



**BORDEAUX
SCIENCES
AGRO**

Analyse d'images agricoles: Télédétection et imagerie embarquée

Christian GERMAIN
Professeur à Bordeaux Sciences Agro
Laboratoire IMS
(CNRS / Univ. Bordeaux / Bordeaux INP)
Groupe Signal & Image

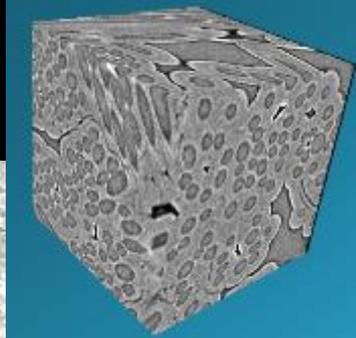
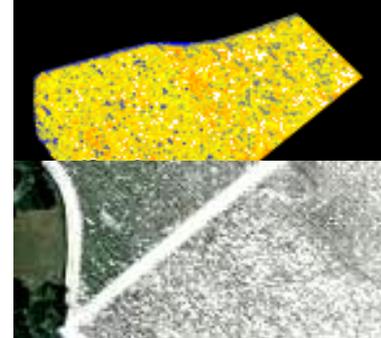
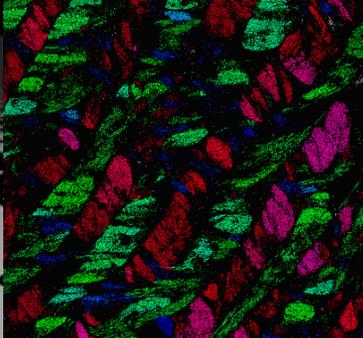
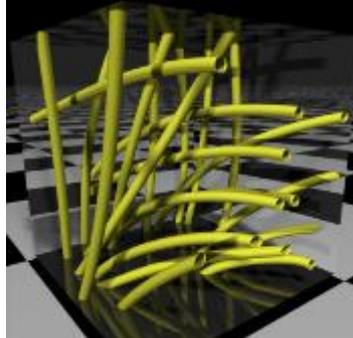


Plan

- Introduction générale
- Télédétection et agriculture
- Proxidétection et agriculture
- Perspectives

INTRODUCTION

Présentation du groupe Signal et Images du laboratoire IMS
Observer les cultures: pourquoi et comment?



Laboratoire IMS

Groupe Signal & Image



BORDEAUX
SCIENCES
AGRO





Laboratoire de l'Intégration du Matériau au Système



350 permanent staff:

- 135 researchers , Prof and assist. Prof
- 150 PhD and post-doctoral fellows
- 65 technical staff

Budget : 20M€



11 research groups, among which the **Signal & Image group**

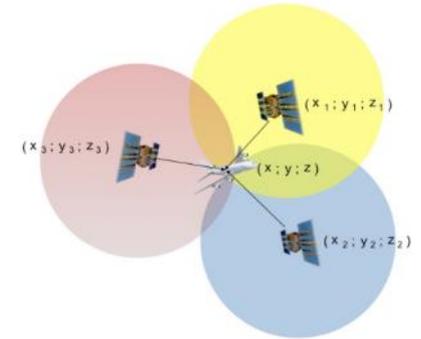
Signal & Image group: 18 permanent staff

- 14 Prof or Assist Prof, 4 researchers
- 15 PhD students and post-doctoral fellows

Signal & Image research group

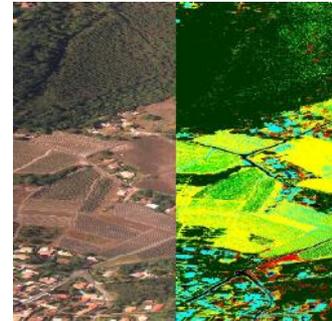
Signal & image: Two sub groups

- SPECTRAL : Statistics for digital communications, Radar, and GNSS
- MOTIVE : MOdels, Textures, Images, VolumEs



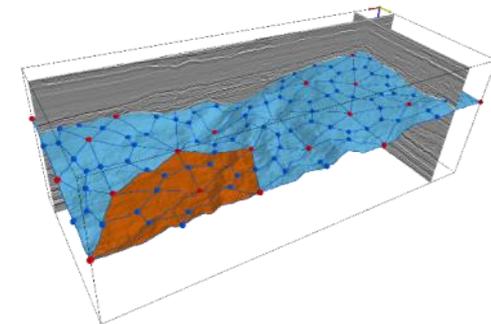
A large expertise large signal and image processing

- Modelisation, Inference, Optimisation, Sampling
- multi-dimensionnal and multiscale problems, static or dynamic
- Inverses problems, characterisation, filtering, decision, transmission



Long term industrial partnerships

- Safran, Total
- CEA-LETI, Thales, Telespazio, I'Sea, ST Micro, VitiRover...



Bordeaux Sciences Agro staff among Signal & Image

4 professors and assistant professors, 1 R&D engineer



Lionel Bombrun
Statistics,
Images analysis



Jean-Pierre Da Costa
Statistics,
Images analysis



Christian Germain
Computer science, Images
analysis



Gilbert Grenier
Precision Agriculture,
Agricultural engineering



Barna Keresztes
Embedded vision,
image analysis

*Focused on computer vision, proximal and remote sensing
for Precision Agriculture*

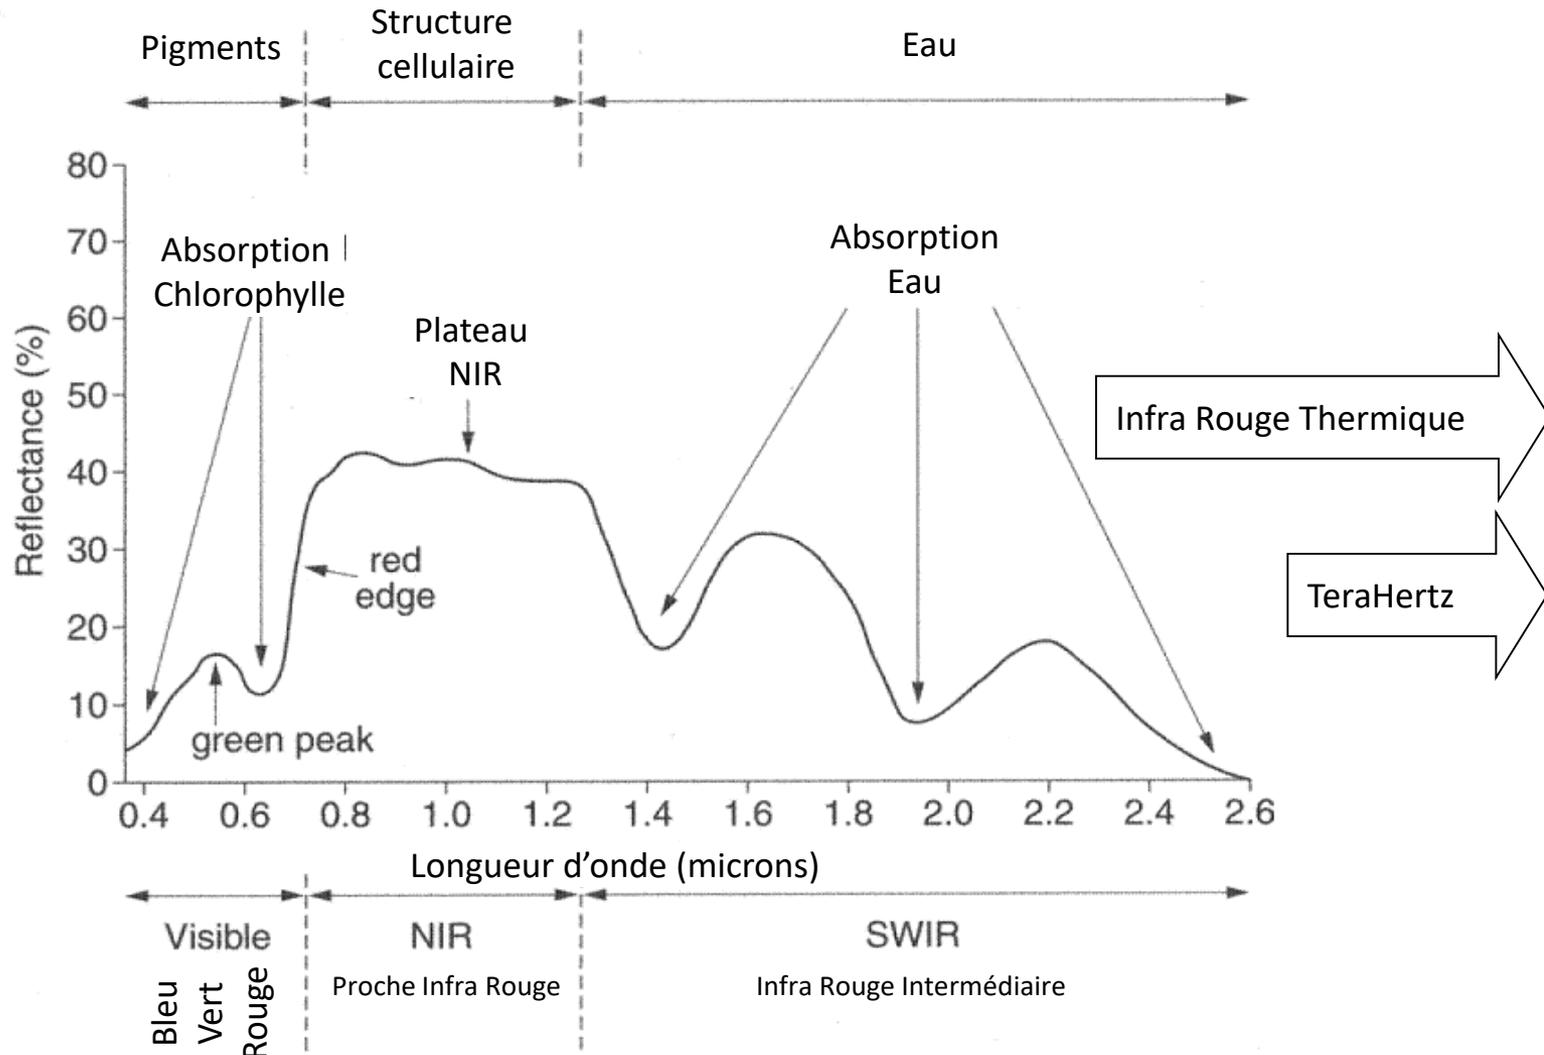
Observer les cultures: pourquoi?

- Piloter
 - Mesurer la phénologie, la maturité
 - Estimer le rendement, la production
- Moduler (Agriculture de précision)
 - Qualité des produits alimentaires
 - Apport raisonné des engrais
 - Réduction des intrants phyto (maladies)
 - Désherbage mécanisé
- Contrôler
 - Respect des surfaces déclarées
 - Occupation du sol

Observer les cultures: comment?

- Vecteur
 - Satellite
 - Aerien
 - Terrestre
 - Pas de vecteur
- Capteurs
 - Optique (Visible + NIR / Mono multi hyper spectral)
 - Thermique
 - Radar

Capteurs: *Comportement spectral des végétaux*



Capteurs *optiques*....

En pratique on utilise:

- La spectrométrie NIR (maturité);
- La fluorescence (maturité, maladie);
- L'imagerie multispectrale couleur (RGB) et infrarouge RGB+NIR.



Caméra multispectrale
<http://www.tetracam.com>

Mais aussi (de façon émergente):

- L'imagerie hyperspectrale NIR;
- L'imagerie thermique (comportement hydrique);
- La spectrométrie et l'imagerie hyperspectrale SWIR;
- Le Lidar ou l'imagerie RGB+D (=>3D) ou la photogrammétrie.



Caméra hyperspectrale



Les vecteurs associés aux capteurs

Deux grandes familles d'approches.

- Capteurs Fixes:
 - Capteurs en réseau; *1 mesure/capteur*
- Capteurs Mobiles:
 - Piéton; *1 mesure par prélèvement,*
 - Rover, engins agricoles; *1 pixel => mm*
 - Drone; *1 pixel => cm*
 - ULM, Avions, Hélicoptères; *1 pixel => dm*
 - Satellites; *1 pixel => m , dam*

En plus de la résolution spatiale, il faut considérer la fréquence de revisite et la souplesse d'utilisation



TELEDETECTION

Vecteurs, capteurs, outils méthodologiques

Applications Forêts cultivées

Applications Parcs Ostréicoles

Téledétection

- Vecteurs :
 - Principalement satellitaire
 - marginalement aérienne et drone
- Capteurs:
 - Panchromatique, Multispectral, Hyperspectral, Radar
- Thématiques
 - Forêt cultivée: parcellaire, âge
 - Parc ostréicoles: culture, friche
 - Vigne: Parcelles, Rangs
- Outils méthodologiques
 - Classification de textures
 - Des dépendances spatiales aux dépendances spectrales, polarimétriques, temporelles...

Téledétection

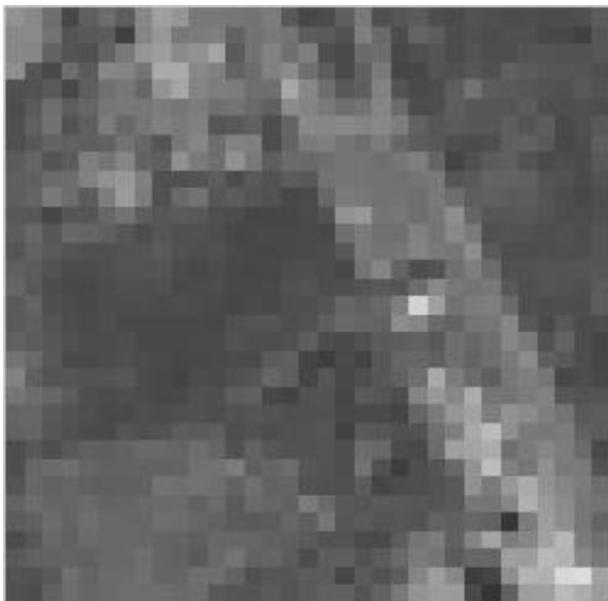
- **Analyse de texture, satellites optiques et Radar**
 - Des matrices de cooccurrences aux ondelettes
 - Application Forêts Cultivées
 - Application Parc ostréicoles
- Généralisation aux covariances
 - Variétés Riemaniennes, covariance et Deep Learning
- Autres travaux:
 - Imagerie hyperspectrale (cépage vigne)
 - Détection de rangs de vigne Drone vs aérien

Analyse de texture pour la cartographie d'occupations
du sol par télédétection très haute résolution

Application à la forêt, et aux parcs ostréicoles

Thèse d'Olivier REGNIERS 2014

Contexte – Image de télédétection optique THR (panchromatique)



15 m (Landsat)



5 m (SPOT)



0,5 m (Pléiades)

Haute Résolution



Très Haute Résolution

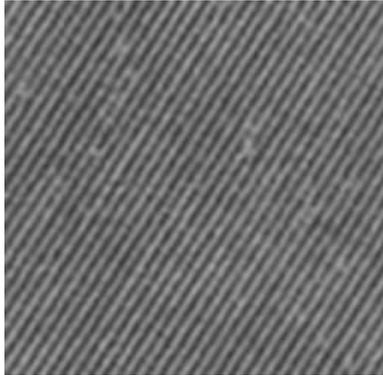
Complexité de l'information augmente
Structures géométriques + Organisation spatiale

Méthodes orientées pixel

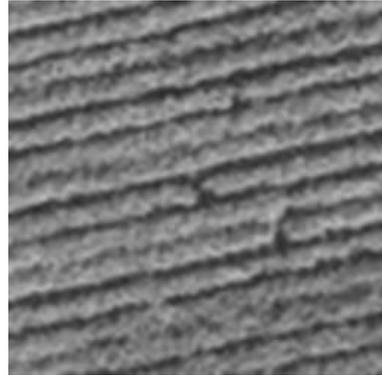
Méthodes orientées objet

→ **Analyse texturale**

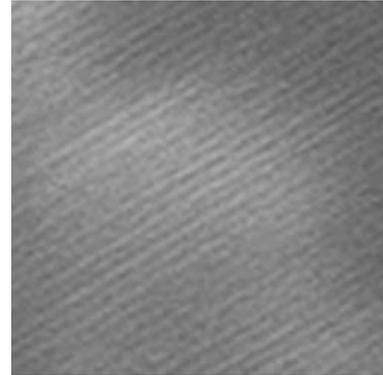
Exemples d'occupations du sol texturées



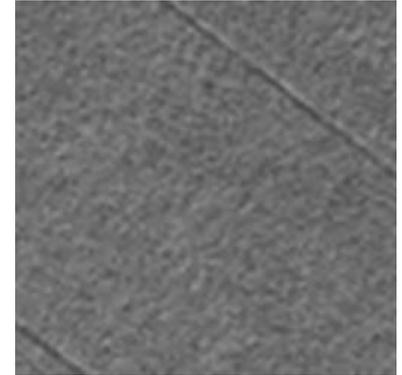
vigne



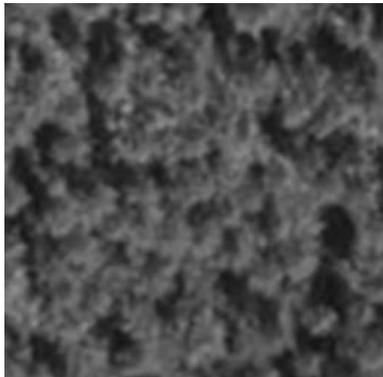
verger



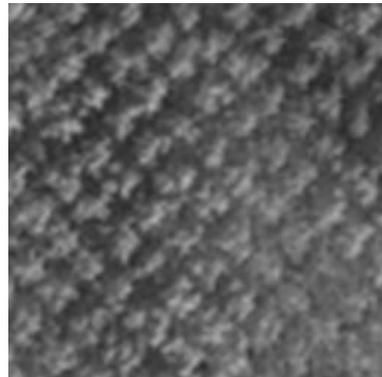
parcelle agricole
labourée



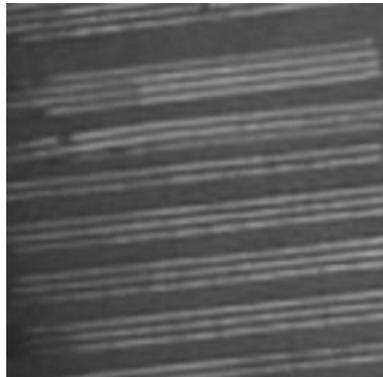
culture céréalière



forêt cultivée



peupleraie



tables ostréicoles



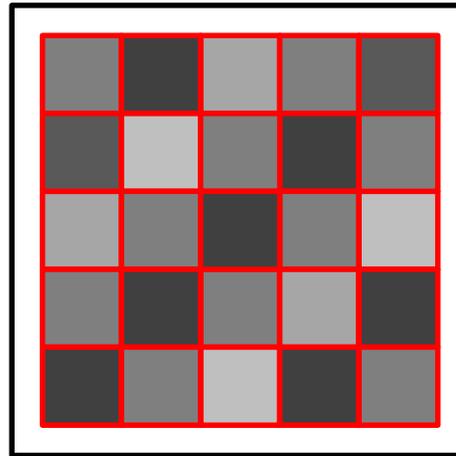
zone urbaine

Statistiques sur l'analyse spatiale des niveaux de gris

Matrice de co-occurrence
Variogrammes

Transformée de Fourier
Filtres de Gabor
Transformée en ondelettes

Méthodes par filtrage fréquentiel



Méthodes structurelles

LBP – Local Binary Patterns

Modèles Markoviens
Modèles de Gibbs

Méthodes par modélisation

Modélisation probabiliste des sous-bandes d'ondelettes

Modélisation **univariée** de la distribution marginale des coefficients
→ GGD [Do & Vetterli, 2002]

Modélisation **multivariée** de la distribution jointe des coefficients
→ Modèles SIRV [Bombrun *et al.*, 2011]
→ Copules [Stitou *et al.*, 2009]

Evaluation du potentiel des modèles multivariés pour la classification d'images de télédétection optiques THR

Forêt

Vigne

Parcs ostréicoles

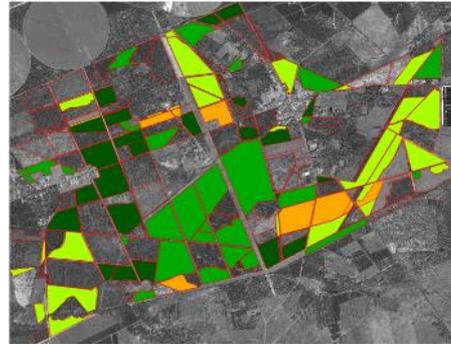
1 – Méthodes d'analyse des textures

- Matrices de co-occurrence des niveaux de gris
- Modélisation multivariée des sous-bandes d'ondelettes

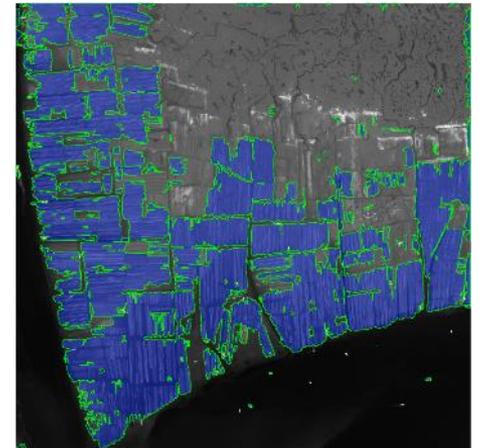
2 – Méthodes d'évaluation des modèles

- Indexation d'images
- Classification supervisée

A – Application FORET

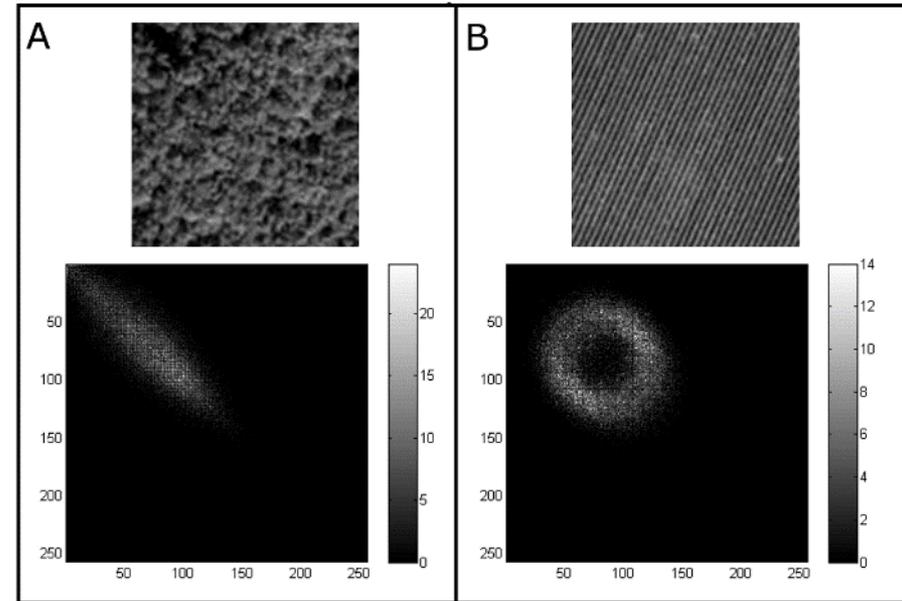
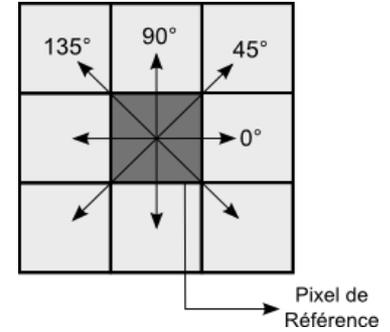
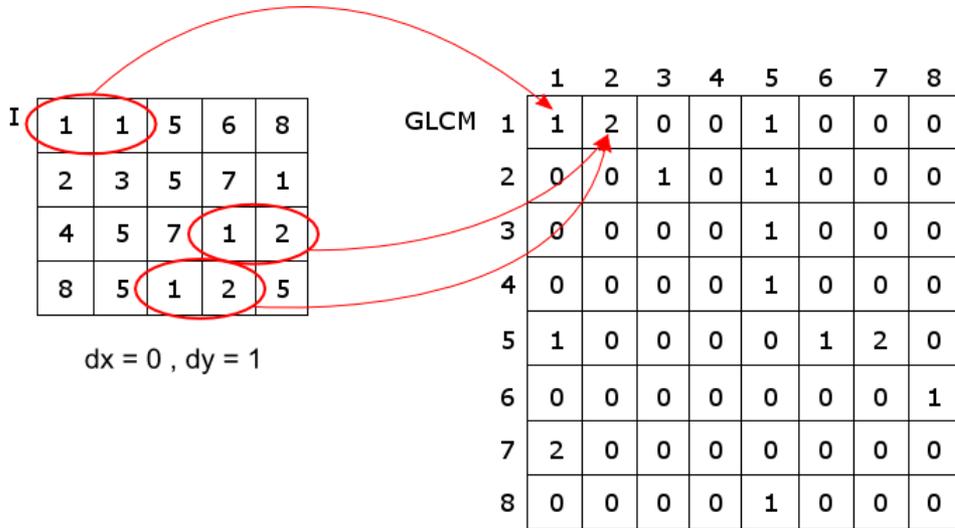


