. and Davenport, J. (1979).

Approximations of the critical region of the friedman statistic.

Technical report, Sandia Labs., Albuquerque, NM (USA) ;
Texas Tech Univ., Lubbock (USA).



Jain, A., Duin, R., and Mao, J. (2000).

Statistical pattern recognition : A review.

Pattern Analysis and Machine Intelligence, IEEE Transactions on, 22(1) :4–37.



Jain, A. K., Prabhakar, S., and Hong, L. (1999).

A multichannel approach to fingerprint classification.





Pattern Analysis and Machine Intelligence, IEEE Transactions on, 21(4) :348–359.



Liu, B., Xia, Y., and Yu, P. (2000).

Clustering through decision tree construction.

In Proceedings of the ninth international conference on Information and knowledge management, pages 20–29.
ACM New York, NY, USA.

-  **Lowe, D. (2004).**
Distinctive image features from scale-invariant keypoints.
International Journal of Computer Vision, 60(2) :91–110.
-  **Marée, R., Geurts, P., Piater, J., and Wehenkel, L. (2005).**
Biomedical image classification with random subwindows and decision trees.
In Proc. of ICCV Workshop on Computer Vision for Biomedical Image Applications, volume 3765 of LNCS, pages 220–229.
-  **Maree, R., Geurts, P., Piater, J., and Wehenkel, L. (2005).**
Random subwindows for robust image classification.
In IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2005. CVPR 2005, volume 1.
-  **Matthews, B. (1975).**

Comparison of the predicted and observed secondary structure of t4 phage lysozyme.

Biochimica et Biophysica Acta (BBA)-Protein Structure, 405(2) :442–451.



Mikolajczyk, K. and Schmid, C. (2005).

A performance evaluation of local descriptors.

IEEE Transactions on Pattern Analysis and Machine Intelligence, 27(10) :1615–1630.



Moosmann, F., Nowak, E., and Jurie, F. (2008).

Randomized clustering forests for image classification.

IEEE Transactions on Pattern Analysis and Machine Intelligence, 30(9) :1632–1646.



Mourao-Miranda, J., Hardoon, D., Hahn, T., Marquand, A., Williams, S., Shawe-Taylor, J., and Brammer, M. (2011).

Patient classification as an outlier detection problem : An application of the one-class support vector machine.
NeuroImage.



Moya, M., Koch, M., and Hostetler, L. (1993).

One-class classifier networks for target recognition applications.

NASA STI/Recon Technical Report N, 93 :24043.



Negri, P., Clady, X., Hanif, S., and Prevost, L. (2008).

A cascade of boosted generative and discriminative classifiers for vehicle detection.

EURASIP Journal on Advances in Signal Processing, 8(2).



Nemenyi, P. (1963).

Distribution-free multiple comparisons.

PhD thesis, Princeton University.



Nowak, E., Jurie, F., and Triggs, B. (2006).

Sampling strategies for bag-of-features image classification.

pages 490–503.



Ojala, T., Pietikainen, M., and Maenpaa, T. (2002).
Multiresolution gray-scale and rotation invariant texture
classification with local binary patterns.

*IEEE Transactions on Pattern Analysis and Machine
Intelligence*, 24(7) :971–987.



Oliveira Martins, L., Junior, G. B., Silva, A. C., de Paiva,
A. C., and Gattass, M. (2009).

Detection of masses in digital mammograms using
k-means and support vector machine.

Electronic Letters on Computer Vision and Image Analysis,
8(2) :39–50.



Papageorgiou, G., Oren, M., and Poggio, T. (1998).

A general framework for object detection.

In Proceedings of ICCV.



Papageorgiou, C. and Poggio, T. (1999).

Trainable pedestrian detection.

In Image Processing, 1999. ICIP 99. Proceedings. 1999 International Conference on, volume 4, pages 35–39. IEEE.



Schmid, C., Mohr, R., and Bauckhage, C. (2000).

Evaluation of interest point detectors.

International Journal of computer vision, 37(2) :151–172.



Scholkopf, B., Platt, J., Shawe-Taylor, J., Smola, A., and Williamson, R. (2001).

Estimating the support of a high-dimensional distribution.

Neural computation, 13(7) :1443–1471.



Tarassenko, L., Clifton, D., Bannister, P., King, S., and King, D. (2009).

Novelty detection.

Encyclopedia of Structural Health Monitoring.



Tarassenko, L., Hayton, P., Cerneaz, N., and Brady, M. (1995).

Novelty detection for the identification of masses in mammograms.

In Fourth International Conference on Artificial Neural Networks, pages 442–447.



Tax, D. and Duin, R. (2004).

Support vector data description.

Machine learning, 54(1) :45–66.



Thiberville, L., G.Bourg-Heckly, M. Salaün, S. D., and Moreno-Swirc, S. (2007).

Human in-vivo confocal microscopic imaging of the distal bronchioles and alveoli.

Chest Journal, 132(4) :426.



Thiberville, L. and Salaün, M. (2012).

Endoscopie en autofluorescence et nouvelles techniques endoscopiques.

Revue des Maladies Respiratoires Actualités,
4(6) :463–468.



Thiberville, L. and Salaün, M. (2013).

Diagnostic of lung cancer : Confocal bronchoscopy.

In *Interventions in Pulmonary Medicine*, pages 221–230.
Springer.



Thiberville, L., Salaün, M., and Bourg-Heckly, G. (2010).

In vivo confocal microendoscopy : From the proximal bronchus down to the pulmonary acinus.

European Respiratory Monograph, (48) :73.



Thiberville, L., Salaün, M., Lachkar, S., Dominique, S., Moreno-Swirc, S., Vever-Bizet, C., and Bourg-Heckly, G. (2009).

Human in vivo fluorescence microimaging of the alveolar ducts and sacs during bronchoscopy.

European Respiratory Journal, 33(5) :974–985.



Vapnik, V. (1998).

Statistical Learning Theory.

Wiley Interscience.



Viola, P. and Jones, M. (2001).

Rapid object detection using a boosted cascade of simple features.

In IEEE Conference on Computer Vision and Pattern Recognition, 1 :511–518.