B – Application PARCS à HUITRES



Méthode de référence : Matrice de co-occurrence (GLCM)

GLCM = Nombre d'occurrences de toutes les paires de valeurs de niveaux de gris situées à une distance d dans l'image dans une direction dx, dy



Descripteurs d'Haralick

$$\text{Corrélation } n = \sum_{i,j=0}^{N-1} P_{i,j} \left[\frac{(i - \mu_i)(j - \mu_j)}{\sqrt{\sigma_i^2 \sigma_j^2}} \right] \quad \text{Energie} = \sum_{i,j=0}^{N-1} P_{i,j}^2$$

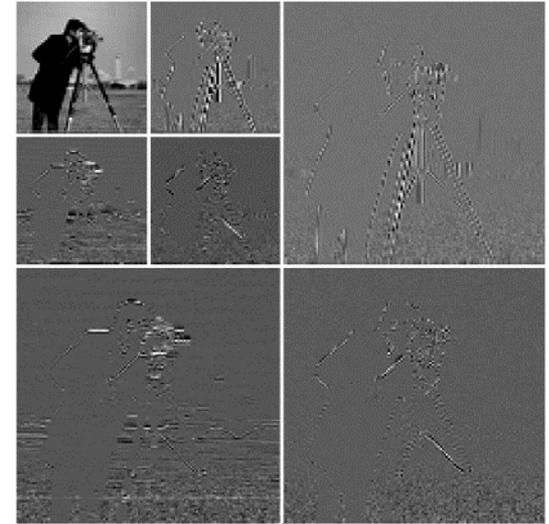
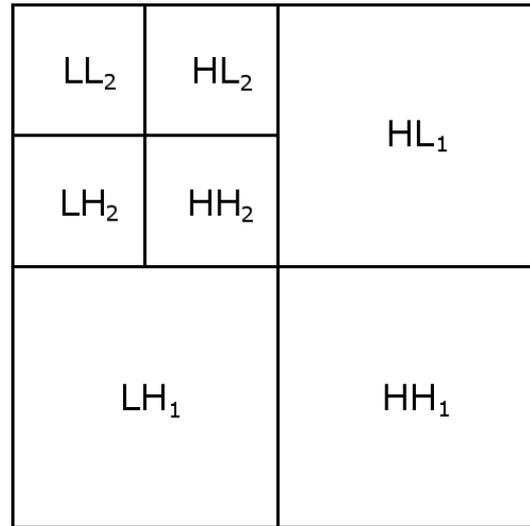
$$\text{Contraste} = \sum_{i,j=0}^{N-1} P_{i,j} (i - j)^2 \quad \text{Homogénéité } é = \sum_{i,j=0}^{N-1} \frac{P_{i,j}}{1 + (i - j)^2}$$

Vecteur de descripteurs texturaux

→ **Signature texturale**

Transformée en ondelettes discrète (DWT)

- Combinaison de filtres passe-haut (H) et passe-bas (L)
- Sous-bandes d'ondelettes orthogonales et indépendantes
- Représentation multi-échelles et multi-orientations du contenu fréquentiel
- Limitée en termes de sélectivité directionnelle (3 orientations) et d'invariance à la translation



Ondelette dyadique → sous-échantillonnage d'un facteur 2 à chaque échelle

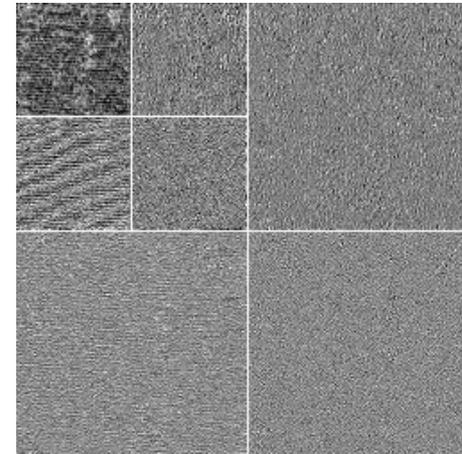
Ondelette-mère = Daubechies db4

Autres transformées en ondelettes : ondelettes stationnaires, pyramides orientées, etc.

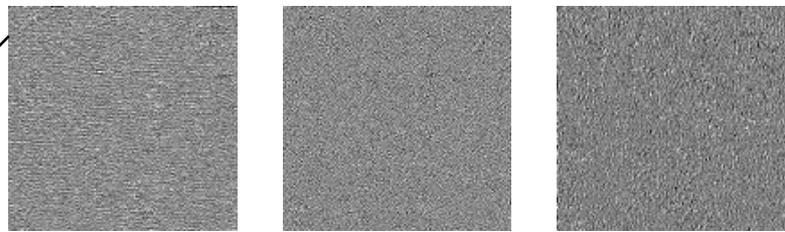
Modélisation probabiliste des sous-bandes d'ondelettes



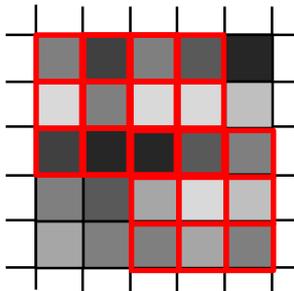
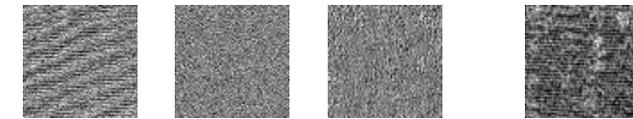
DWT – db4
Nombre échelles = 2



1^{ère} échelle



2^{ème} échelle



$k_1 =$ [row of 8 sub-bands]
 $k_2 =$ [row of 8 sub-bands]
 \vdots
 $k_N =$ [row of 8 sub-bands]

N vecteurs k d'observation de la dépendance spatiale
=
 N réalisations d'un processus aléatoire multivarié

Modélisation probabiliste des sous-bandes d'ondelettes

Modèle Gaussien multivarié

$$\mathbf{k} \sim \mathcal{N}(\mathbf{0}, \mathbf{M}) \quad [\hat{\mathbf{M}}]_{SCM} = \frac{1}{N} \sum_{i=1}^N \mathbf{k}_i \mathbf{k}_i' \quad \rightarrow \text{SCM}$$

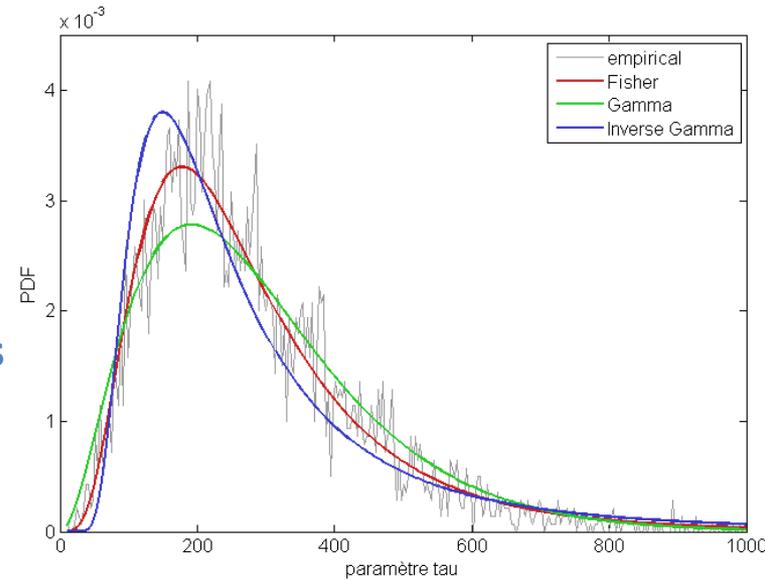
Modèles SIRV (Spherically Invariant Random Vectors)

$$\mathbf{k} = \sqrt{\tau} \mathbf{z} \quad \mathbf{z} \sim \mathcal{N}(\mathbf{0}, \mathbf{M})$$

Si loi Gamma Inverse sur τ , vecteur SIRV \mathbf{k} suit loi GO \rightarrow **SIRVg0**

Si Dirac sur τ , vecteur SIRV \mathbf{k} suit loi Gaussienne \rightarrow **SIRVgauss**

$$[\hat{\mathbf{M}}]_{FP} = \frac{p}{N} \sum_{i=1}^N \frac{\mathbf{k}_i \mathbf{k}_i'}{\mathbf{k}_i' [\hat{\mathbf{M}}]_{FP}^{-1} \mathbf{k}_i} \quad \hat{\tau}_i = \frac{\mathbf{k}_i' [\mathbf{M}]^{-1} \mathbf{k}_i}{p}$$



Modèles sur copules

$$F(\mathbf{k}_i) = F(k_{i,1}, \dots, k_{i,p}) = C(F_{i,1}(k_{i,1}), \dots, F_{i,p}(k_{i,p}))$$

$$[\hat{\mathbf{M}}] = \frac{1}{N} \sum_{i=1}^N \mathbf{k}_i^G \mathbf{k}_i^{G'} \quad \text{Gamma multivariée sur copule Gaussienne} \quad \rightarrow \text{GCG}$$

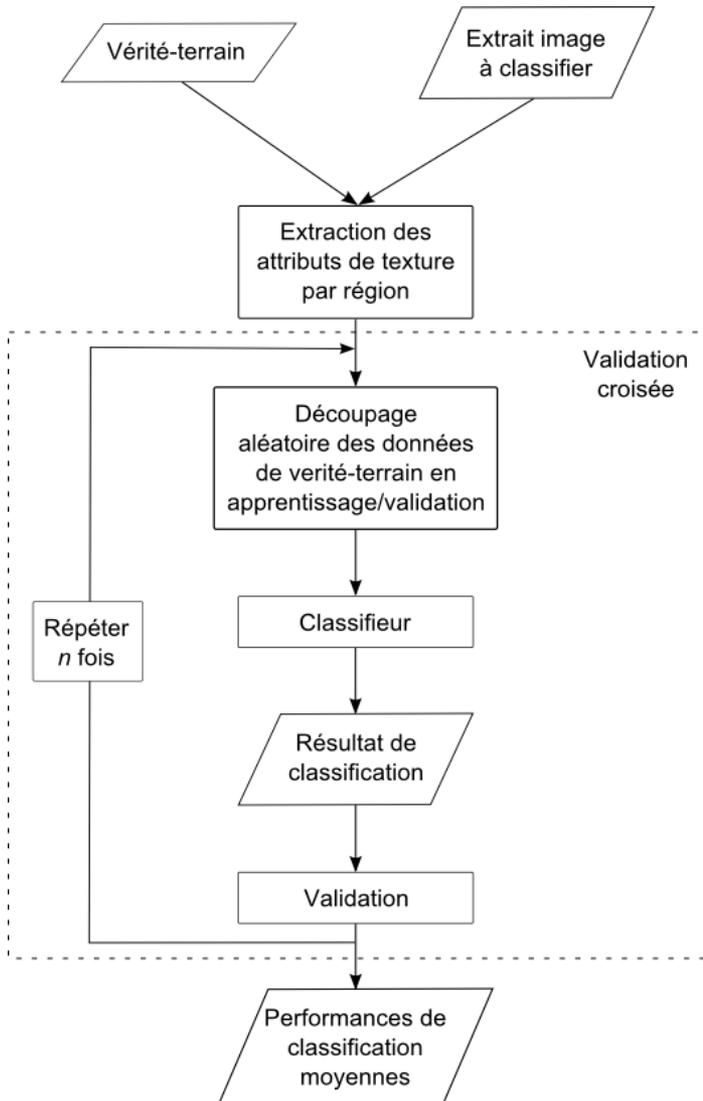
Estimateur de la matrice de covariance

(+ Estimateur autres paramètres)

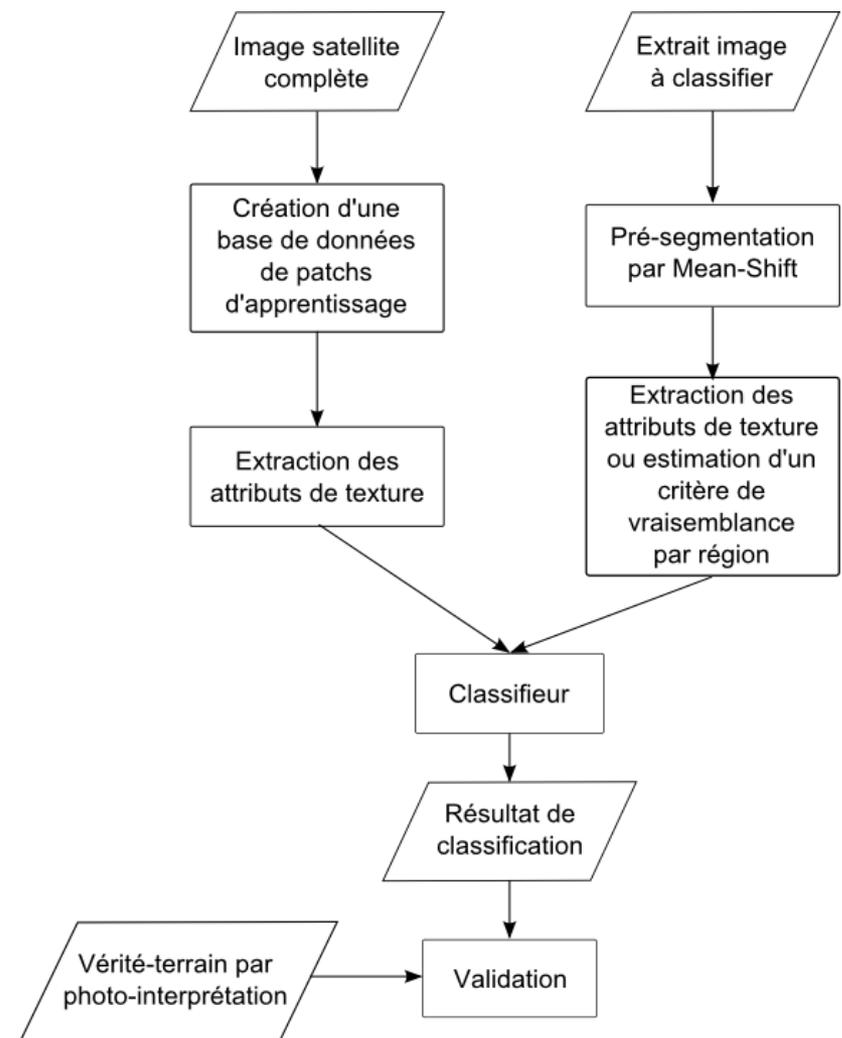
\rightarrow SIGNATURE TEXTURALE

Stratégies d'évaluation des performances de classification

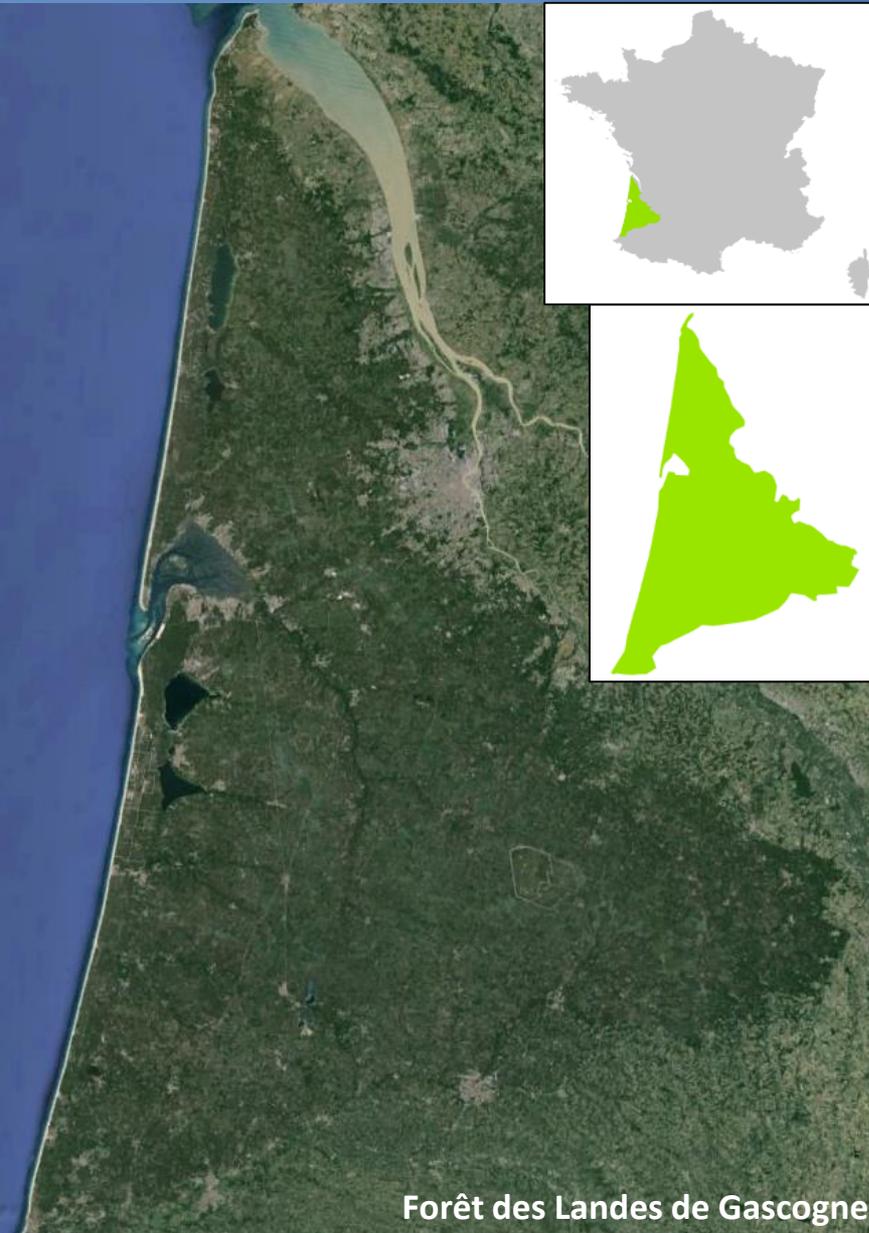
Avec vérité-terrain



Sans vérité-terrain



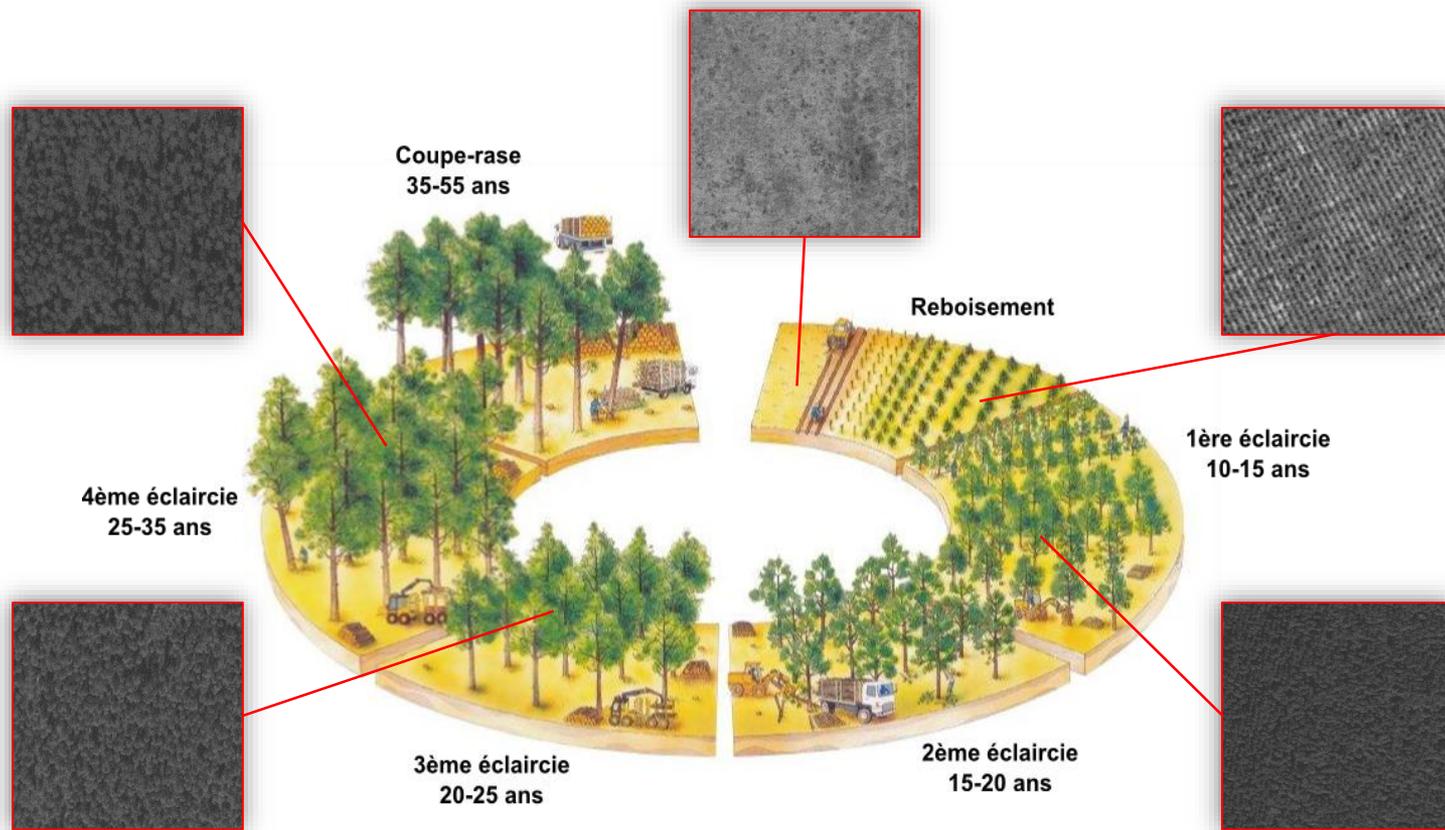
k plus proches voisins (**k-NN**), maximum de vraisemblance (**ML**), machine à vecteurs de support (**SVM**)



Forêt des Landes de Gascogne

- 10⁶ hectares
- forêt mono-spécifique équiennne
- 90% de pins maritimes cultivés
- organisation parcellaire morcelée
- séquelles de la tempête Klaus (2009) et de la tempête Martin (1999)



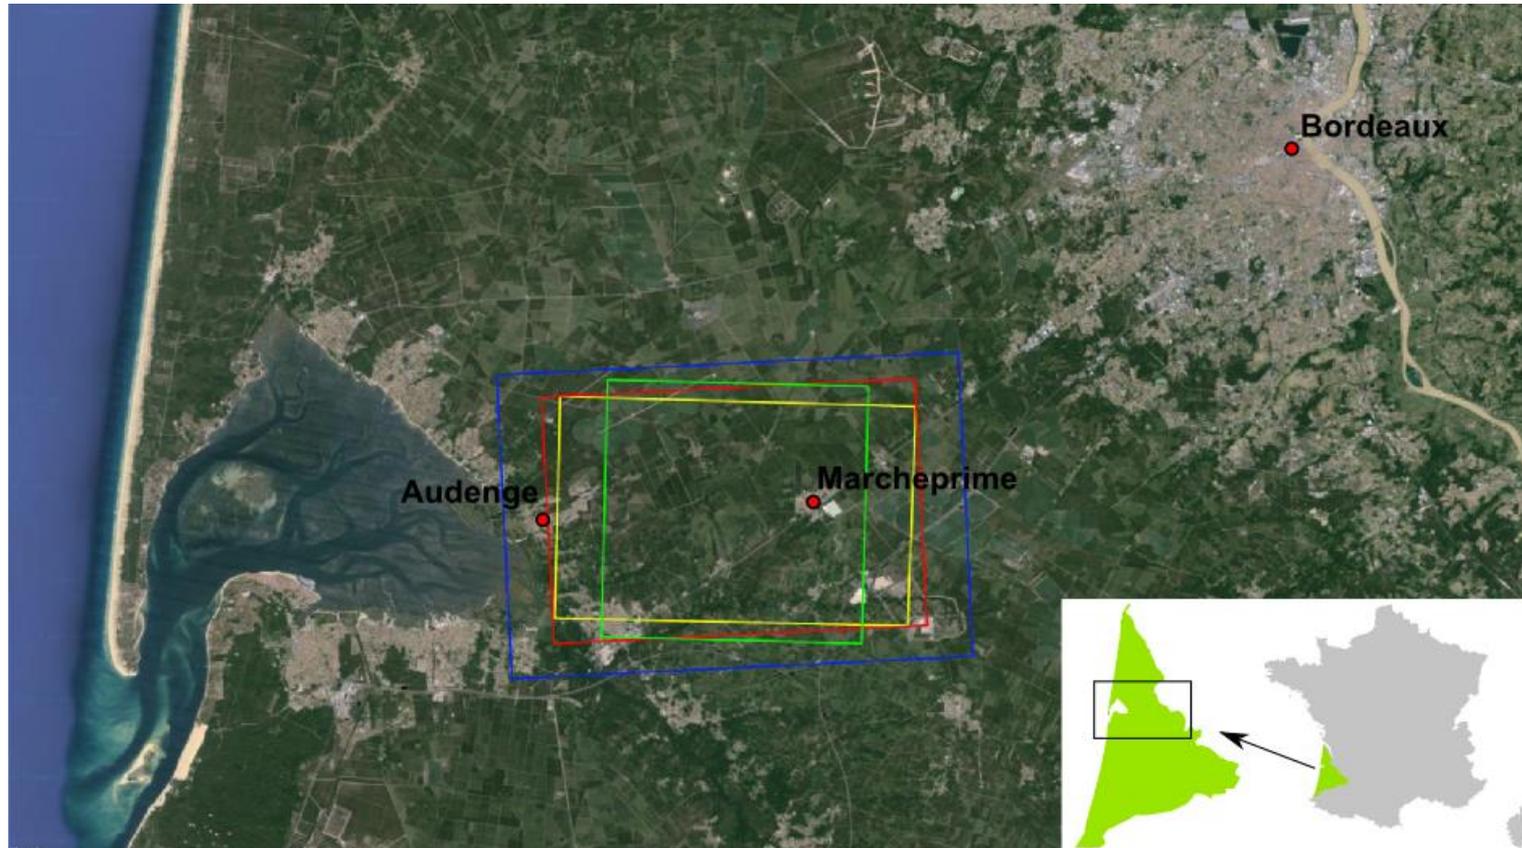


Corrélation entre variables de structures forestières et distribution spatiales des arbres

→ GLCM

- Epicéas [Kayitakire *et al.*, 2006]
- Peupliers [Lévesque & King, 2003]
- Pins maritimes [Béguet *et al.*, 2014]

Evaluation des modèles multivariés sur sous-bandes d'ondelettes pour la classification d'âges de peuplements forestiers (forêt mono-spécifique de pins maritimes)



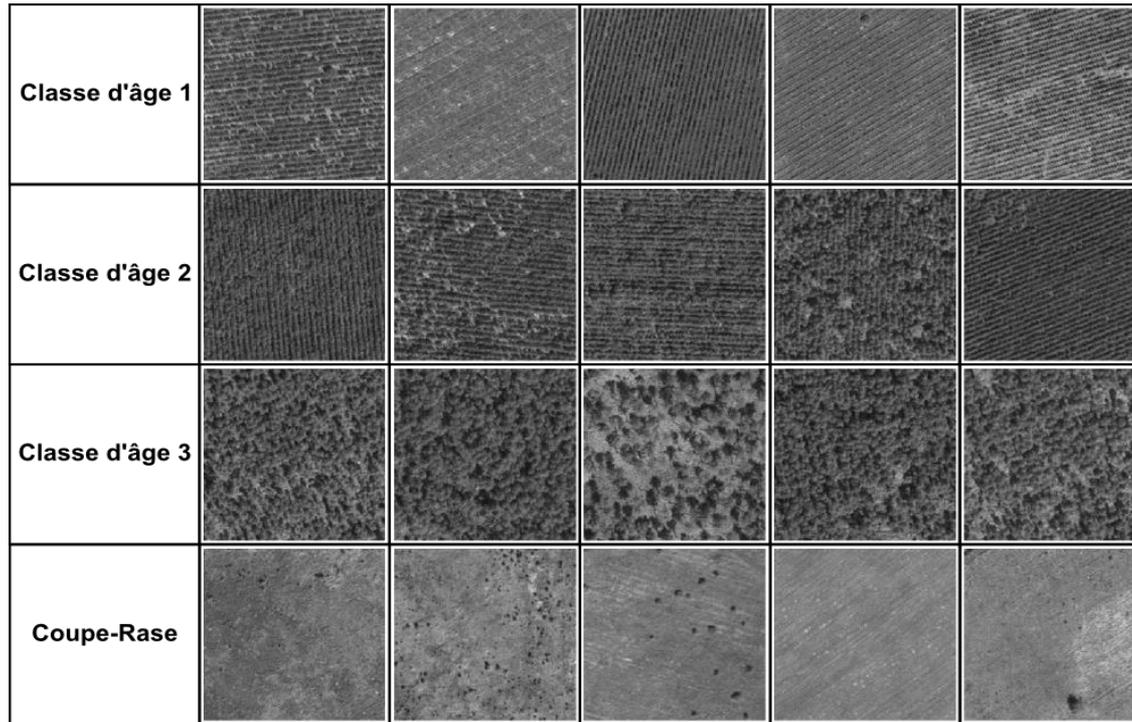
3 images Pléiades (RTU programme ORFEO – CNES)

1 image GeoEYE-1 (Telespazio – EarthLab)

→ Résolution spatiale PAN = **0,5 m**

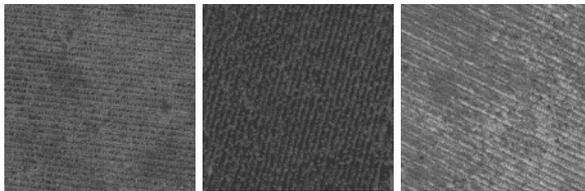
	Pléiades 24/06/12	Pléiades 08/08/12	Pléiades 20/02/13	GeoEYE-1 03/04/13
Angle d'incidence	27,5°	15°	22°	20,5°
GSD PAN	0,83 m	0,74 m	0,78 m	0,45 m
Élévation solaire	66°	59,5°	32,5°	49°

Base de données réalisée par photo-interprétation (dimension patches = 256 x 256 pixels) **BD**

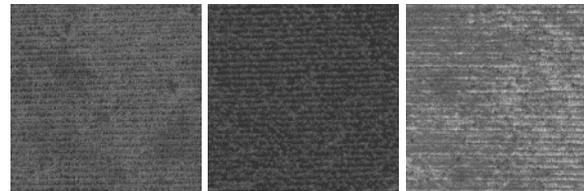


ATTENTION : âge peuplements = variable continue

Sensibilité à l'anisotropie



Seconde base de données **BDrot**



Estimation de l'orientation par un tenseur de structure

Evaluation des performances des modèles en indexation

GLCM

Descripteurs moyennés sur 4 orientations (0° , 45° , 90° , 135°)

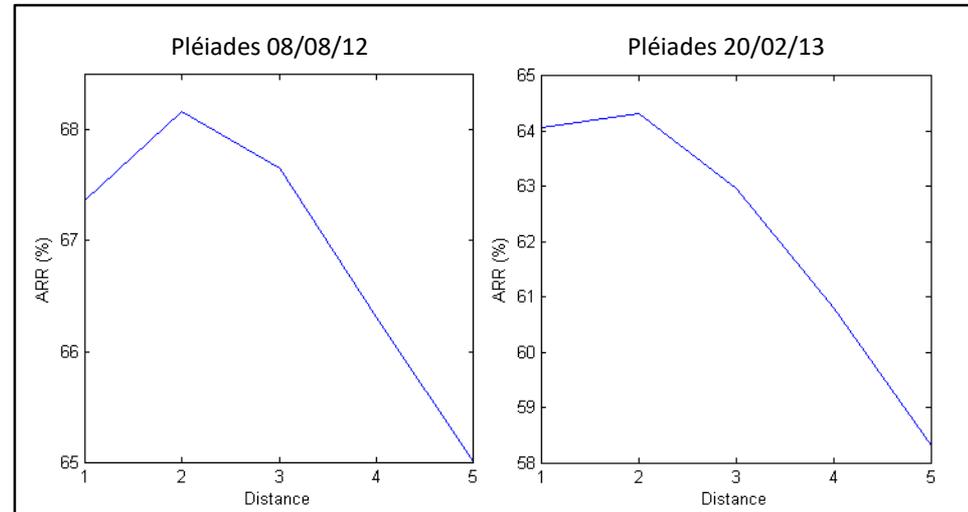
→ Invariance à la rotation

Sélection des descripteurs par ACP

→ homogénéité, entropie, corrélation, moyenne

Sélection de la distance entre paires de pixels

→ Distance de 2 pixels plus performante



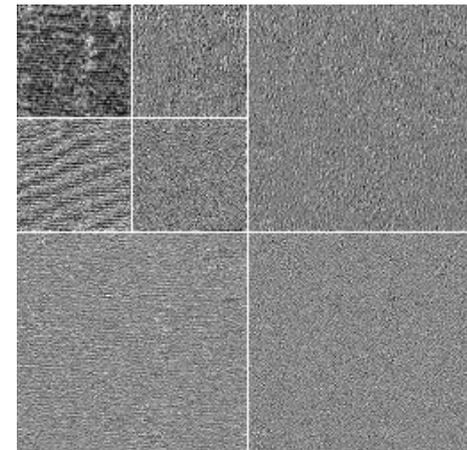
Modèles multivariés

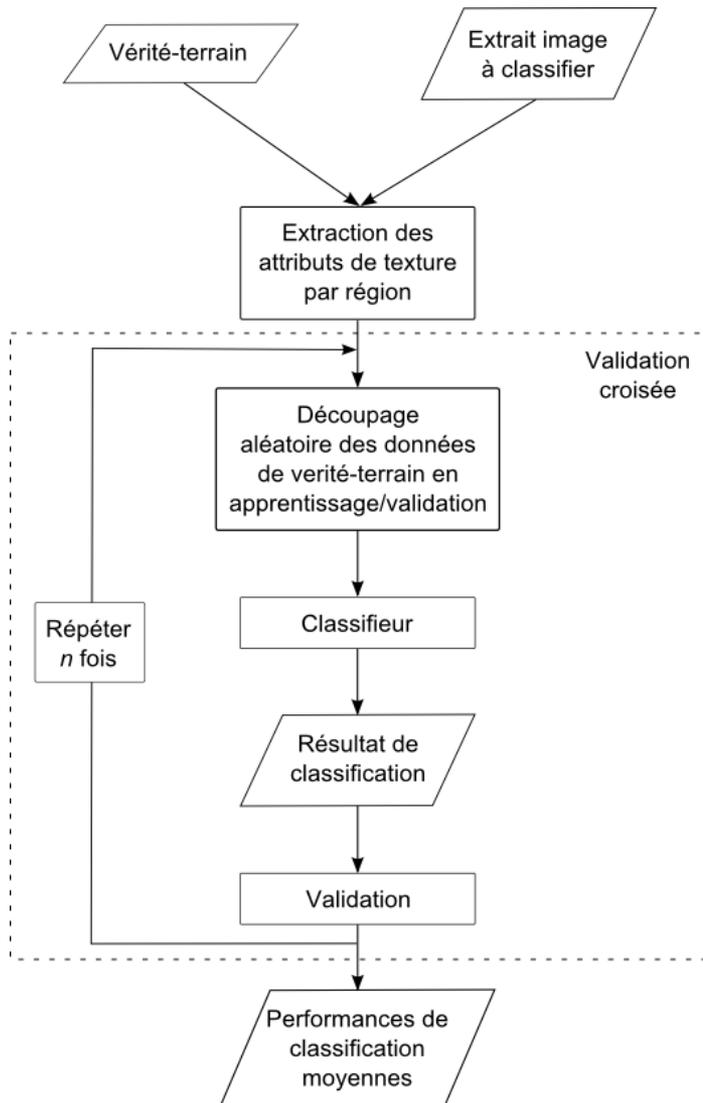
Transformée en ondelettes discrète (DWT)

2 échelles x 3 orientations = 6 sous-bandes

Dimension sous-bandes échelle 1 = 128×128 , échelle 2 = 64×64

Voisinage de dépendance spatiale = 3×3



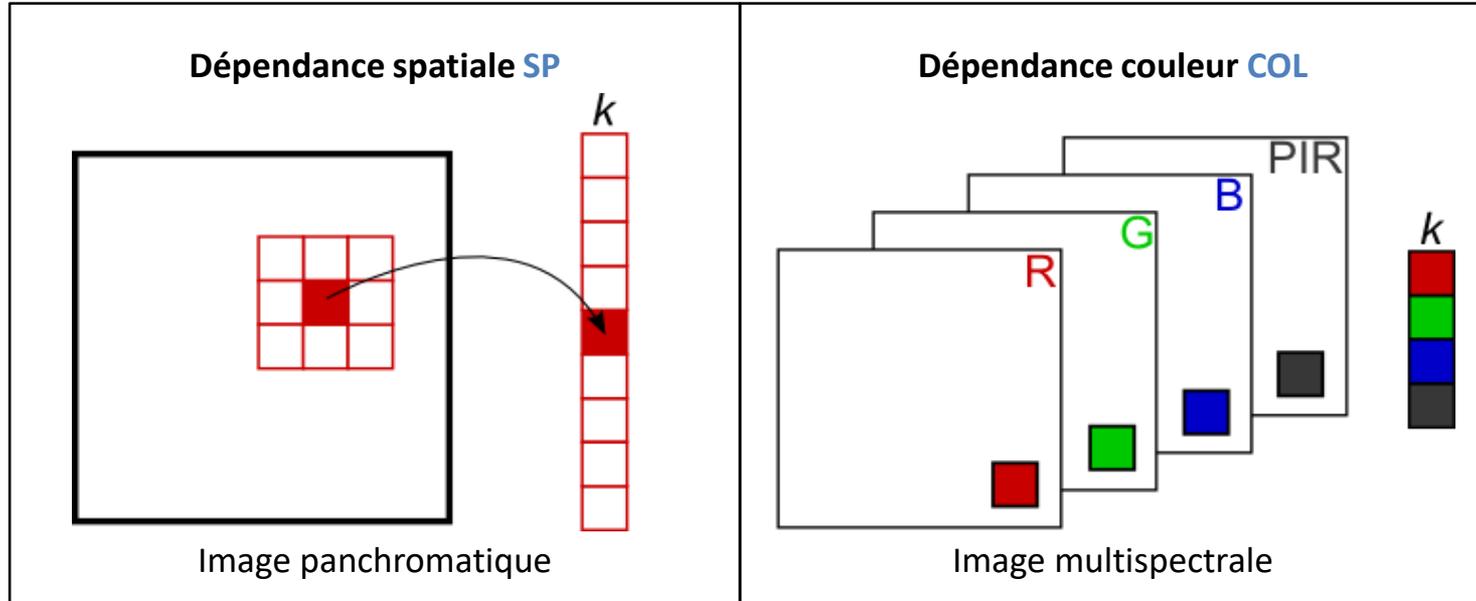


Contours de 179 peuplements (coupe-rases incluses)
→ 0 à 50 ans par tranche d'âge de 5 ans

Classe d'âge 1 : peuplements de 0 à 9 ans

Classe d'âge 2 : peuplements de 10 à 19 ans

Classe d'âge 3 : peuplements de plus de 19 ans

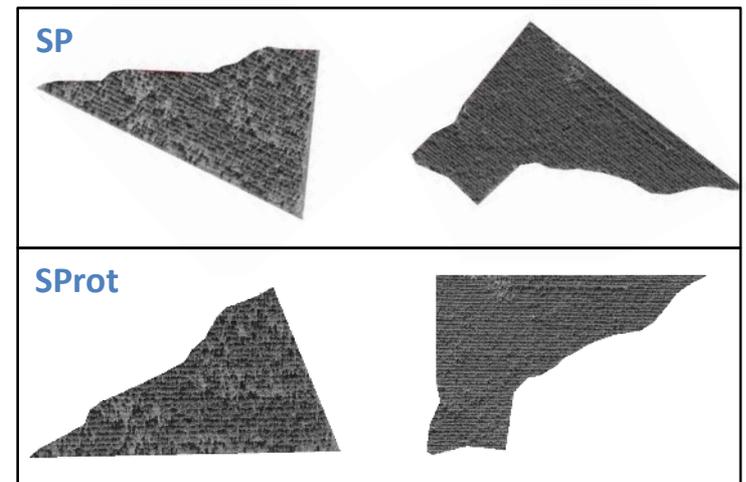


SP+COL : Dépendance spatiale SP + Dépendance couleur COL

SProt : Dépendance spatiale après rotation

SProt+COL : Dépendance spatiale après rotation + Dépendance couleur

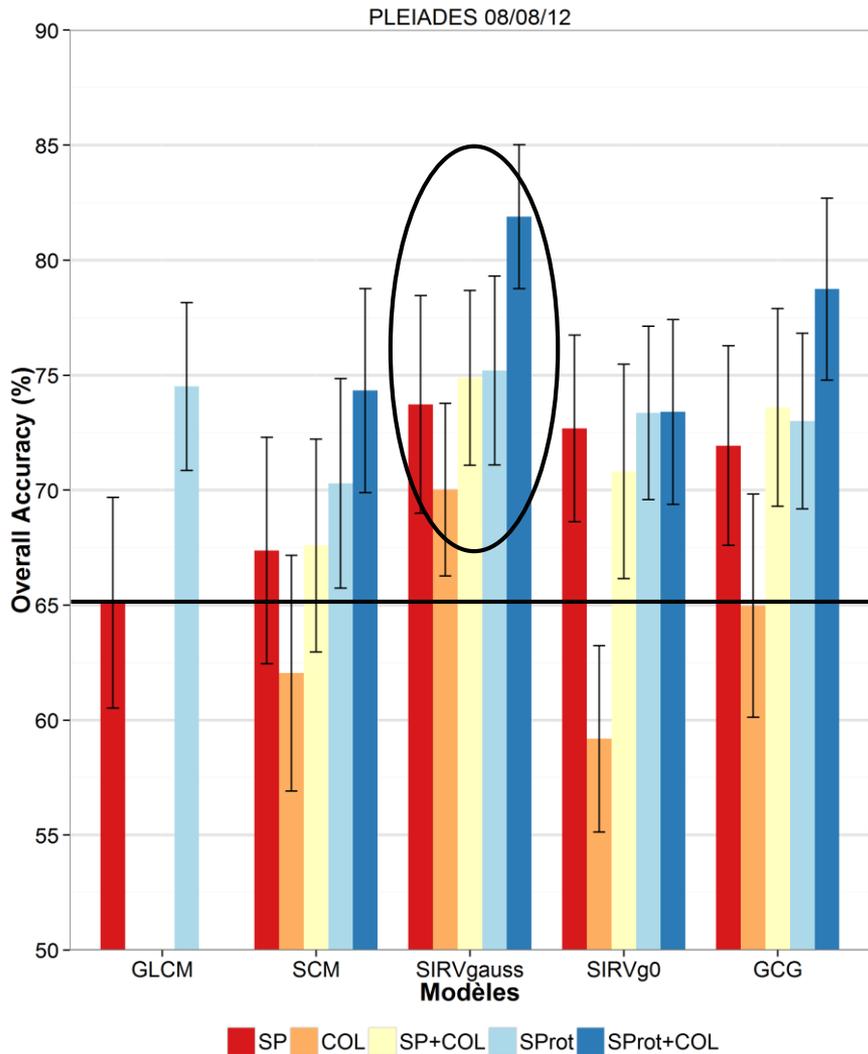
Sensibilité à l'anisotropie



Comparaison de deux classifieurs :

k-NN vs SVM

Thématique Forêt – Résultats de classification k -NN ($k = 5$)



Meilleures performances avec modèle SIRVgauss

Meilleures performances des modèles multivariés (SP)

→ Seuil de distance faible ($k = 5$)

→ Textures des peuplements hétérogènes

Producer's Accuracy par classe – modèle SIRVgauss

	Classe d'âge 1	Classe d'âge 2	Classe d'âge 3	Coupe-Rase	OA
SP	73.24	63.86	94.55	56.62	73.47
COL	66.06	73.69	81.3	32.5	68.89
SP+COL	72.47	79.66	86	47.87	75.57
SProt	83.09	69	82.1	47.37	75.24
SProt+COL	86.91	79.62	85.35	50.75	81.07

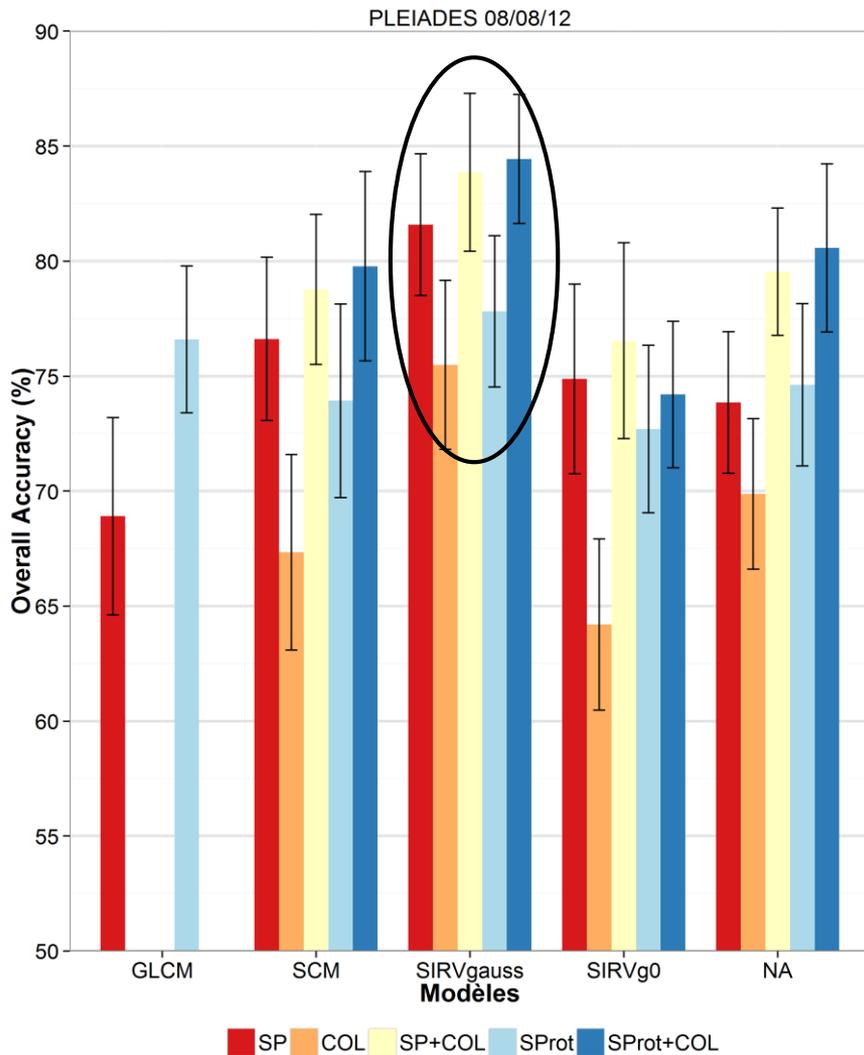
OA = Overall Accuracy

Effet synergétique de la dépendance couleur et de la rotation (SProt+COL)

→ Caractéristiques propres à chacune des classes

Meilleure capacité des modèles multivariés (SIRVgauss) à capturer des motifs texturaux complexes

Thématique Forêt – Résultats de classification SVM



$$\text{Noyau Gaussien } K = \exp\left(\frac{-(\text{distance})^2}{\sigma^2}\right)$$

Modèle SIRVgauss toujours plus performant

Meilleure discrimination des classes anisotropes

Meilleure valorisation des paramètres de la dépendance couleur

Producer's Accuracy par classe – modèle SIRVgauss

	Classe d'âge 1	Classe d'âge 2	Classe d'âge 3	Coupe-Rase	OA
SP	91.68	78.76	85	40	81.55
COL	94.53	75	71.1	7.37	75.5
SP+COL	93.47	84.65	84.25	39.37	83.89
SProt	91.91	79.17	67.15	34.62	77.37
SProt+COL	94.18	84.1	84.4	39.62	84.02

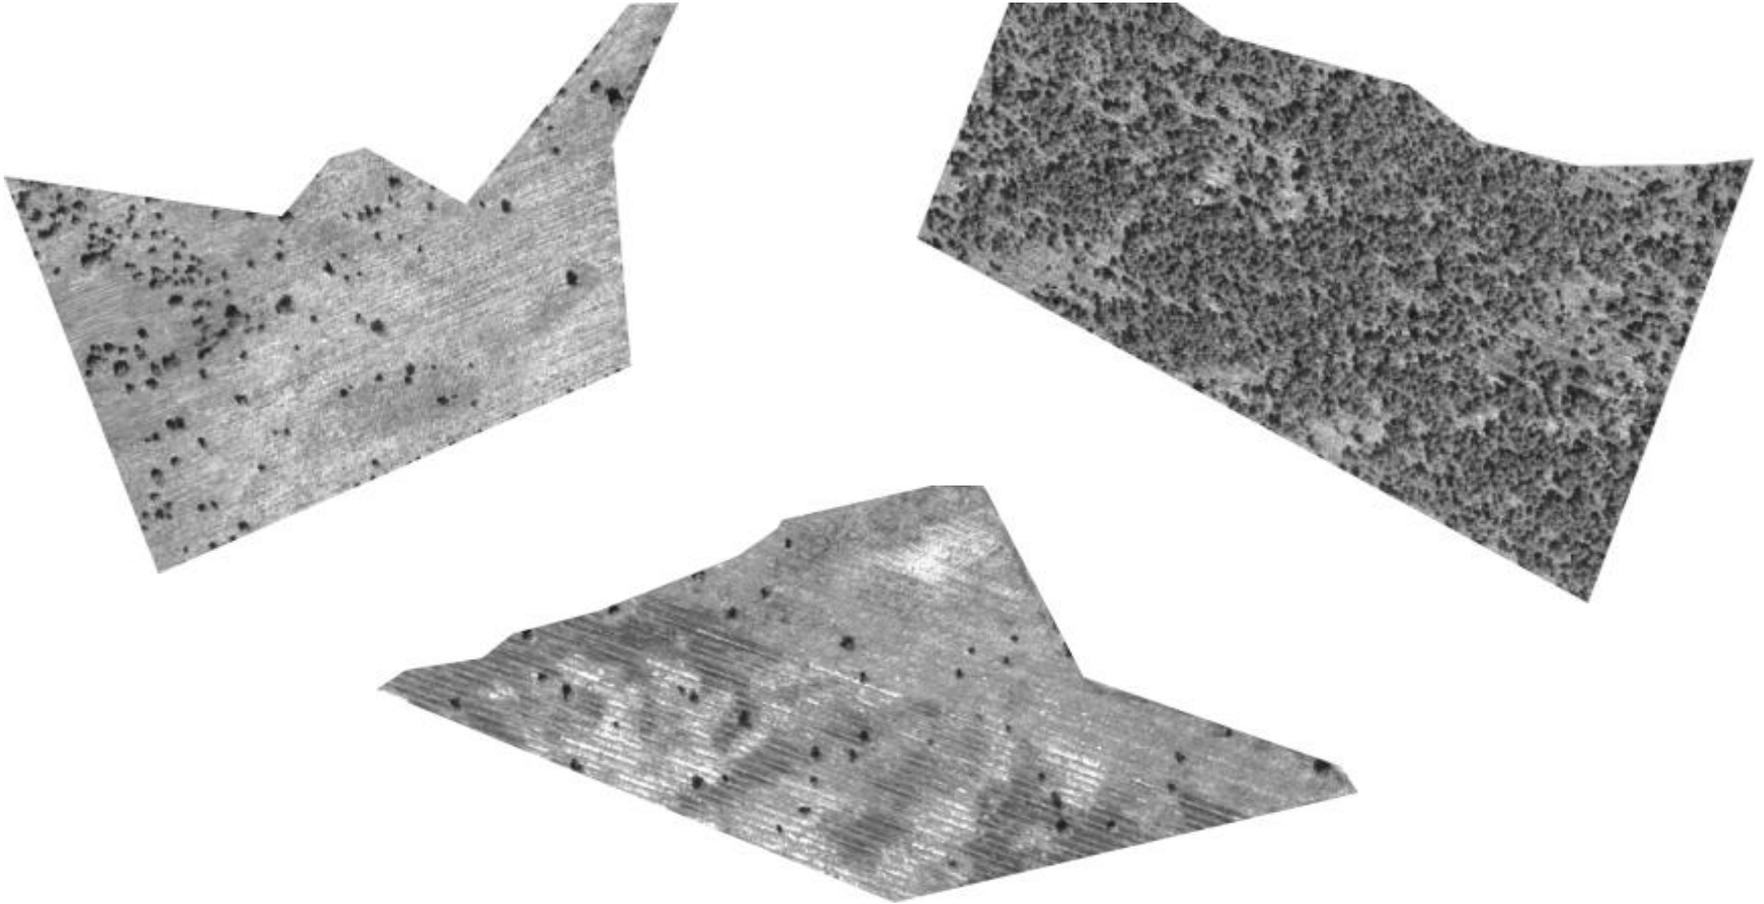
OA = Overall Accuracy

Confusion liée à l'anisotropie réduite + valorisation de la dépendance couleur par l'utilisation des SVMs

Thématique Forêt – Outliers et erreurs de classification

Performances de classification plafonnée à $\pm 85\%$

→ Présence significative de peuplements d'aspect aberrant



Limites de l'*a priori* principal → relation entre âge des peuplements et distribution spatiale des arbres

CONCLUSIONS

- Modèles multivariés (**SIRVgauss**) plus performants que GLCM → textures hétérogènes
- **Caractéristiques propres** à chacune des classes → orientation, couleur, texture
- Classifieur **SVM** plus efficace que *k*-NN
- **Hypothèse *a priori*** pas aussi simple

PERSPECTIVES

- **Modélisation par classe** plutôt que modélisation globale
 - Tests de *Goodness-of-Fit*
 - Nombre d'échelles, types de modèle différents
- **Autres variables** de structure forestière



Bassin d’Arcachon

- Ostréiculture = activité économique majeure
- 850 hectares cultivés et 10.000 tonnes d’huîtres creuses par an
- Plus grand centre d’écloserie ostréicole européen
- Deux modes d’élevage : cultures à plat + cultures sur table

Culture à plat



Culture sur tables



Friches ostréicoles



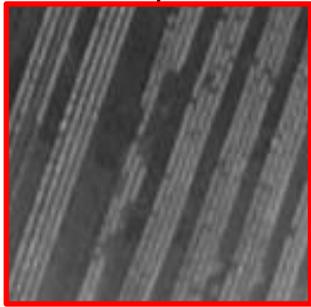
Crises successives

- Pression sur l’occupation de l’espace littoral
- Efflorescence d’espèces planctoniques toxiques
- Mortalité massive des jeunes huîtres causée par un virus

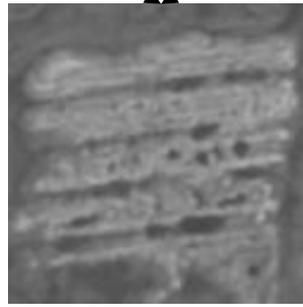
→ Tous les sites de production en France et à l’étranger

**Désaffectation
de sites de
production**

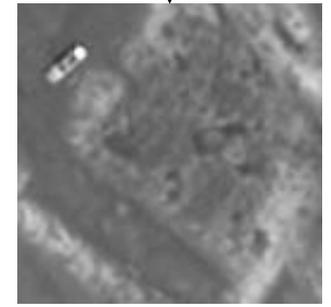
Thématique Parcs à Huîtres – Contexte



Cultures sur tables



Fiches ostréicoles structurées



Fiches ostréicoles non-structurées

Evaluation des modèles multivariés sur sous-bandes d'ondelettes pour la détection des cultures ostréicoles sur tables

Pléiades – 25/04/13



RTU Pléiades
Programme ORFEO
CNES

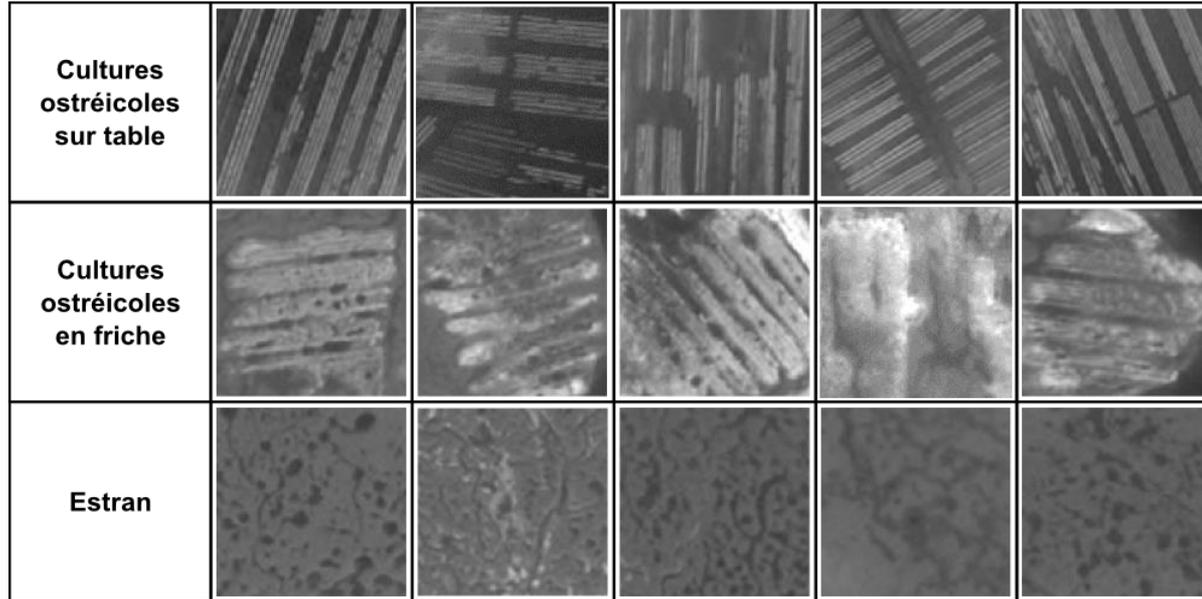
Acquisition à marée
basse



Localisation des cultures
sur tables –
« vérité terrain »

Thématique Parcs à Huîtres – Base de données de patches de texture

Base de données réalisée par photo-interprétation (dimension patches = 128 x 128 pixels) **BD**



GLCM

Descripteurs moyennés

homogénéité, entropie, corrélation,
moyenne

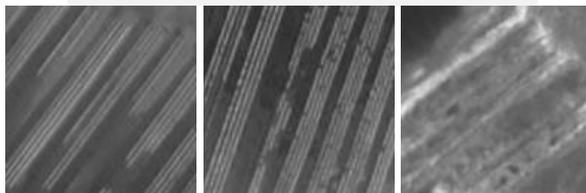
Distance = **1 pixel**

Modèles multivariés

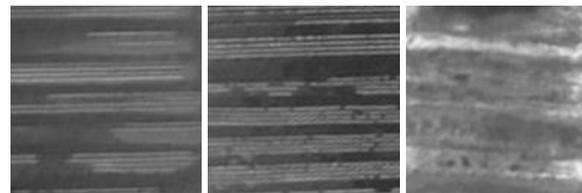
2 échelles x 3 orientations =
6 sous-bandes

Voisinage = 3 x 3

Sensibilité à l'anisotropie



Seconde base de données **BDrot**

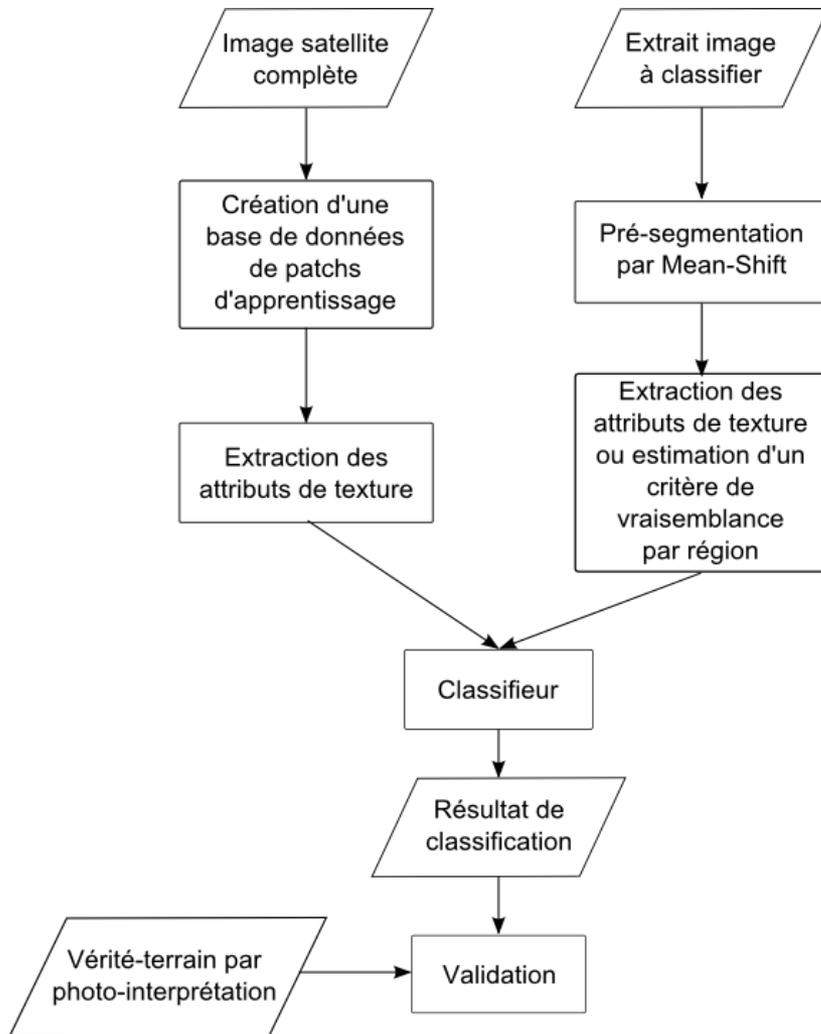


Estimation de l'orientation par un tenseur de structure

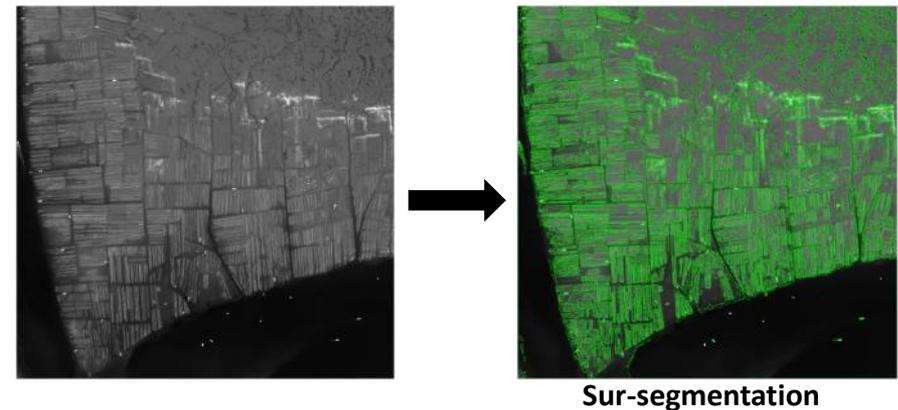
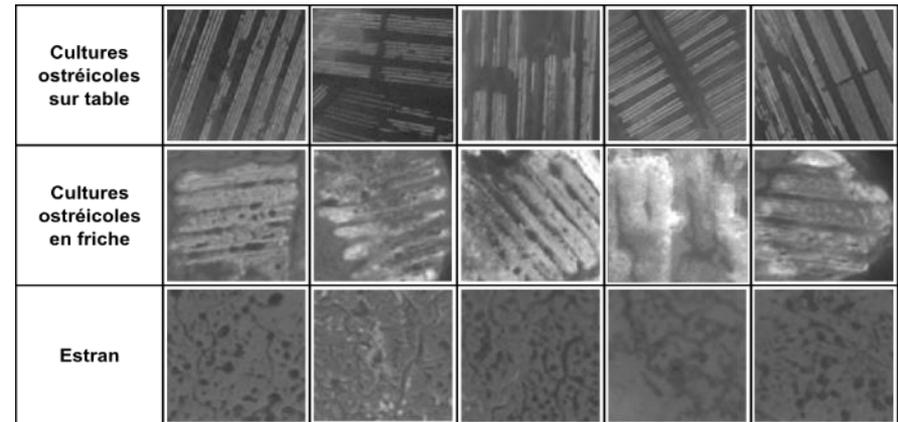
Evaluation des performances des modèles en indexation
+
Base de données d'apprentissage pour la classification

Thématique Parcs à Huîtres – Stratégie de Classification

Classification supervisée



Base de données d'apprentissage



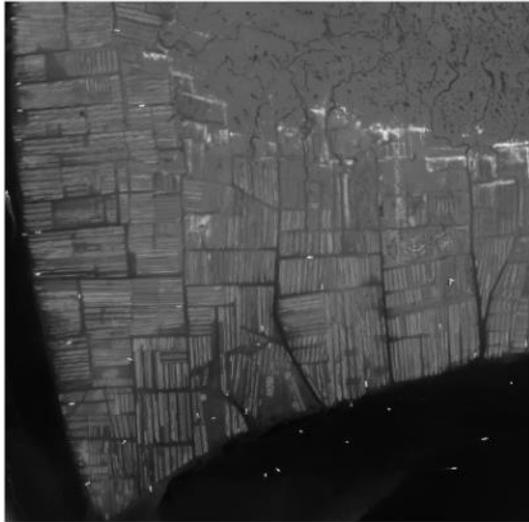
Classifieurs

k-NN – GLCM

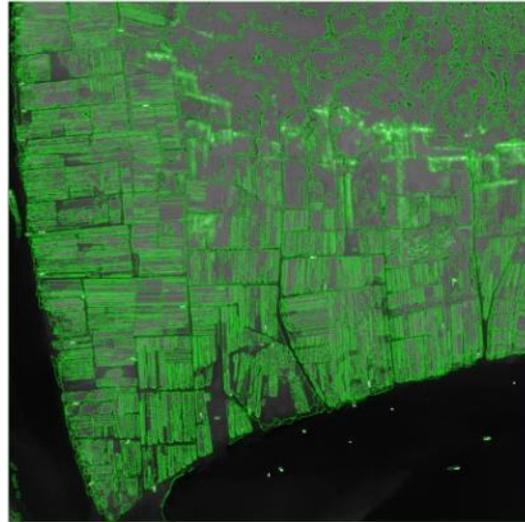
ML – Modèles multivariés

Thématique Parcs à Huîtres – Résultats de classification

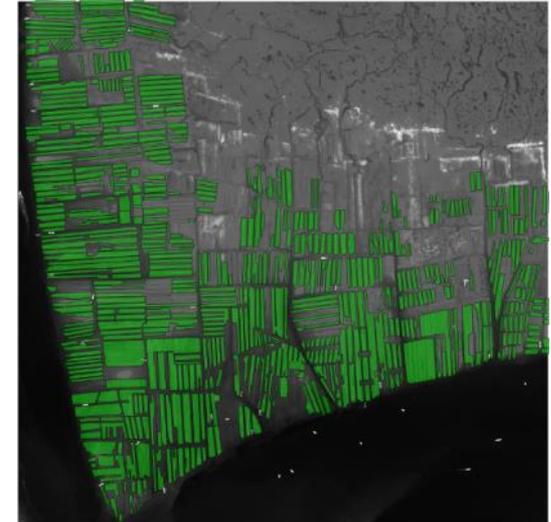
Pléiades 25/04/13



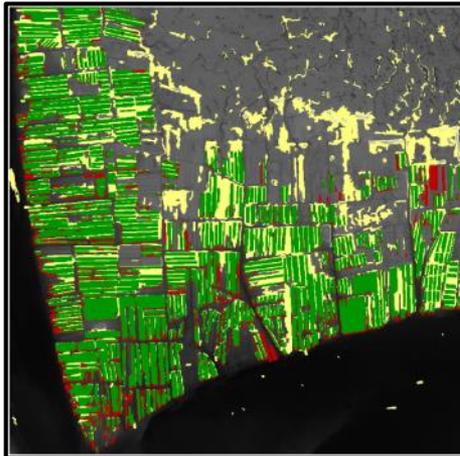
Pré-segmentation Mean-Shift



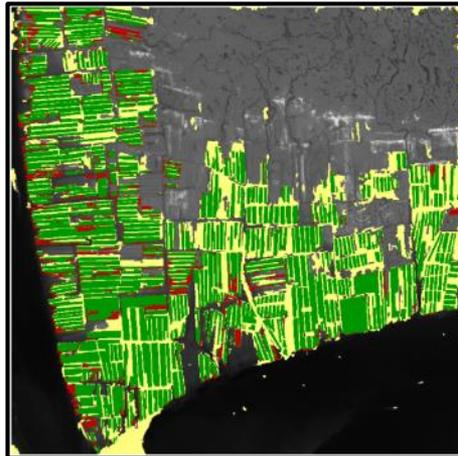
« vérité-terrain »



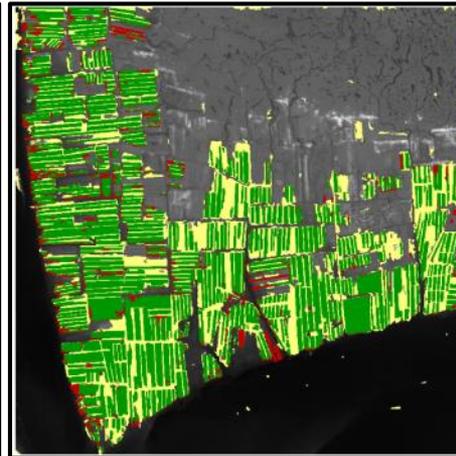
GLCM – k-NN



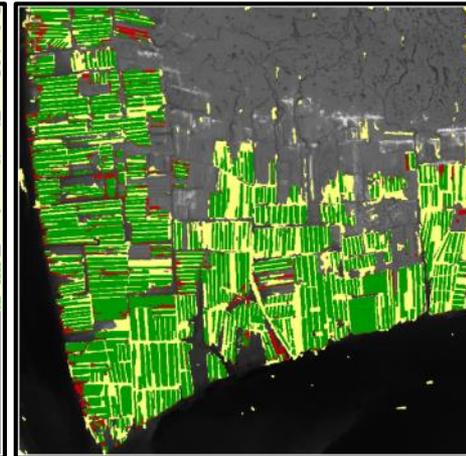
SCM - ML



SIRVg0 - ML

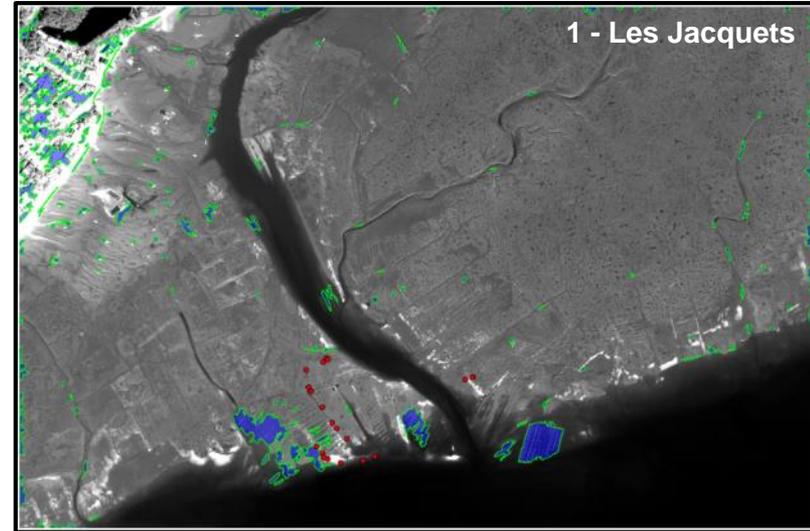
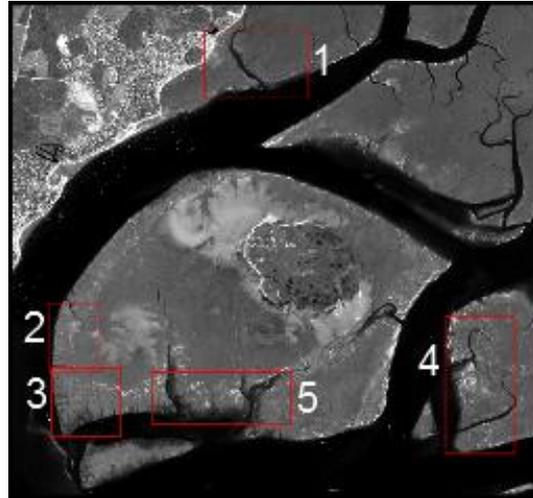
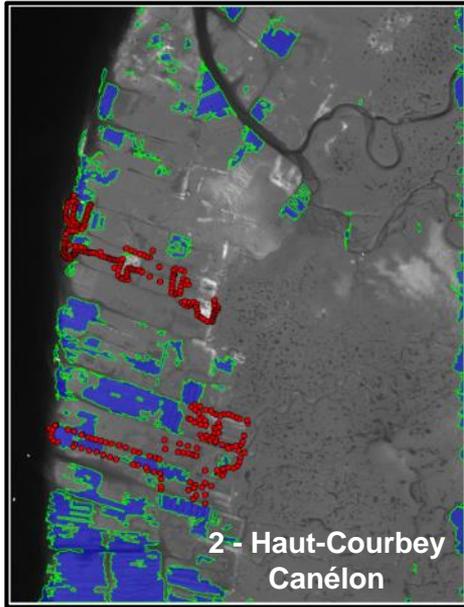


GCG – ML

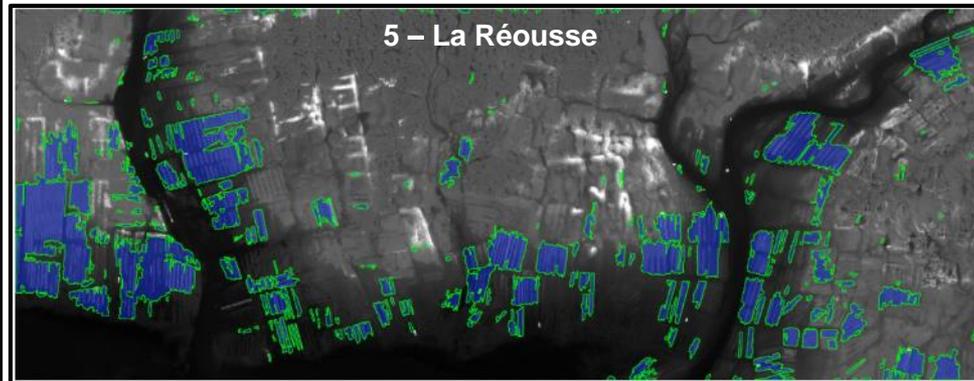
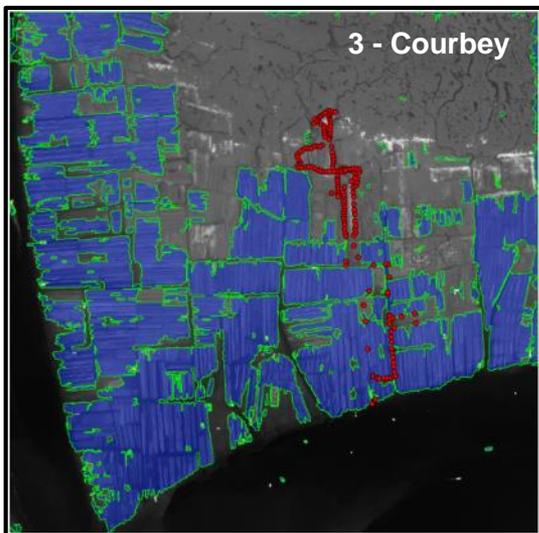
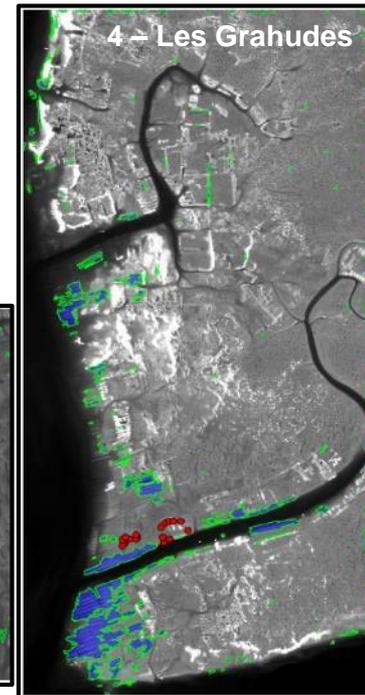


 Vrais positifs  Faux positifs  Vrais négatifs  Faux négatifs

Thématique Parcs à Huîtres – Validation



● = Points de validation

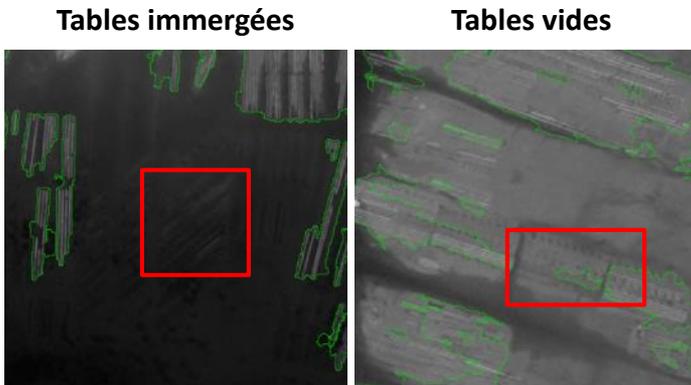


Thématique Parcs à Huîtres – Validation

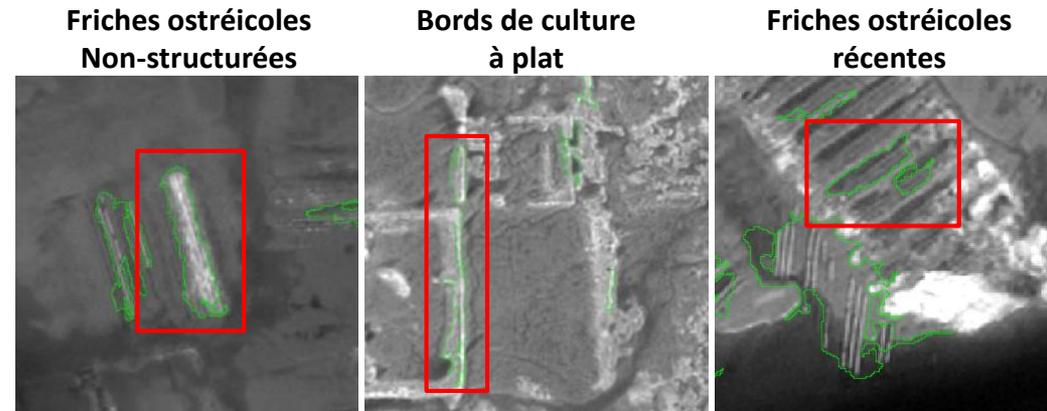
	GLCM	SCM	SIRVg0	GCG
Pourcentage total de bonnes classifications	48 %	65 %	70 %	66 %
Pourcentage de cultures sur tables bien détectées	88 %	68 %	75 %	71 %
Pourcentage de friches ostréicoles classées en cultures sur table	67 %	6 %	10 %	13 %

SIRVg0

→ Meilleur compromis



→ Confusion avec estran



→ Confusion avec friches

Téledétection

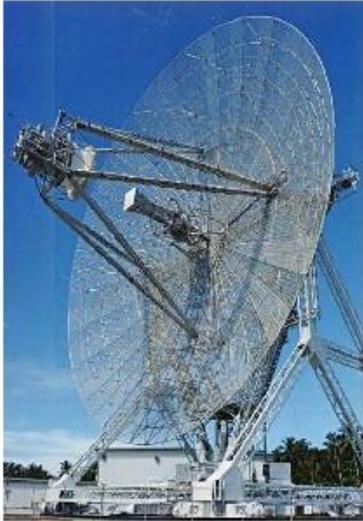
- **Analyse de texture, satellites Optiques et Radar**
 - Des matrices de cooccurrences aux ondelettes
 - **Application Forêts Cultivées**
 - Application Parc ostréicoles
- **Généralisation aux covariances**
 - Variétés Riemaniennes, covariance et Deep Learning
- **Autres travaux:**
 - Imagerie hyperspectrale (cépage vigne)
 - Détection de rangs de vigne Drone vs aérien

Classification robuste sur l'espace des **matrices de covariance**.

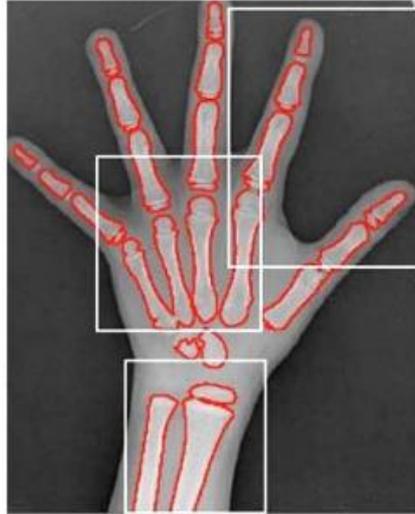
Application aux **images de télédétection polarimétriques Radar** à Ouverture Synthétique en forêt

Thèse de Ioana ILEA 2016

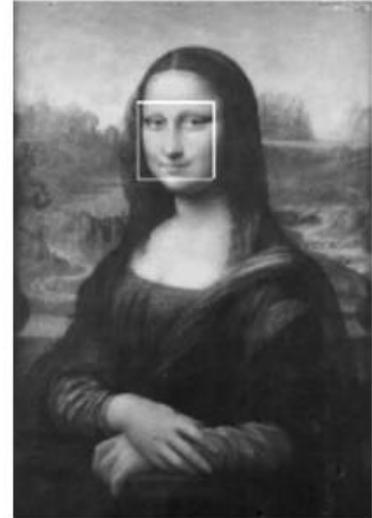
Matrices de covariance en traitement d'image



Détection radar [Greco *et al.*, 2014].



Segmentation d'images médicales [de Luis-García *et al.*, 2011].



Détection de visage [Robinson, 2005].

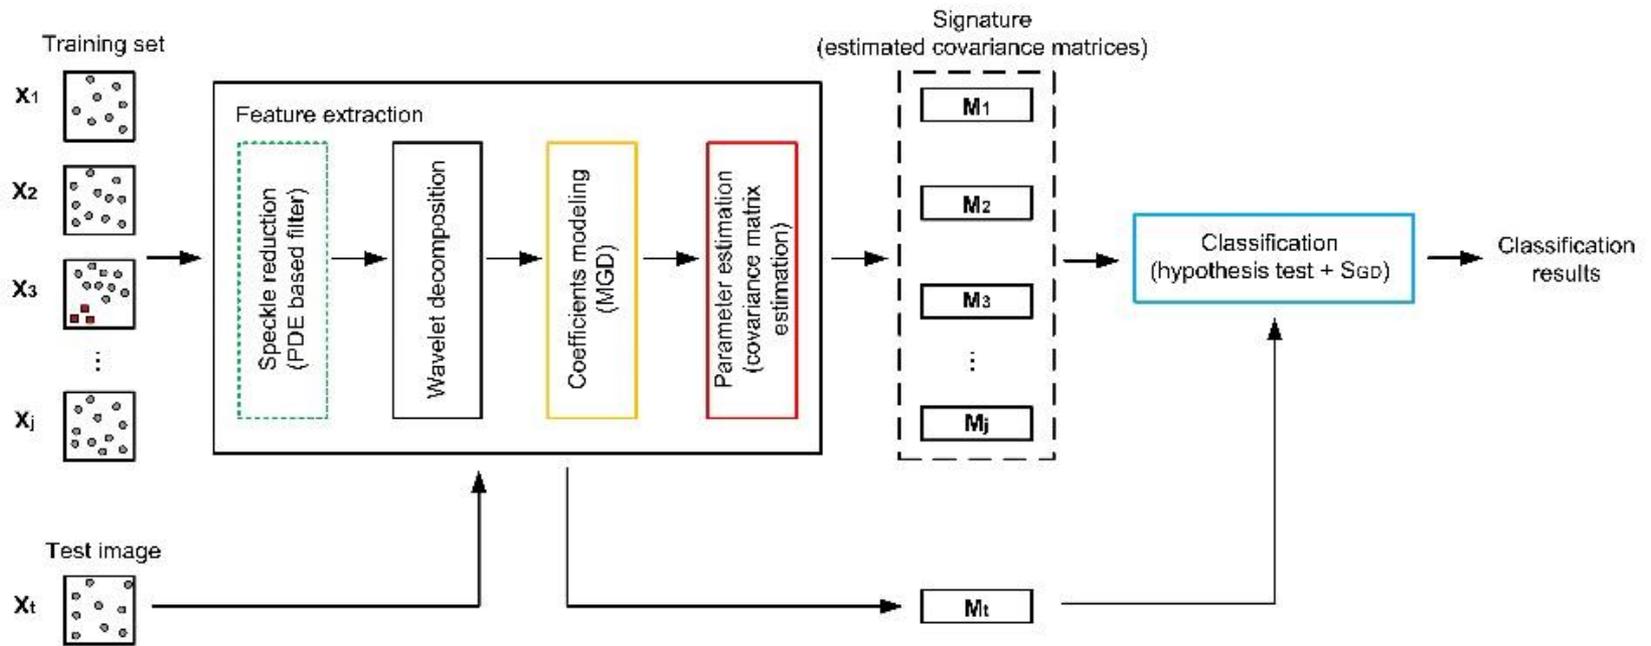


Détection de véhicule [Mader *et al.*, 2012].



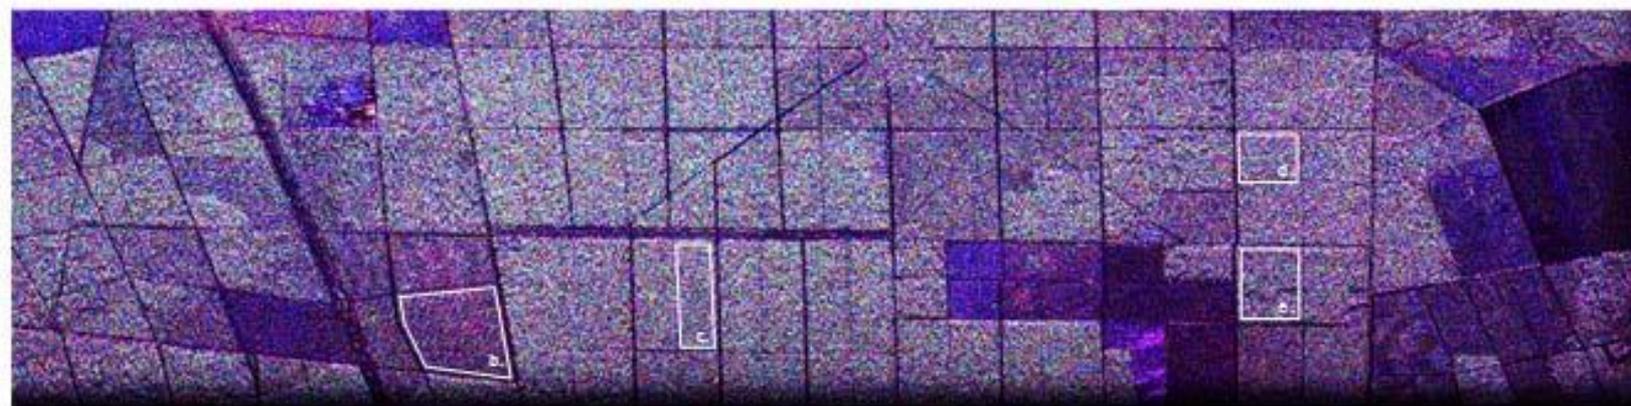
Classification de textures.

L'algorithme de classification proposé



La base de données

- Image PolSAR :



- 62 parcelles forestières.
- 4 classes d'âge :
 - classe 1 : moins de 10 ans ;
 - classe 2 : entre 10 et 20 ans ;
 - classe 3 : entre 20 et 30 ans ;
 - classe 4 : plus de 30 ans.

Caractéristiques de l'image PolSAR

- Bruit multiplicatif de type speckle :
 - difficultés dans l'analyse d'image ;
 - impact négatif sur la classification.
- **Proposition :**
 - Modélisation stochastique multi-échelles de l'information :
 - décomposition en ondelettes ;
 - modélisation par MGDs.
 - Réduction préalable du bruit :
 - en préservant les caractéristiques géométriques des éléments texturaux ;
 - en utilisant des méthodes de diffusion à base d'équations aux dérivées partielles.

Méthodes de filtrage basées sur la diffusion anisotrope

- Soient :

- le vecteur :

$$\mathbf{C} = [|HH|^2 \quad 2|HV|^2 \quad |VV|^2] ;$$

- le span défini pour la position spatiale (x, y) et l'itération t :

$$\mathbf{S}(x, y, t) = \sum_{i=1}^3 \mathbf{C}_i(x, y, t), \quad \mathbf{C}_i \in \mathbf{C}.$$

- La norme du gradient multiplicatif [Mora, *et al.*, 2012] :

$$\|\nabla_{\eta} \mathbf{S}\| = \exp \left(\sqrt{\ln^2 \left(\frac{S_{m+1,n}}{S_{m,n}} \right) + \ln^2 \left(\frac{S_{m,n+1}}{S_{m,n}} \right)} \right).$$

- en pratique : utilisation de la version lissée $\|\nabla_{\eta}(G_{\sigma} * \mathbf{S})\|$.

Méthodes de filtrage basées sur la diffusion anisotrope

- Le tenseur de structure [Di Zenzo, 1986] :

$$G_\rho * \sum_{j=1}^3 \nabla C_j (\nabla C_j)^T$$

donne les directions u et v du filtrage.

- Le filtre EDP :

$$\frac{\partial C_j}{\partial t} = \frac{\partial}{\partial v} [g^v (\|\nabla_\eta(G_\sigma * S)\|) C_{i_v}] + \frac{\partial}{\partial u} [g^u (\|\nabla_\eta(G_\sigma * S)\|) C_{i_u}],$$

où :

- g^v et g^u sont les fonctions de diffusion [Tsiotsios & Petrou, 2013] ;
- C_{i_v} et C_{i_u} sont les dérivées par rapport à v et u .

Résultats du filtrage



Image originale



Filtre Gaussien



Filtre SRAD



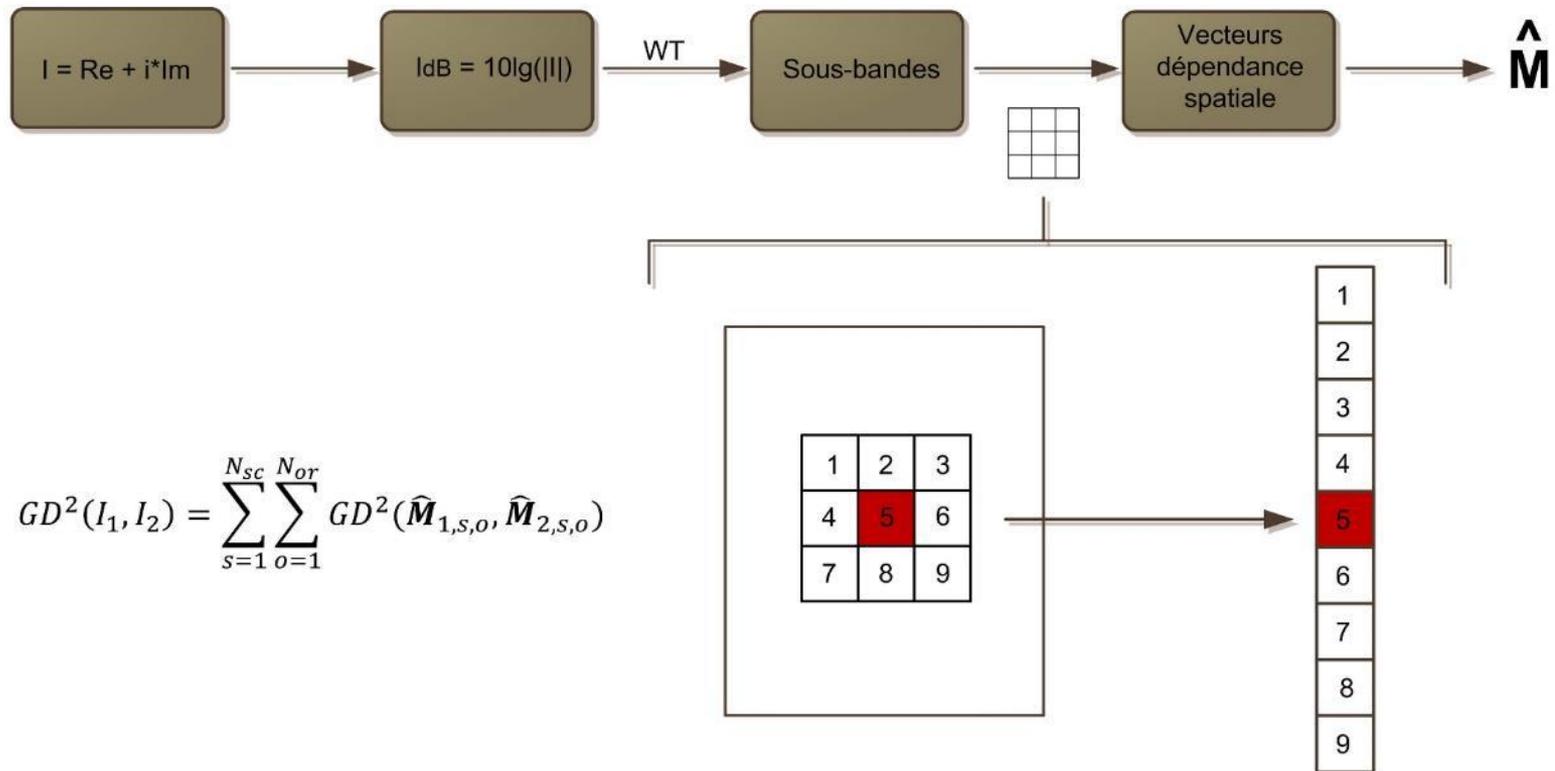
Filtre Boxcar



Filtre EDP

Descripteurs

- Dépendance spatiale sur les coefficients en ondelettes :



$$GD^2(I_1, I_2) = \sum_{s=1}^{N_{sc}} \sum_{o=1}^{N_{or}} GD^2(\hat{M}_{1,s,o}, \hat{M}_{2,s,o})$$

Performances de classification



Image originale



Filtre Gaussien



Filtre SRAD



Filtre Boxcar



Filtre EDP

Méthode de classification	Image originale	Image filtrée			
		Gaussien	Boxcar	SRAD	EDP
MGD HH + WT + S	57.94 ± 6.15	63.00 ± 4.09	62.28 ± 4.24	63.03 ± 5.14	65.47 ± 2.99
MGD HV + WT + S	61.09 ± 5.32	61.38 ± 3.94	62.88 ± 4.64	60.25 ± 6.05	64.47 ± 3.37
MGD VV + WT + S	59.66 ± 4.68	60.94 ± 5.66	65.50 ± 4.68	61.58 ± 5.20	65.91 ± 4.26

Téledétection

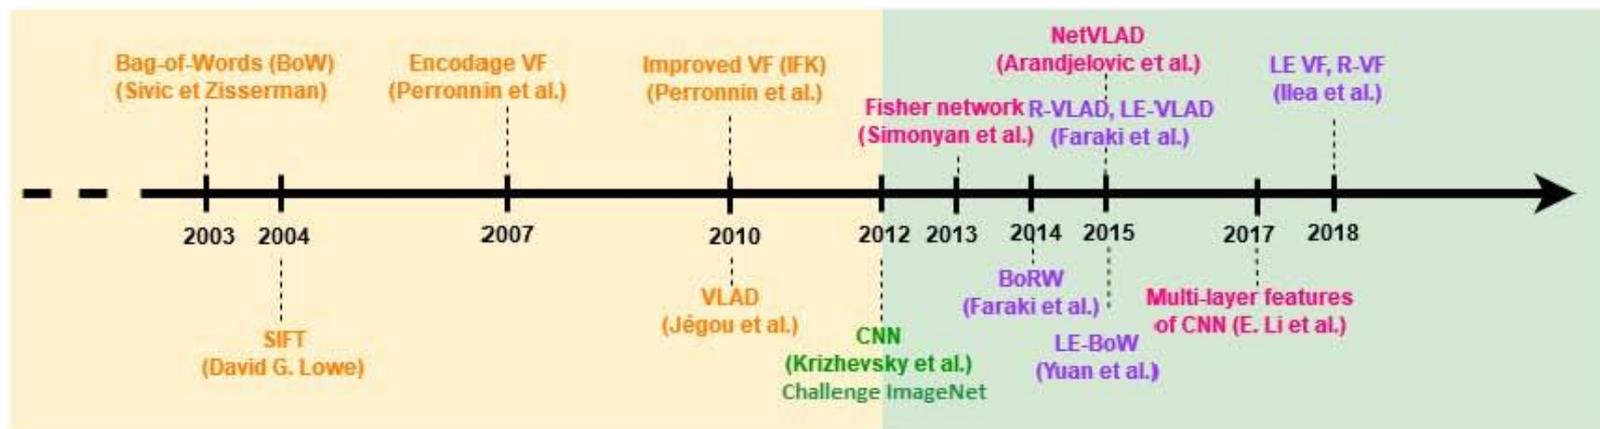
- Analyse de texture, satellites Optiques et Radar
 - Des matrices de cooccurrences aux ondelettes
 - Application Forêts Cultivées
 - Application Parc ostréicoles
- **Généralisation aux covariances**
 - **Variétés Riemaniennes, covariance et Deep Learning**
- Autres travaux:
 - Imagerie hyperspectrale (cépage vigne)
 - Détection de rangs de vigne Drone vs aérien

Image classification based on log-Euclidean Fisher Vectors for covariance matrix descriptors

Travaux de Sara AKODAD 2018

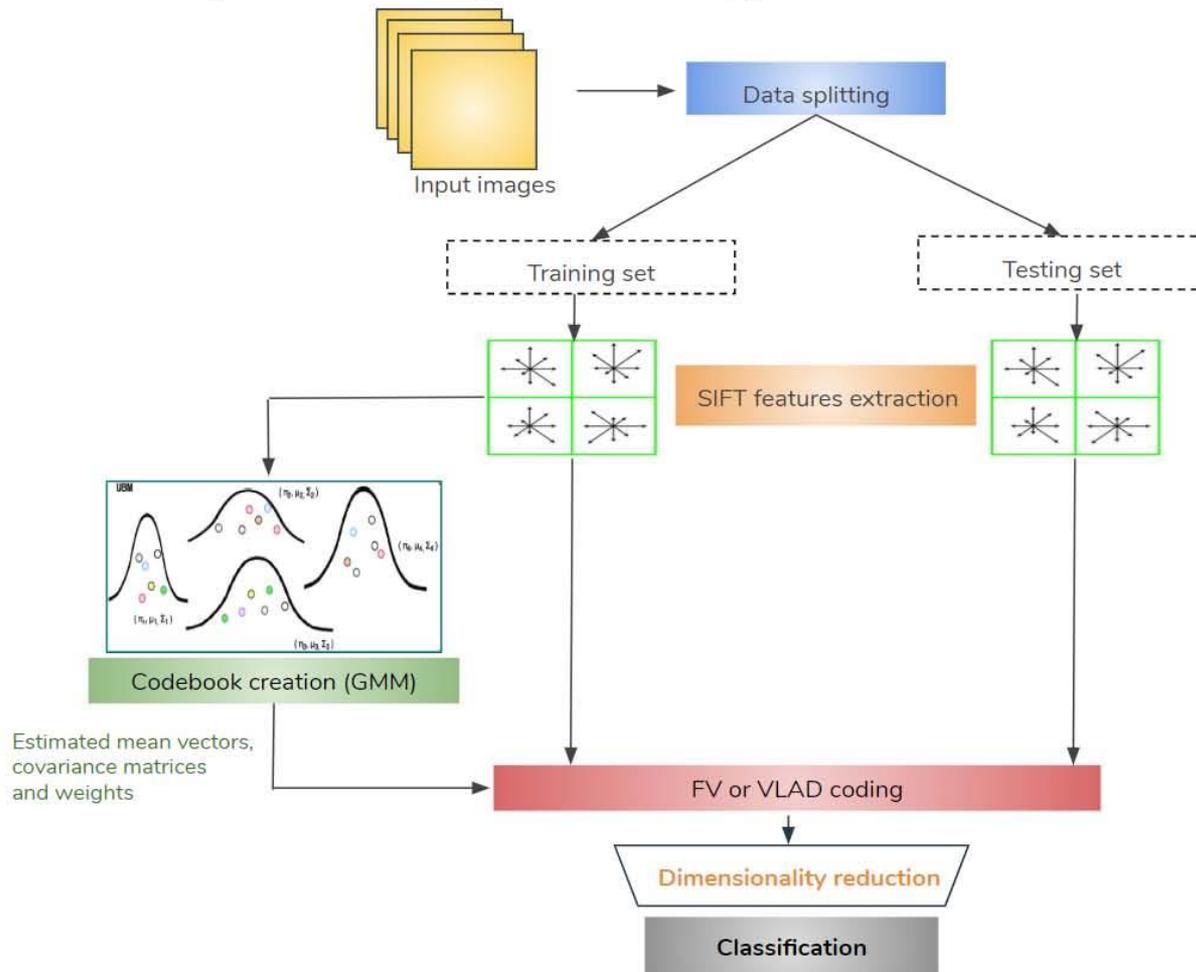
Image supervised classification based on :

- **Standard approaches** : Extraction of local features, Fisher vectors (FV) and vectors of locally aggregated descriptors (VLAD).
- **Deep learning techniques** using neural networks
- **Combination of these approaches** → Hybrid architectures.
- Extension to covariance matrices descriptors.



VF and VLAD encoding of SIFT features

- Scale-invariant feature transform (SIFT) extraction
- Codebook generation using the mixture of Gaussian models (GMM)
- Features encoding by VF/VLAD and SVM classification
- Dimensionality reduction (if necessary)



FV and VLAD encoding of SIFT features

Fisher vectors (FV) [Perronnin et al. 2007]

Fisher vectors :

$$G_{\lambda}^{\mathbf{X}} = \mathbf{F}_{\lambda}^{-\frac{1}{2}} \nabla_{\lambda} \log p(\mathbf{X}|\lambda)$$

In the case of the Gaussian mixture model (GMM) :

$$G_{\mu_k^d}^{\mathbf{X}} = \frac{1}{\sqrt{\omega_k}} \sum_{n=1}^N \gamma_k(\mathbf{x}_n) \left(\frac{\mathbf{x}_n^d - \mu_k^d}{\sigma_k^d} \right),$$

$$G_{\sigma_k^d}^{\mathbf{X}} = \frac{1}{\sqrt{2\omega_k}} \sum_{n=1}^N \gamma_k(\mathbf{x}_n) \left(\frac{[\mathbf{x}_n^d - \mu_k^d]^2}{(\sigma_k^d)^2} - 1 \right),$$

with :

$$\gamma_k(\mathbf{x}_n) = \frac{\omega_k p_k(\mathbf{x}_n|\lambda_k)}{\sum_{j=1}^K \omega_j p_j(\mathbf{x}_n|\lambda_j)}$$

VLAD vectors [Jégou et al. 2010] : Hard version of Fisher vectors.

Application of the *K-means* algorithm :

$$\mathbf{v}_k = \sum_{\mathbf{x}_n \in C_k} \mathbf{x}_n - \mu_k \quad \mathbf{VLAD} = [\mathbf{v}_1^T, \dots, \mathbf{v}_K^T].$$

VF and VLAD encoding of SIFT features

Accuracy evaluation

Comparison of classification results for various encoding approaches (Database : UC Merced Land Use Land Cover).

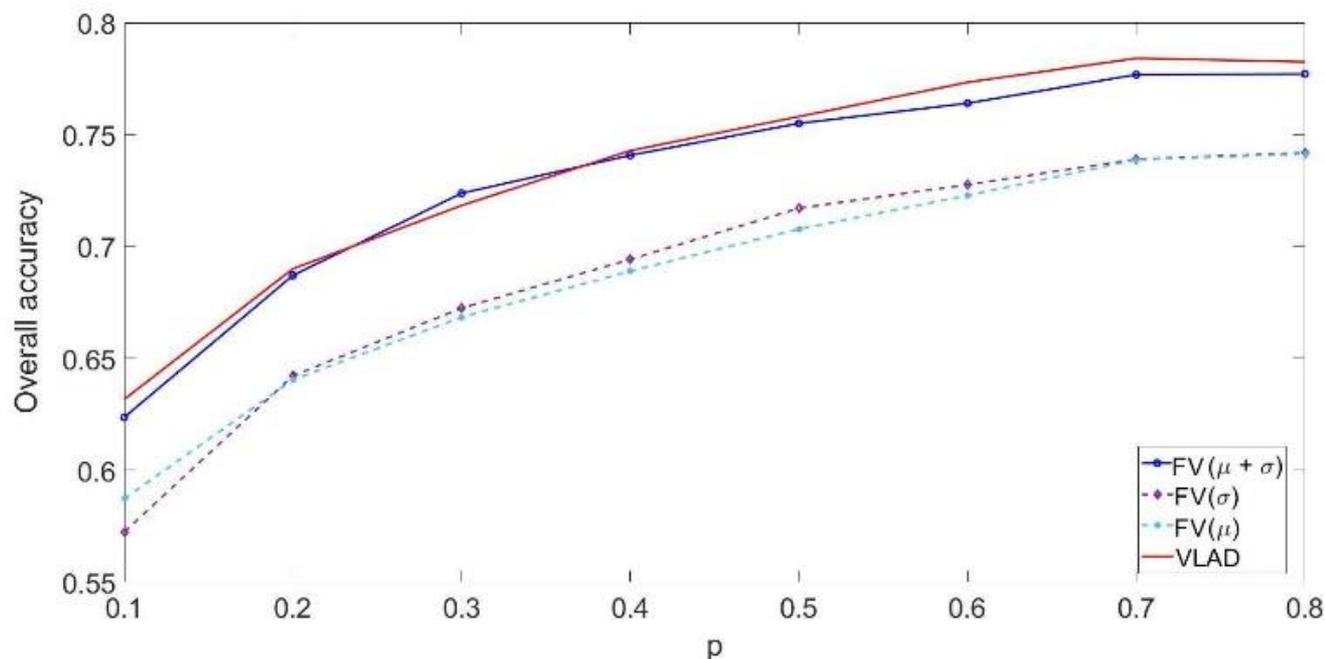


Figure – Evolution of the classification accuracy as a function of the proportion p of training samples (No dimensionality reduction, $K = 30$)

VLAD and $FV(\mu + \sigma)$ encoding methods are more effective.

\Rightarrow $\sim 75\%$ of overall accuracy for $p = 50\%$

Convolutional neural networks (CNNs)

Structure : Stacking convolution, pooling and activation layers.

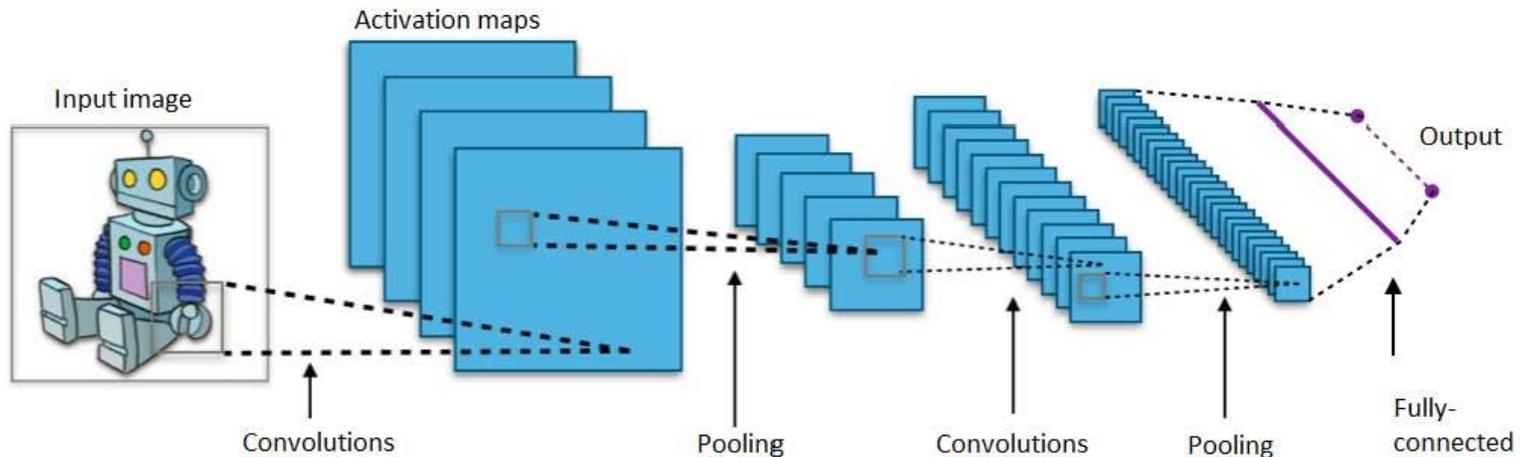


Figure – General architecture of a CNN model

- Use of 7 CNN models : Vgg-s, Vgg-m, Vgg-f, caffeNet, alexNet, Vgg-verydeep-16 and Vgg-verydeep-19.

Convolutional neural networks (CNNs)

Performance evaluation on UC Merced Land Use database

The CNN models trained on ImageNet \Rightarrow **Transfer Learning**.

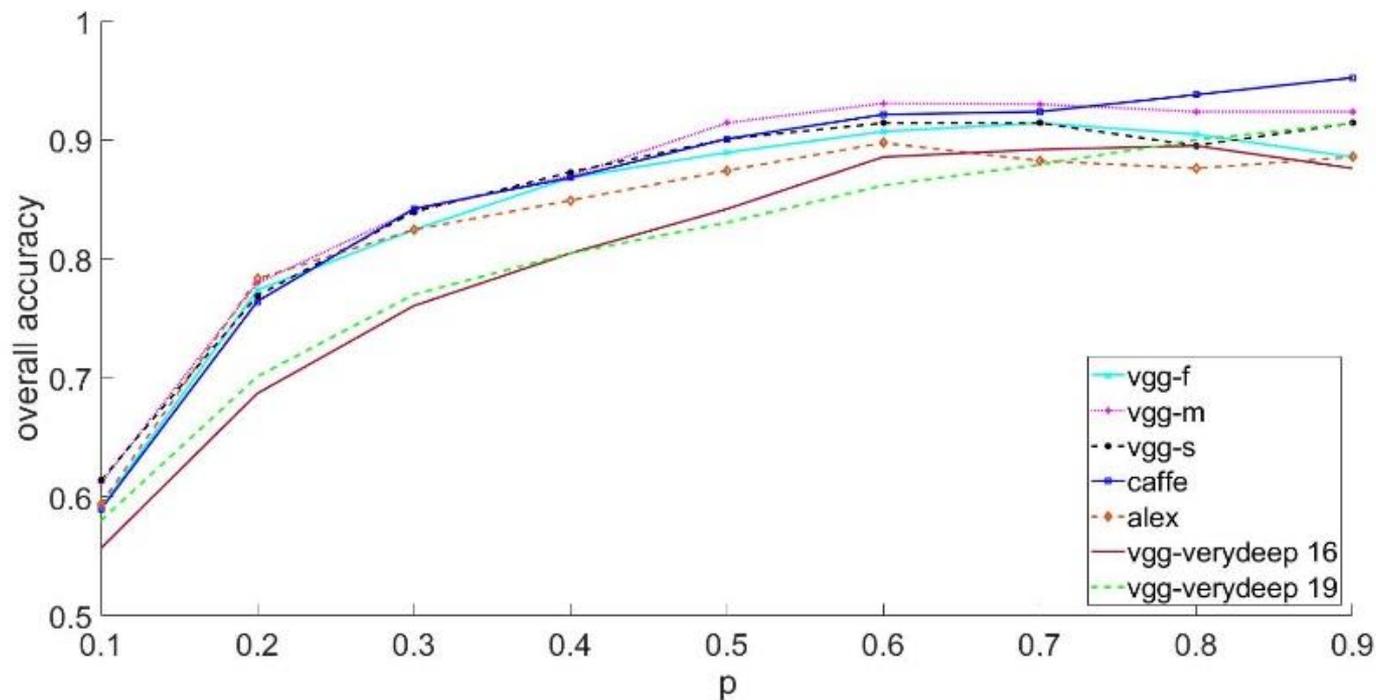


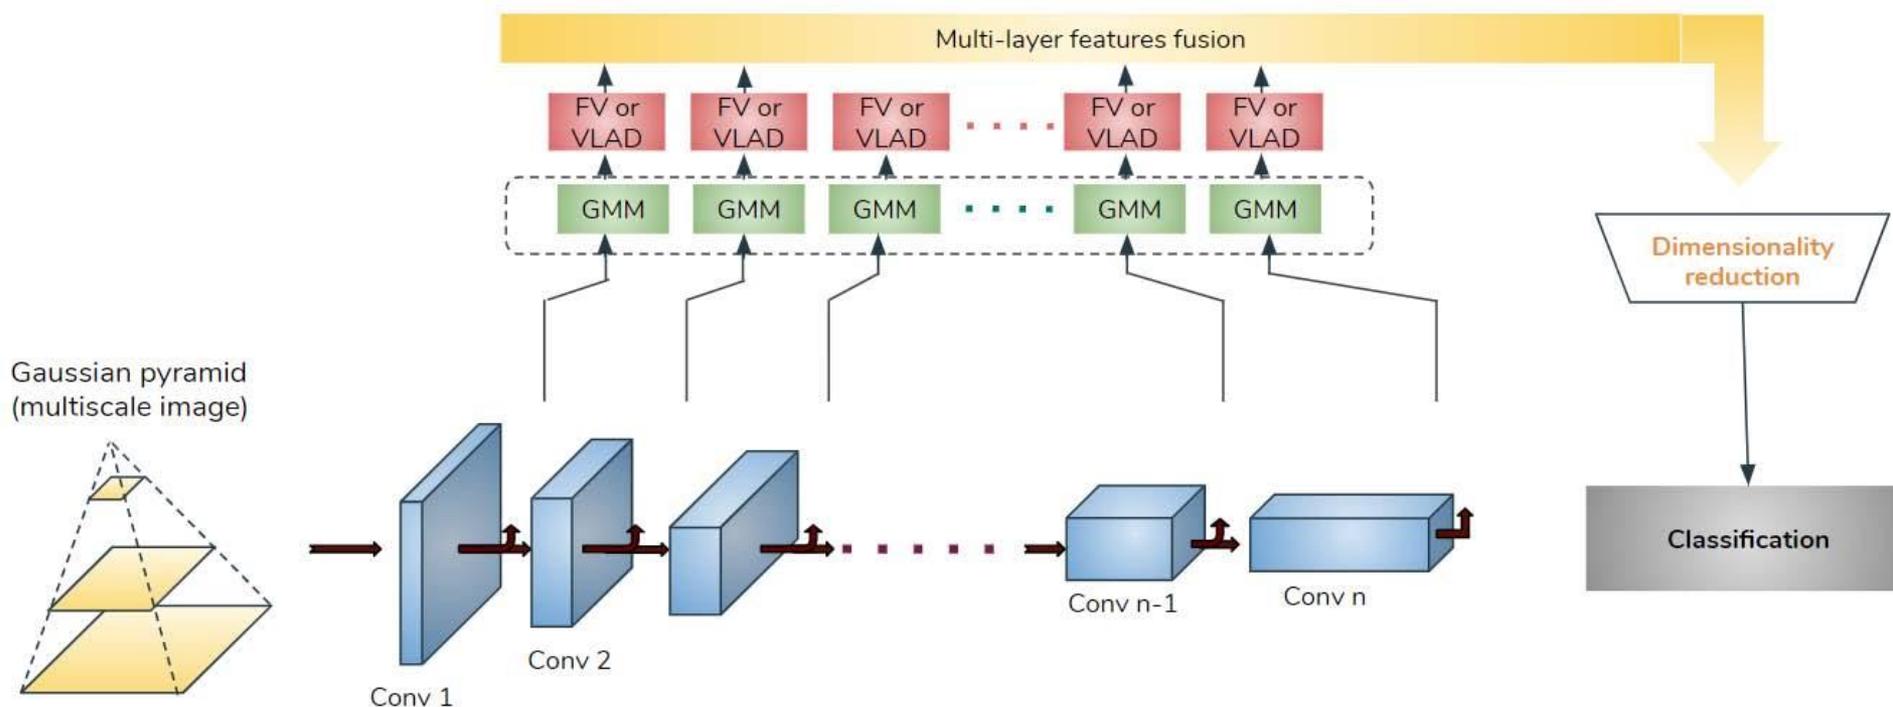
Figure – Classification accuracy regarding the 7 CNN models

- Similar behaviour for the different CNN models.
- Overall accuracy close to 90% from $p = 50\%$.

Hybrid architecture

State-of-the-art hybrid architectures :

- Fisher Network [Simonyan et al. 2013]
- NetVLAD [Arandjelovic et al. 2015]
- **Encoding multi-layer features of convolutional neural network [Li et al. 2017]**



Hybrid architecture

Classification accuracy (UC Merced Land Use database)

Comparison of the different CNN models (hybrid architecture)

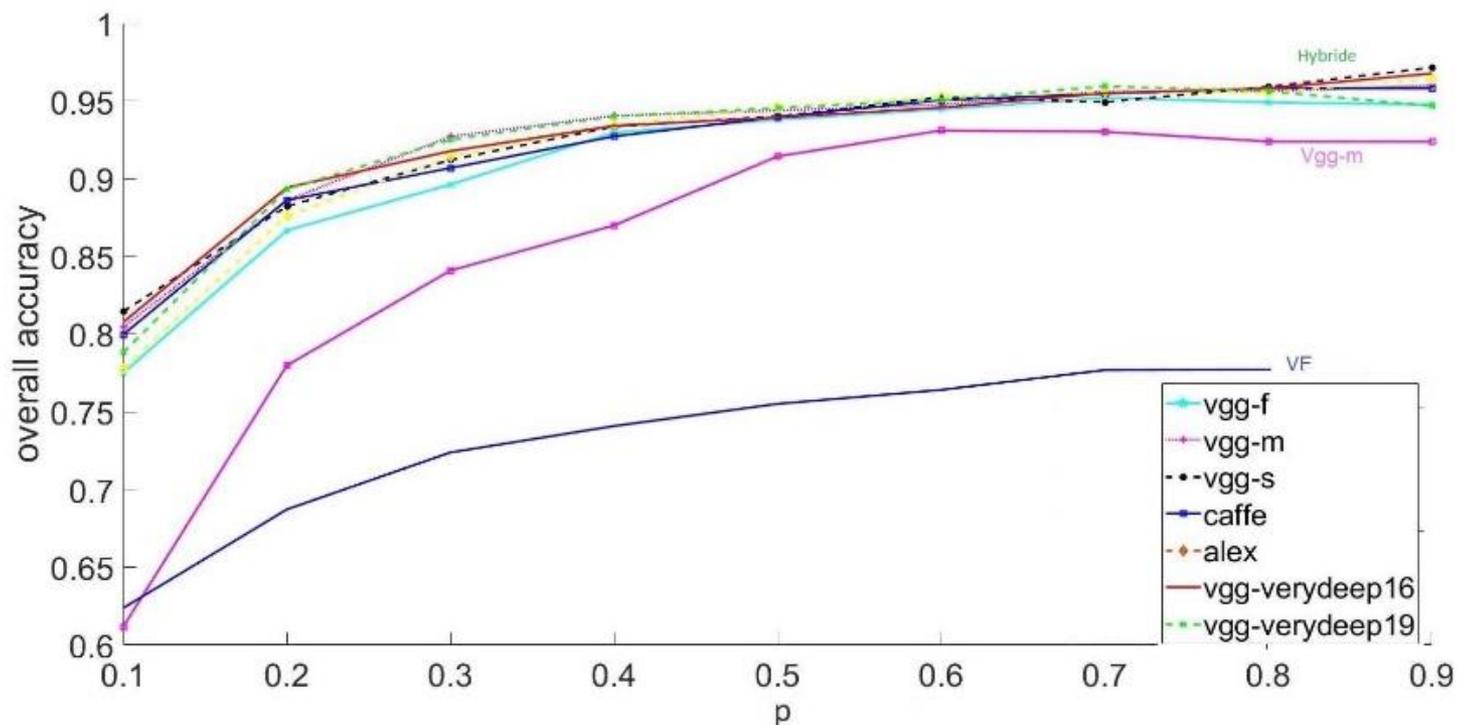


Figure – Comparison of classification results

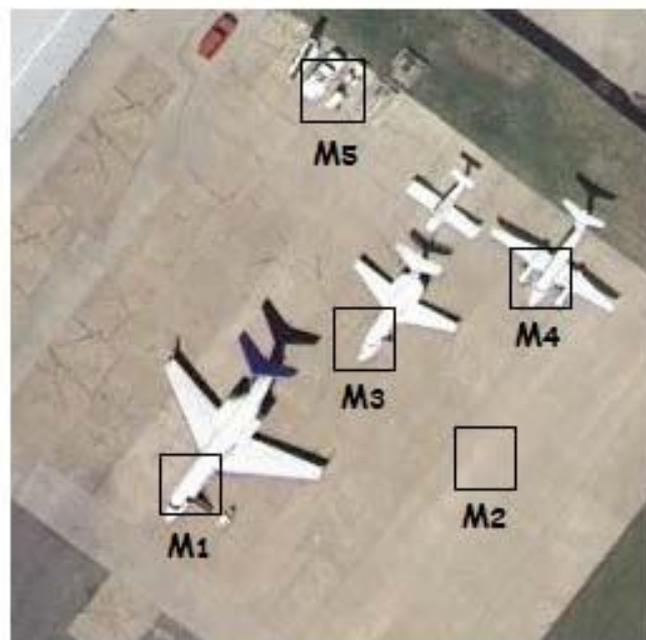
Comparison results :

Method	FV	CNN	Hybrid
Overall accuracy at $p = 50\%$	$\sim 75\%$	$\sim 90\%$	$\sim 94\%$

Covariance matrices encoding

Local covariance matrices

- Each image is represented by a set of $\{\mathbf{M}_n\}_{n=1:N}$ covariance matrices.



- ⚠ - Encoding a set of covariance matrices.
- Respect the geometric properties of the space of Symmetric Positive Definite (SPD) matrices.

Covariance matrices encoding

Manifold of covariance matrices

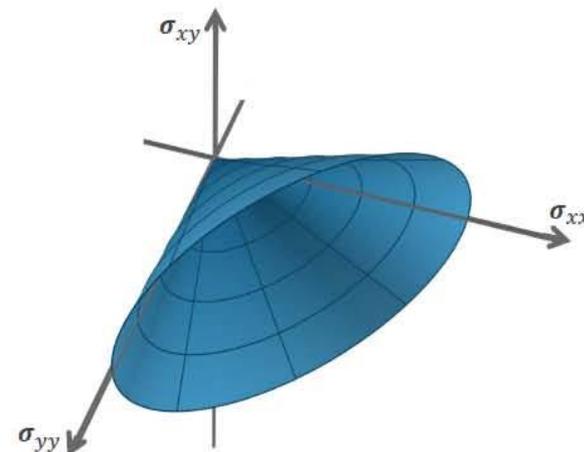
$\mathbf{M} = \begin{pmatrix} \sigma_{xx} & \sigma_{xy} \\ \sigma_{xy} & \sigma_{yy} \end{pmatrix}$ is a 2×2 SPD matrix.

$$\mathbf{M} - \mathbf{M}^T = 0 \text{ (Symmetry)}$$

$$\mathbf{x}^T \mathbf{M} \mathbf{x} > 0 \text{ (Positive definite)}$$

$$\forall \mathbf{x} \in \mathbb{R}^2 \text{ and } \mathbf{x} \neq 0$$

→ Subspace of \mathbb{R}^3



- Invariance properties : $d(\mathbf{M}_1, \mathbf{M}_2) = d(T(\mathbf{M}_1), T(\mathbf{M}_2))$

Distance	rotation	scale	inversion	affine invariance
Euclidean	✓	✗	✗	✗
Log-Euclidean	✓	✓	✓	✗
Affine invariant	✓	✓	✓	✓

Covariance matrices encoding

Encoding a set of covariance matrices computed from SIFT features (LE FV approach)

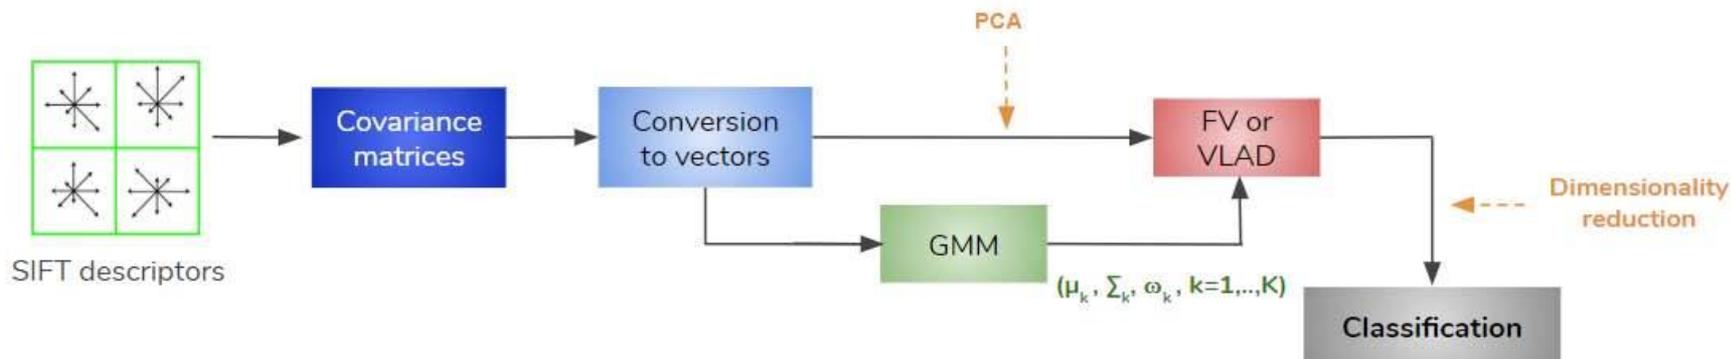
- Each covariance matrix \mathbf{M} is mapped on the Log-Euclidean (LE) space \Rightarrow Conversion from matrices to vectors :

$$\mathbf{m} = \text{Vect}(\text{Log}(\mathbf{M}))$$

with $\text{Vect}(\mathbf{X}) = [X_{11}, \sqrt{2}X_{12}, \dots, \sqrt{2}X_{1m}, X_{22}, \sqrt{2}X_{23}, \dots, \sqrt{2}X_{mm}]$,
 X_{ij} the elements of \mathbf{X} and $\mathbf{m} \in \mathbb{R}^{\frac{m(m+1)}{2}}$

FV encoding of vectors $\mathbf{m} \Rightarrow$ LE FV vectors

- Codebook generation, coding and classification steps.



Covariance matrices encoding

Performance comparison between FV and LE FV approaches

Classification results with FV and LE FV approaches on the UC Merced Land Use database :

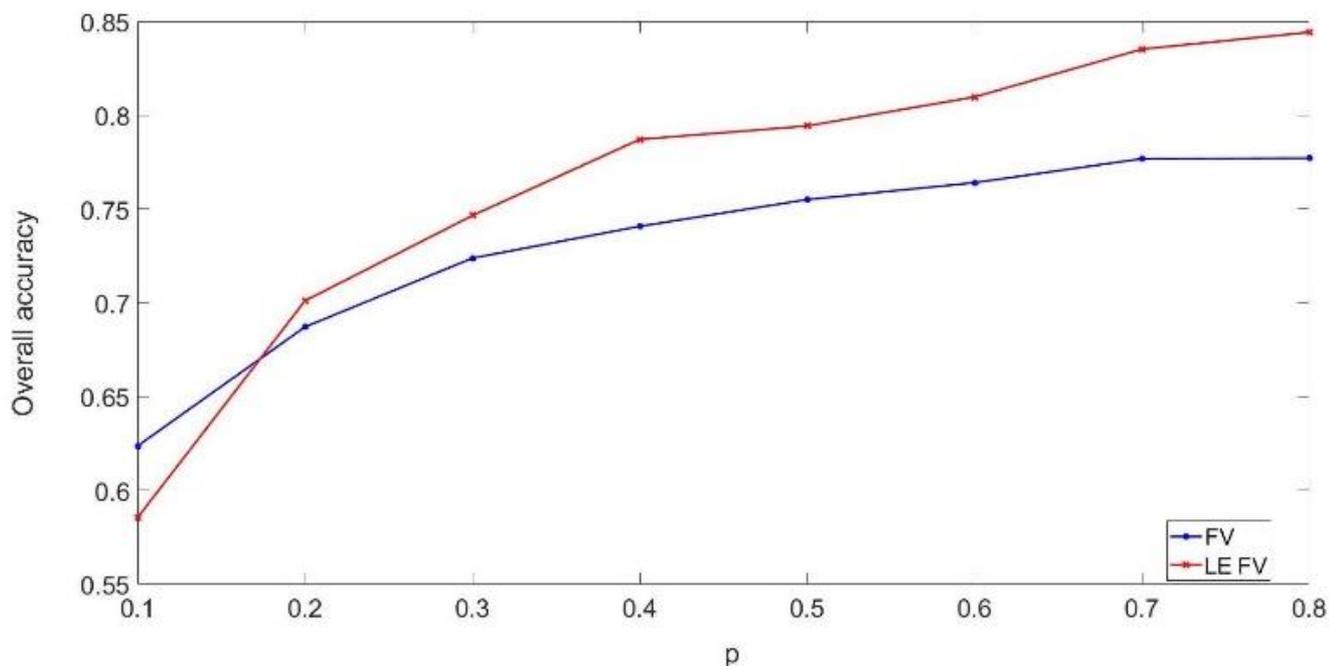


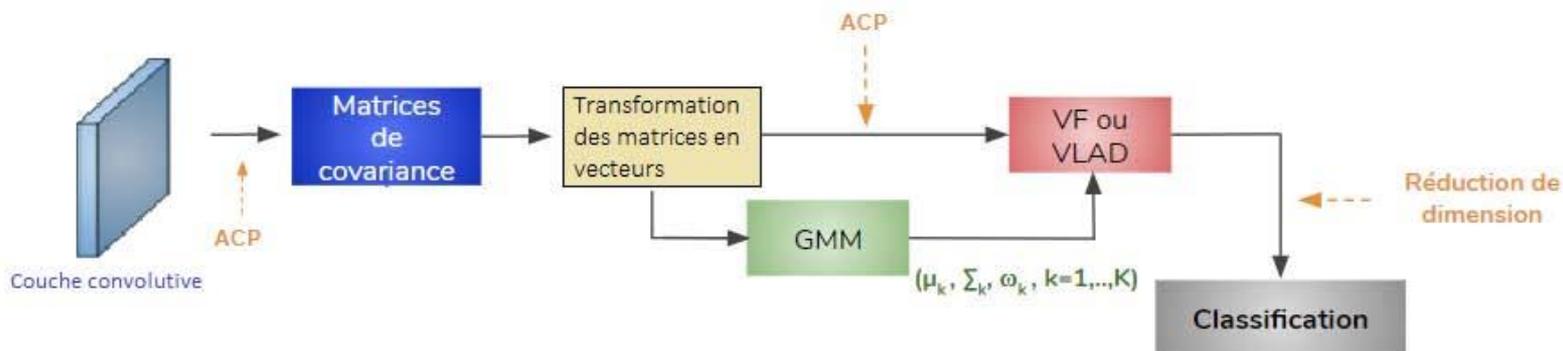
Figure – Accuracy comparison of the FV and LE FV approaches ($N_{PCA} = 20$, $K = 30$)

- Gain of about **5%** for the LE FV compared to FV.

Covariance matrices encoding

LE FV coding of convolutional layers (Hybrid architecture)

- Selection of appropriate convolutional networks :
Small-sized images \Rightarrow few covariance matrices
- Operating on the first two layers of deep neural networks
Vgg-verydeep 16 and *Vgg-verydeep 19*.



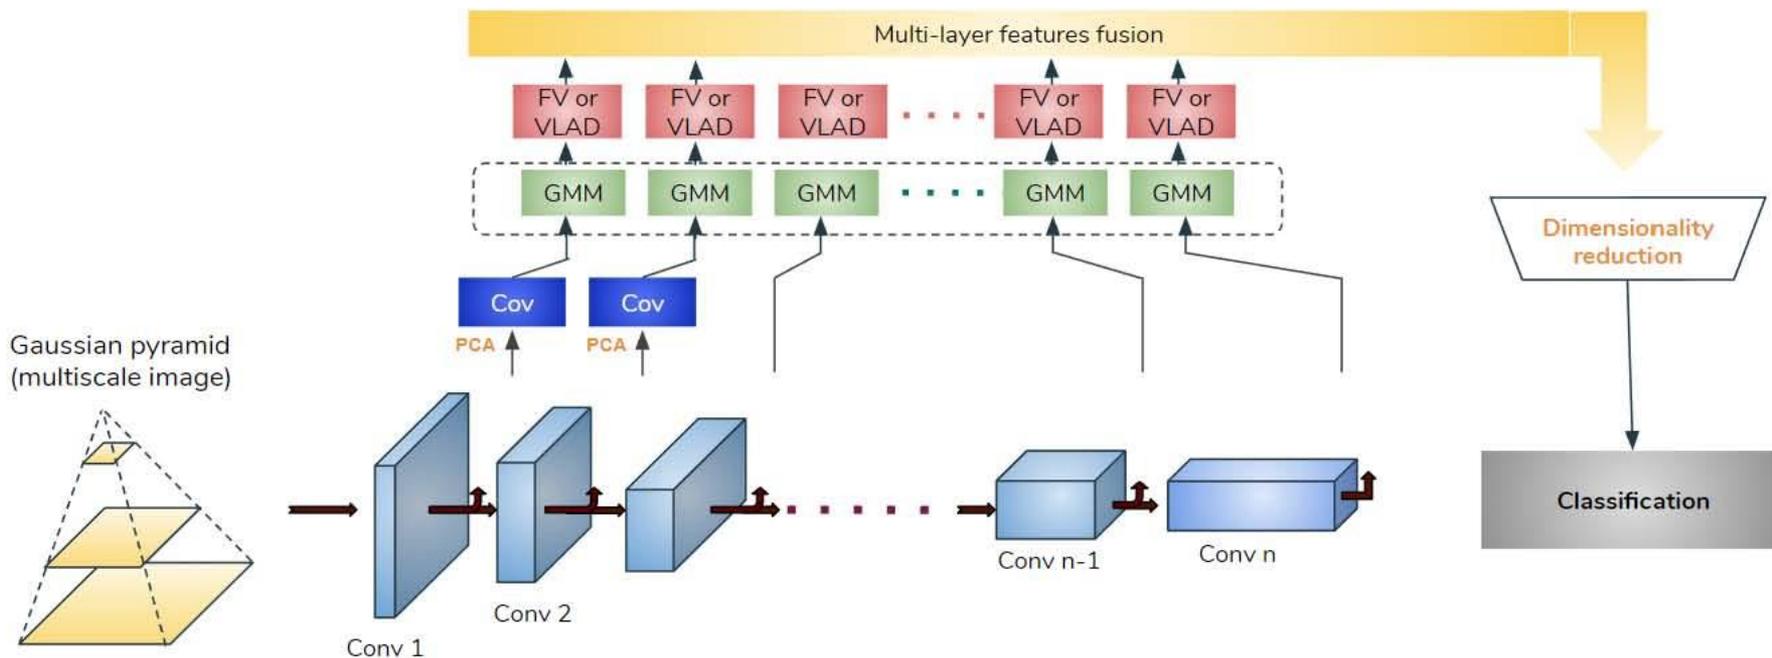
Classification results ($p = 50\%$) :

	Approach	Vgg-verydeep 16	Vgg-verydeep 19
Conv1	FV	58.2 \pm 0.7	57.6 \pm 1.1
	LE FV	70.9 \pm 1.0	69.2 \pm 0.9
Conv2	FV	62.5 \pm 1.2	63.1 \pm 1.2
	LE FV	87.7 \pm 0.7	87.3 \pm 0.4

Covariance matrices encoding

LE FV coding for the full hybrid architecture

- LE FV encoding for the first two layers.
- FV encoding for the deepest layers.



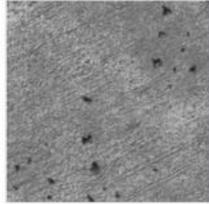
Classification results (Vgg-verydeep 16 model) :

Approaches	Hybrid FV	Hybrid LE FV
OA for $p = 50\%$	96.2 ± 0.7	95.9 ± 0.7

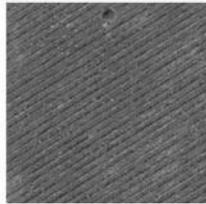
Appendix I

Experiments on other remote sensing dataset

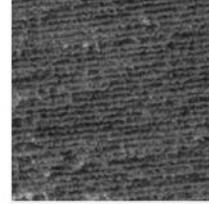
Maritime pine forest : 4 classes (Resolution : 50 *cm*)



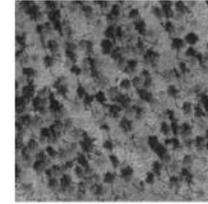
Clear-cutting



Age 1

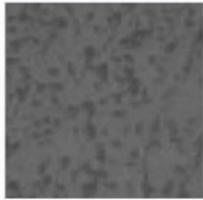


Age 2

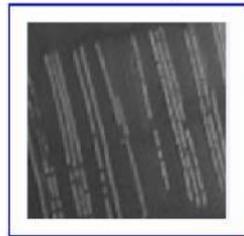


Age 3

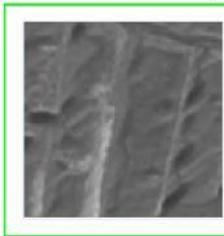
Oyster racks : 5 classes (Resolution : 50 *cm*)



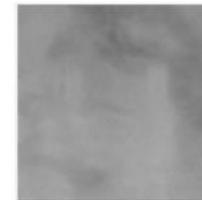
Foreshore



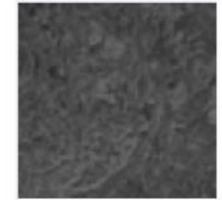
Oyster racks



Abandoned fields



Sand



Schorre



Oyster racks



Abandoned fields

Appendix I

Experiments on other remote sensing dataset

FV and LE FV coding of convolutional layers (CNN model : Vgg-verydeep 16) :

Forest dataset :

Approach	Conv 1	Conv 2	Conv 1 to Conv n
FV	85.7 \pm 1.6	86.1 \pm 1.9	93.4 \pm 1.5
LE FV	89.9 \pm 1.1	91.4 \pm 0.3	95.0 \pm 1.0

Oyster racks dataset :

Approach	Conv 1	Conv 2	Conv 1 to Conv n
FV	87.7 \pm 2.5	88.7 \pm 2.1	98.0 \pm 1.2
LE FV	94.4 \pm 1.1	96.6 \pm 0.7	98.4 \pm 0.3

Téledétection

- Analyse de texture, satellites optiques et Radar
 - Des matrices de cooccurrences aux ondelettes
 - Application Forêts Cultivées
 - Application Parc ostréicoles
- Généralisation aux covariances
 - Variétés Riemaniennes, covariance et Deep Learning
- Autres travaux:
 - Imagerie hyperspectrale (cépage vigne)
 - Détection de rangs de vigne Drone vs aérien

PROXIDETECTION

Contexte, vecteurs, capteurs, outils méthodologiques

Applications Vigne

Applications Arboriculture fruitière

Motivation

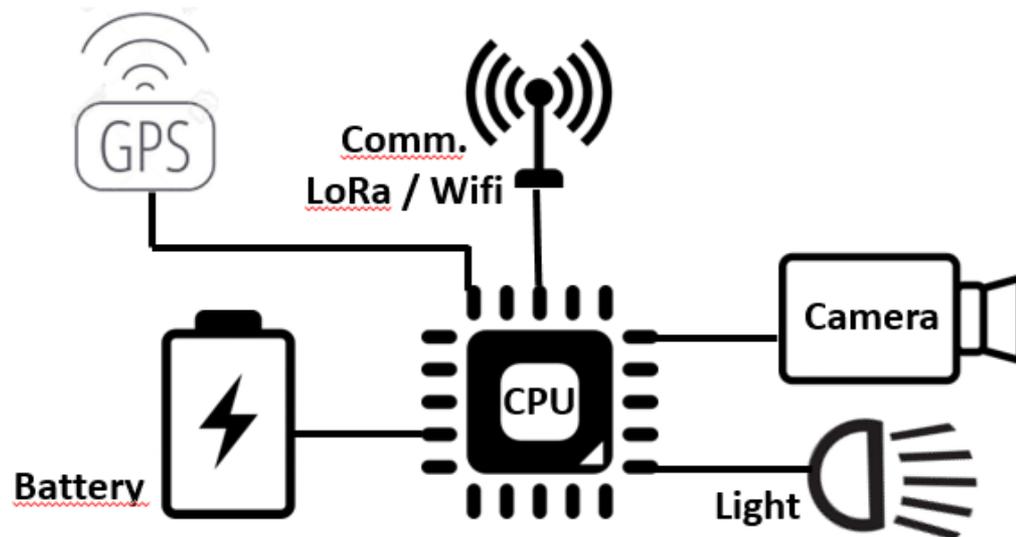
- Visual data can provide detailed and precise direct observations about the plant
- Proximal detection images are easy to acquire as the cameras can be fitted in the existing infrastructure (tractors and trellis wires)
- Monitoring:
 - Vigour
 - Yield
 - Phenological stage
 - Health
 - ...

Motivation

- Two acquisition strategies:
 - High spatial frequency: mobile sensors
 - One photo per plant
 - Around one passage per month
 - High temporal frequency: fixed sensors
 - One photo per day
 - 1-2 low cost sensors per plot (one hectare area)

Mobile sensors

- High-performance mobile sensors
 - Industrial camera, high-power flash, on-board computer, GPS in a dustproof housing
 - 2 units per tractor to monitor both sides of the plant



Mobile sensors



First prototype



New sensor setup

Mobile sensors: Various vectors



Mobile sensors: Various vectors



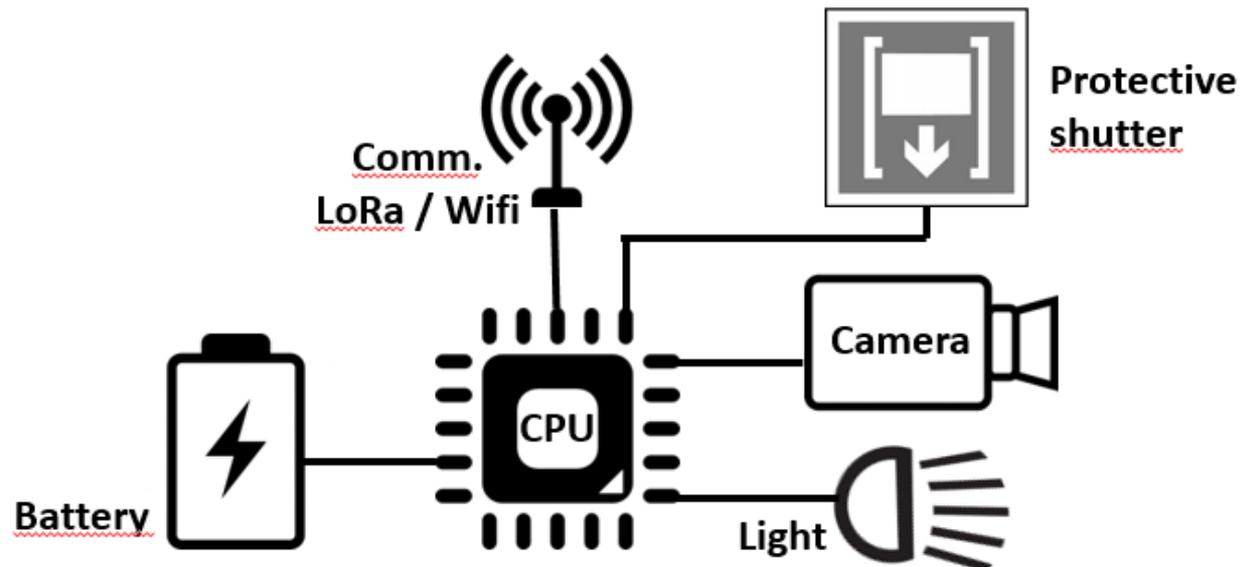
Mobile sensors: Various vectors



Mobile sensors: Various vectors

Fixed sensors

- Fixed sensors monitor, night after night, the evolution of the vine. Low cost technologies for large distribution in the plot.
- Specific camera and lighting for multispectral (visible and near infrared) images of the plant. On board processing: reduced communications with the gateway.

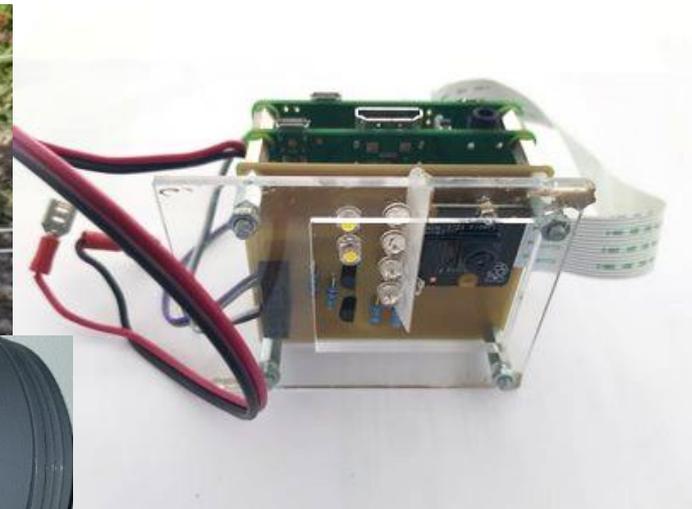


Capteurs fixes: applications

- Thématiques:
 - Vigne:
 - Vigueur
 - Surveillance des insectes ravageurs
 - Arboriculture fruitière
 - Calibration / contrôle qualité

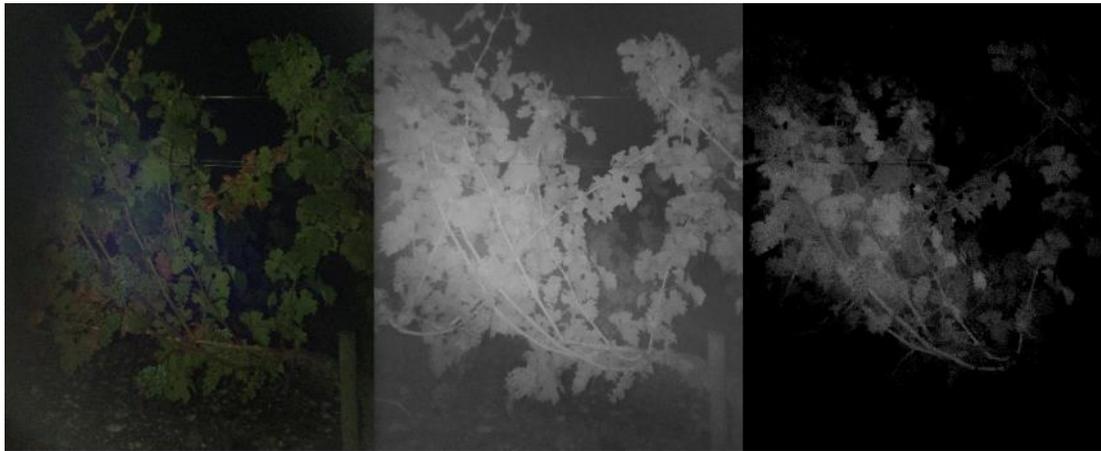
Fixed sensors (phenology)

- Fixed vegetation sensor
 - Low-cost multispectral camera
 - Based on a Raspberry Pi, power management circuit, lighting circuit board
 - Enclosed in a weatherproof housing with a motorized protective sliding door.

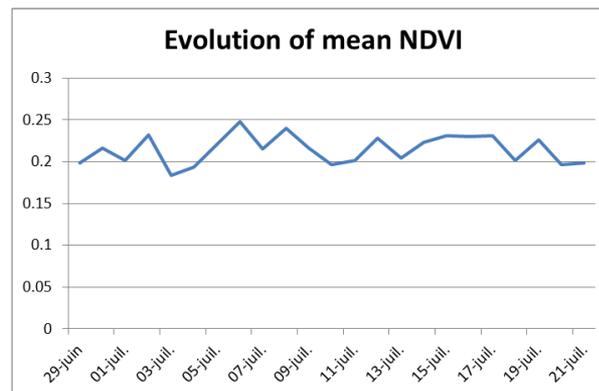


Results

- Vigor estimation using the fixed sensor



Color, near infrared images acquired by the sensor and the NDVI



Results

- Vigor estimation using the fixed sensor



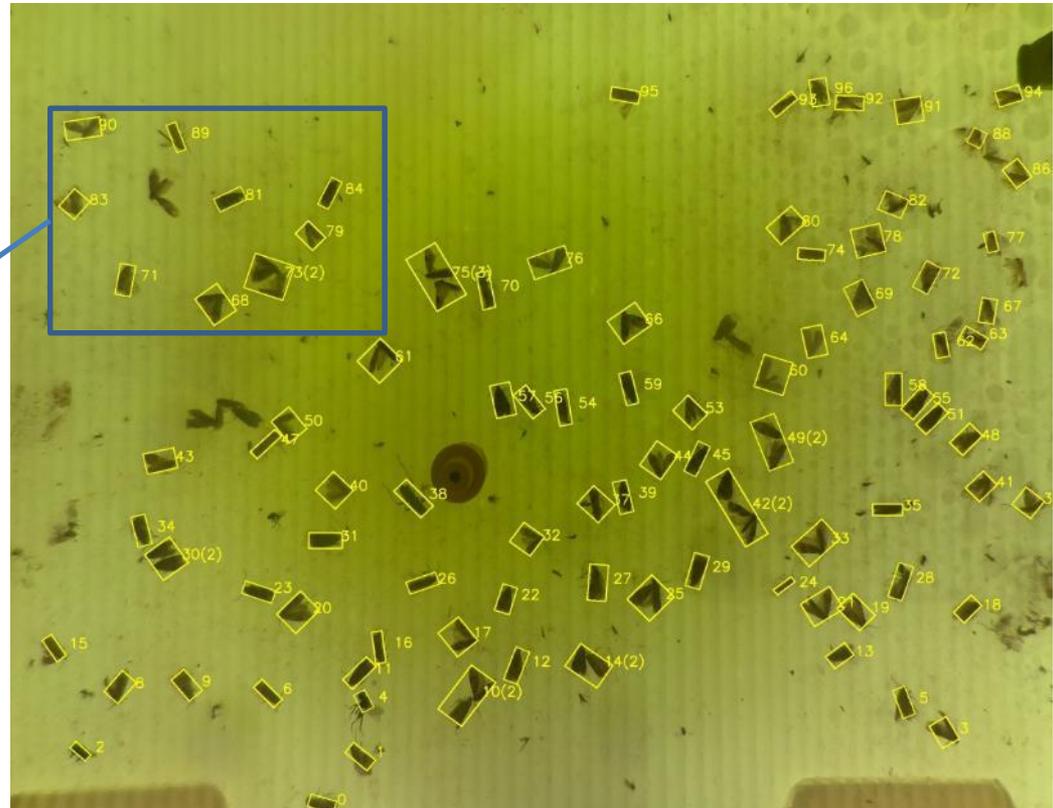
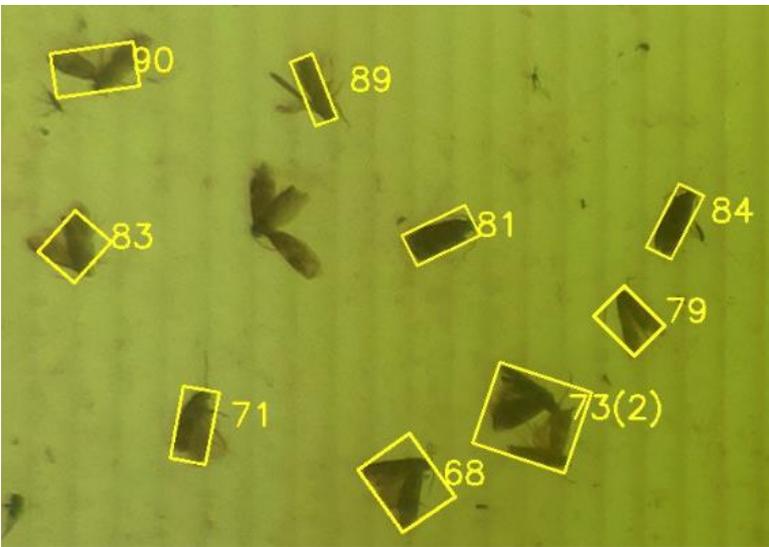
Fixed sensors (Pest monitoring)

- Intelligent insect trap
 - Self-contained communicating camera in a delta trap
 - Solar powered for continuous operation
 - Sensor developed by Cap2020 (Small Company)



Results

- Intelligent insect trap



Insects identification and counting on a yellow sticking sheet

Projet PixFel (2006-2012)

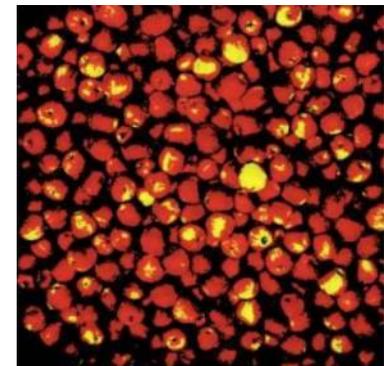
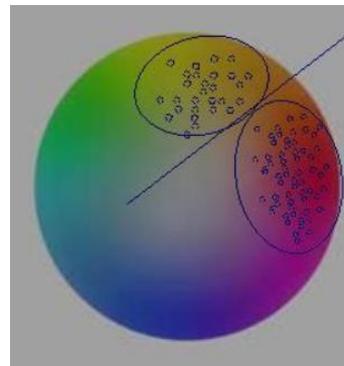


Outil d'agréage qualitatif de fruits en palox.

Dispositif d'acquisition



Mesure de diamètres



Classification couleur

Capteurs mobiles: applications

- Thématiques:
 - Vigne:
 - Segmentation/classification des organes
 - Détection des maladies
 - Rendement
 - Vigueur
 - Arboriculture fruitière
 - Pilotage de l'éclaircissage
 - Détection précoce des maladies

Imagerie couleur pour la détection et la caractérisation des maladies du bois de la vigne

Thèse de Florian RANCON 2019

Maladies du bois de la vigne (MBV)

Famille de plusieurs maladies fongiques s'attaquant au bois des ceps âgés de vigne :



- On parlera principalement de **l'esca**, majoritaire au champ.
- L'esca peut s'exprimer :
 - sous forme **lente** (symptômes foliaires¹)
 - sous forme **apoplectique**, pouvant aboutir en quelques jours à la mort du pied
- Impact économique considérable : remplacement des ceps malades ou morts, rajeunissement des vignobles (5% des pieds atteints en 2018)

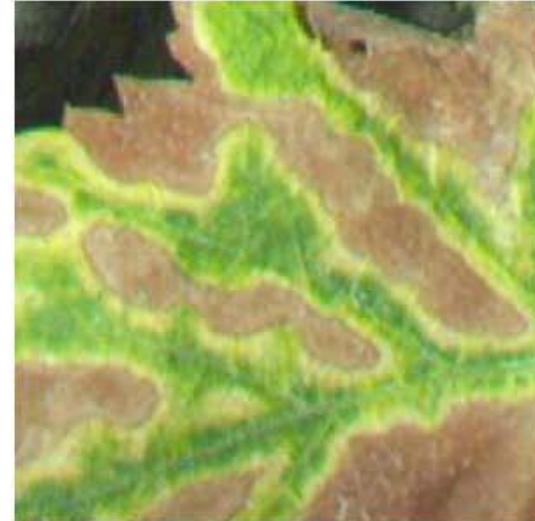
1. Lecomte et al. 2012, Plant Disease

Symptômes foliaires visibles

Décolorations variées le long des nervures, formant un motif tigré.



Cépage rouge



Cépage blanc

Forme typique permettant de distinguer les MBV

Symptômes foliaires visibles

Forte variabilité des symptômes :

- Selon le cépage, la parcelle et le terroir
- Selon le millésime et le moment de l'été

Les pieds atteints n'expriment pas nécessairement de symptômes l'été. Rareté relative des symptômes "cas d'école".



Motif atténué



Dessèchements



Forme BDA précoce²

2. Larignon et al. 2001, Phytoma

Facteurs confondants

Existence de nombreux symptômes plus ou moins similaires dus à :

- des stress **biotiques** (maladies fongiques, virales)
- des stress **abiotiques** (carences, sécheresse, chocs physiques)

Parfois une combinaison de plusieurs de ces facteurs.

Potentielle source de confusion aux symptômes des maladies du bois.

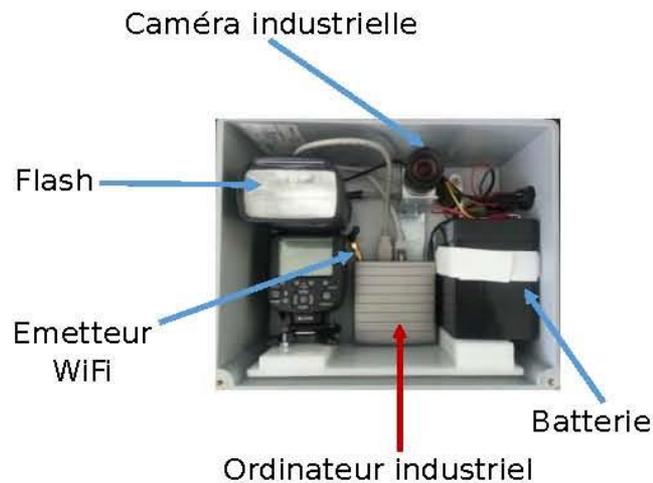


Objectifs

- Détecter les feuilles symptomatiques esca sur le pied de façon automatisée :
 - Extraire les caractéristiques visuelles du faciès esca sous forme de descripteurs
 - Différencier le faciès esca des autres symptômes
- Evaluer la qualité de la détection réalisée
- Proposer un indicateur d'atteinte à l'esca au pied

Campagne d'acquisition

Dispositif intégrant une caméra RVB embarquée sur un engin agricole.



Campagne d'acquisition

Acquisition d'environ 1200 images de pieds durant l'été 2017.
Parcelles identiques aux expérimentations en hyperspectral



Problème de classification

Recherche de la séparation optimale entre 3 classes :

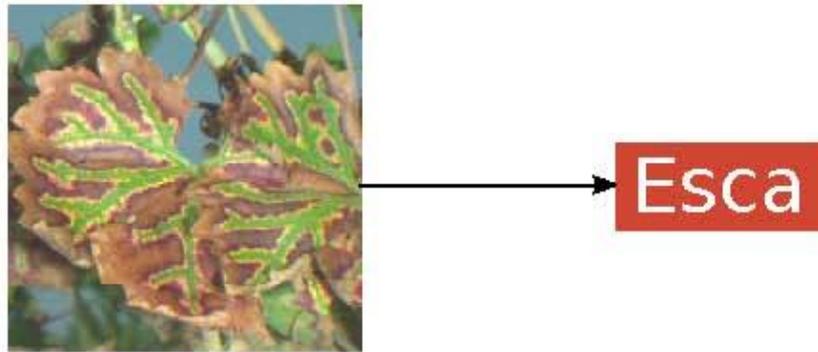
- Feuilles **saines** (*témoin*) 
- Feuilles **esca** (*classe d'intérêt*), 3 sous-classes :
 - Esca1 → Symptômes sévères 
 - Esca2 → Symptômes modérés 
 - Esca3 → Symptômes faibles 
- **Autres** symptômes (*facteurs confondants*) 

→ Notation des images d'apprentissage sous forme de rectangles (à l'échelle de la feuille) appartenant à l'une des 3 classes.

Méthodologie

Deux étapes successives :

- **Classification** de l'esca (imagettes de **feuilles**)

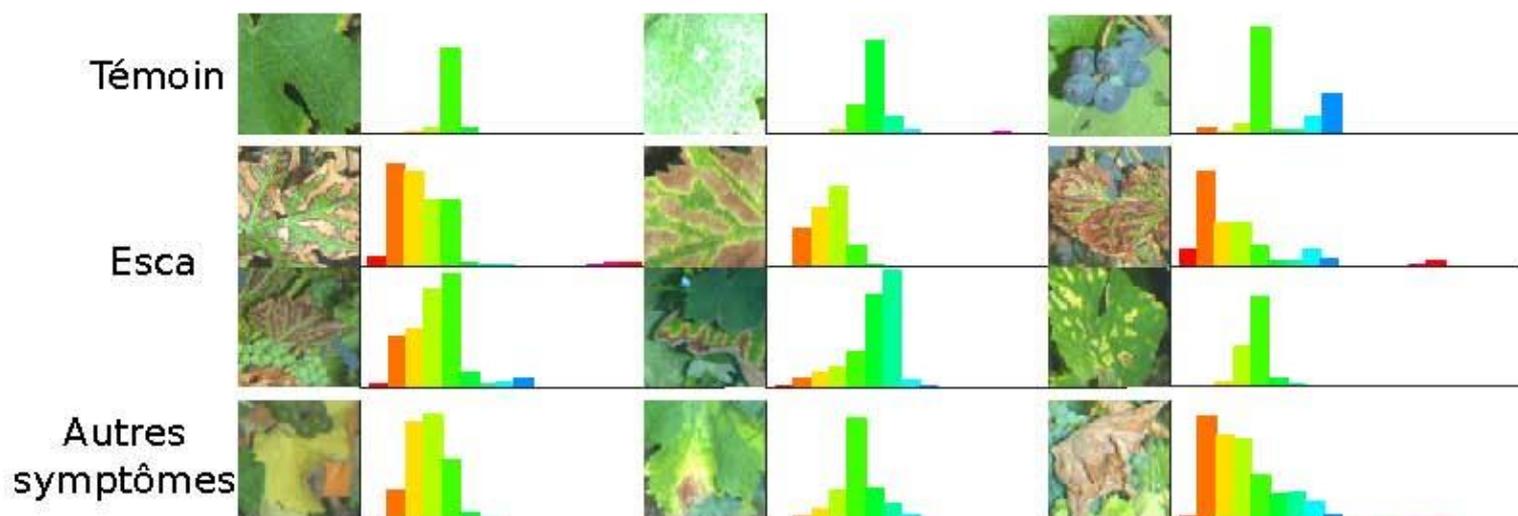


- **Détection** de l'esca (images du **ped**)



Limitations de l'information couleur seule

Teinte : Espace cyclique représentant la couleur. Histogrammes de teintes (16 compartiments)



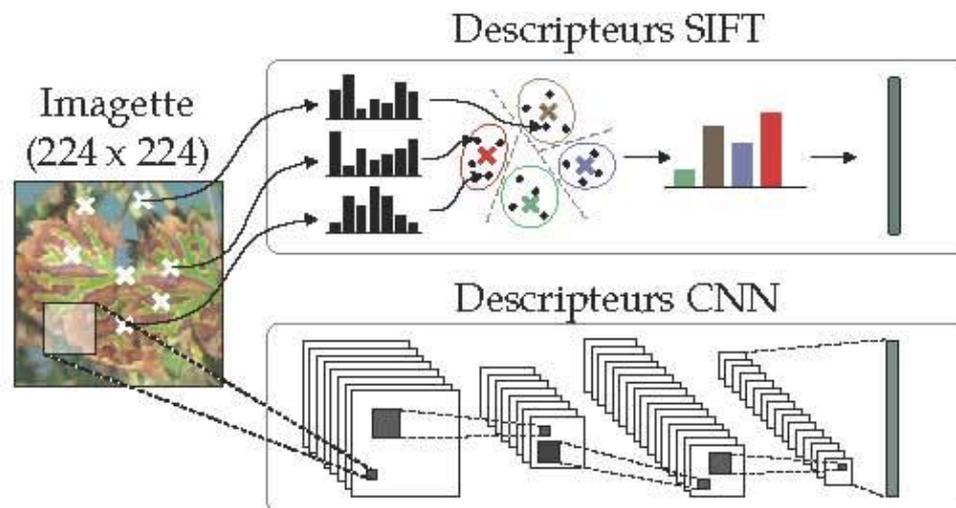
- Feuilles saines relativement simples à séparer des feuilles esca
- Facteurs confondants plus complexe

L'information spatiale est essentielle pour différencier les motifs

Méthodologie pour la classification

Comparaison entre deux méthodes d'extraction de descripteurs visuels à l'échelle de la feuille.

- Encodage de descripteurs SIFT locaux (gradients orientés)
- Sortie de réseau de neurones convolutif (CNN)

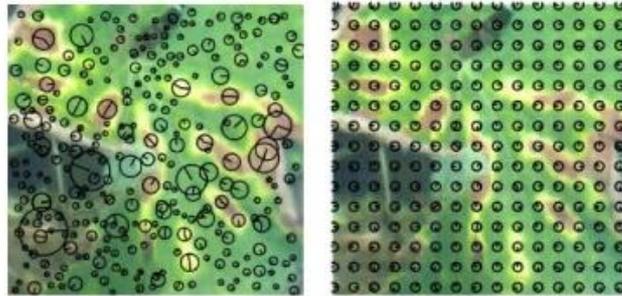


Méthodes dominantes de l'état de l'art sur les 20 dernières années

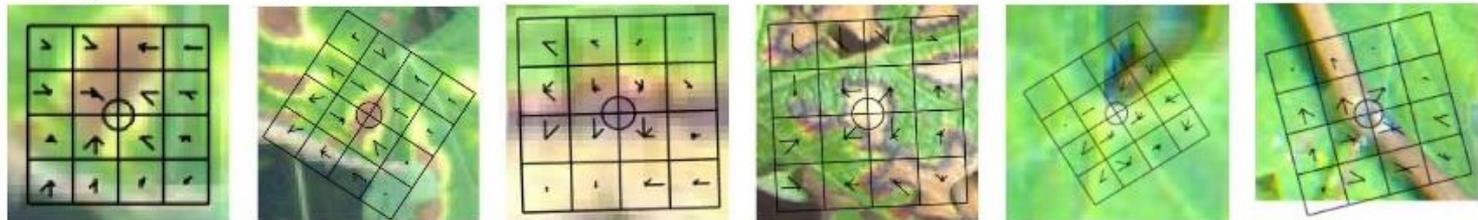
Méthode SIFT

Fonctionnement en deux étapes :

- **Détermination de points d'intérêt** : Détection par extrema sur pyramides de gaussiennes (*DoG*) ou grille régulière



- **Calcul des descripteurs locaux** (grille d'histogrammes orientés du gradient) autour des points d'intérêt.



Signature de l'image sous forme d'une liste de points remarquables invariants à l'échelle et la rotation.

Encodage dans l'espace des descripteurs

Description naturelle de la composition en descripteurs locaux dans l'image, prise en compte de la variabilité des images (tiges, bords, grappes).

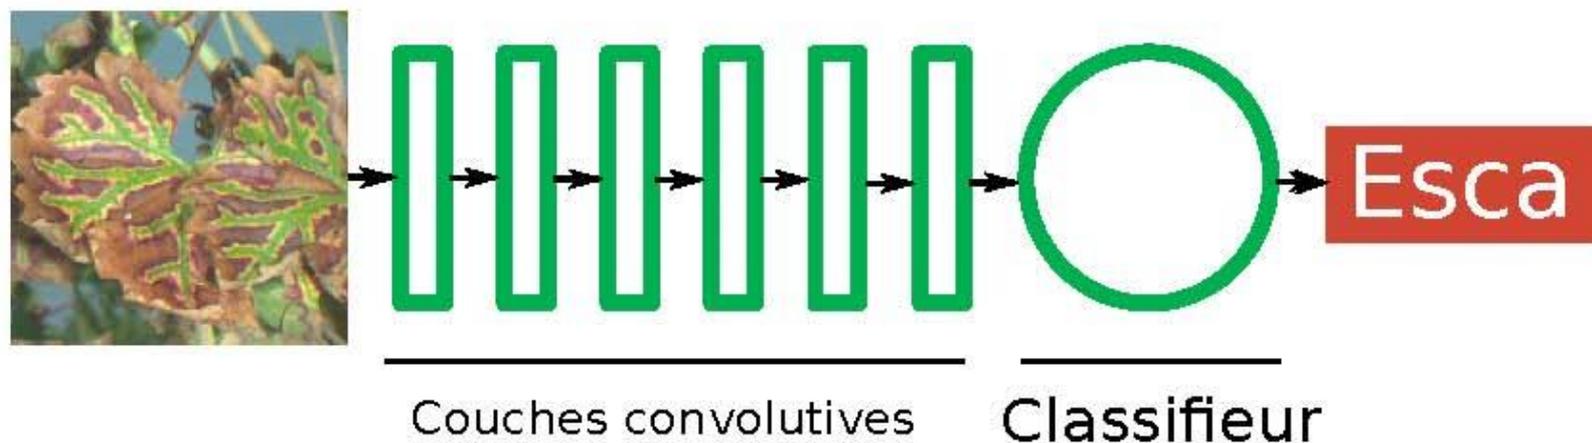
Utilisation d'algorithmes d'encodage :

- Sacs de mots (BoW)
- VLAD
- Vecteurs de Fisher

Approches graduellement plus complexes.

Approche *deep learning* : réseau convolutif

Un **réseau de neurones convolutif** (CNN) empile un ensemble de couches contenant des filtres convolutifs. Décomposition de l'image en un descripteur compact et informatif.



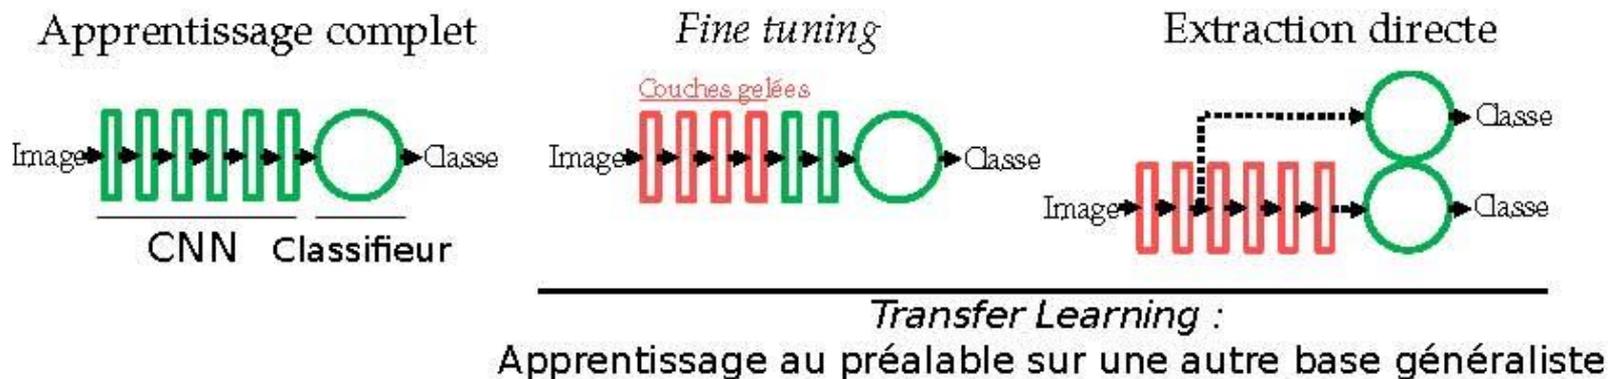
Choix du réseau **MobileNet** léger et modulable⁶.

6. Howard et al. 2017, Computing Research Repository

Apprentissage du réseau convolutif

Nécessité d'apprendre les poids des filtres convolutifs à partir d'une base de données.

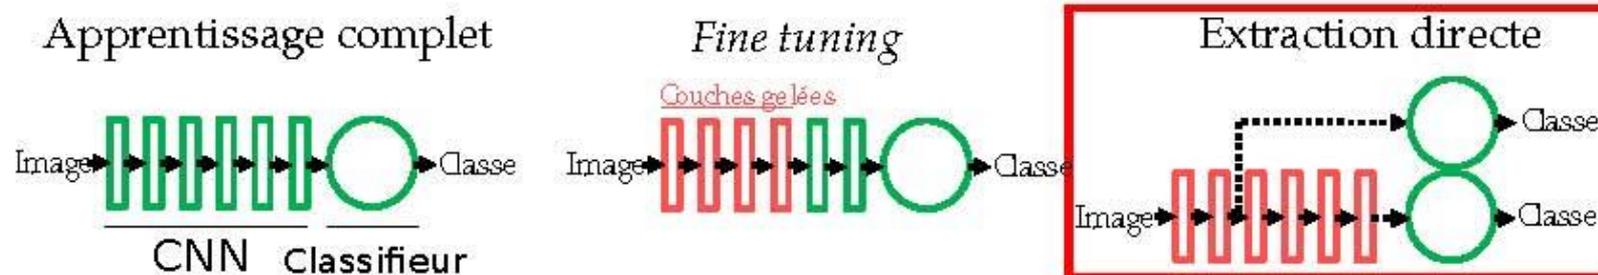
Trois approches usuelles pour apprendre un réseau convolutif :



Apprentissage du réseau convolutif

Choix motivé par les propriétés de la base.

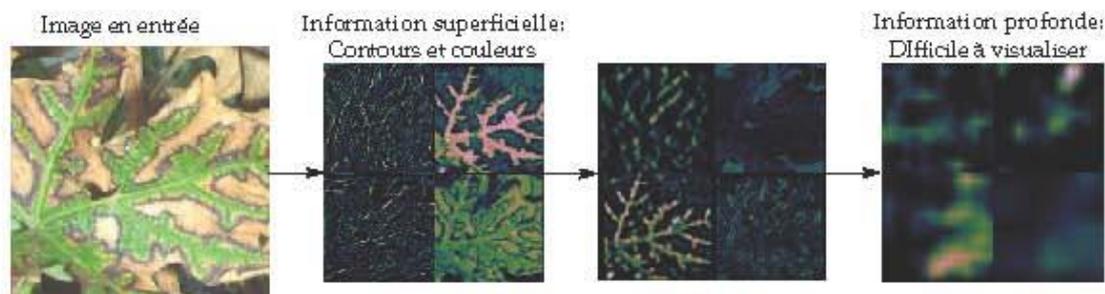
- Petite base de données (moins de 500 échantillons esca)
- Grande variabilité de motifs rencontrés



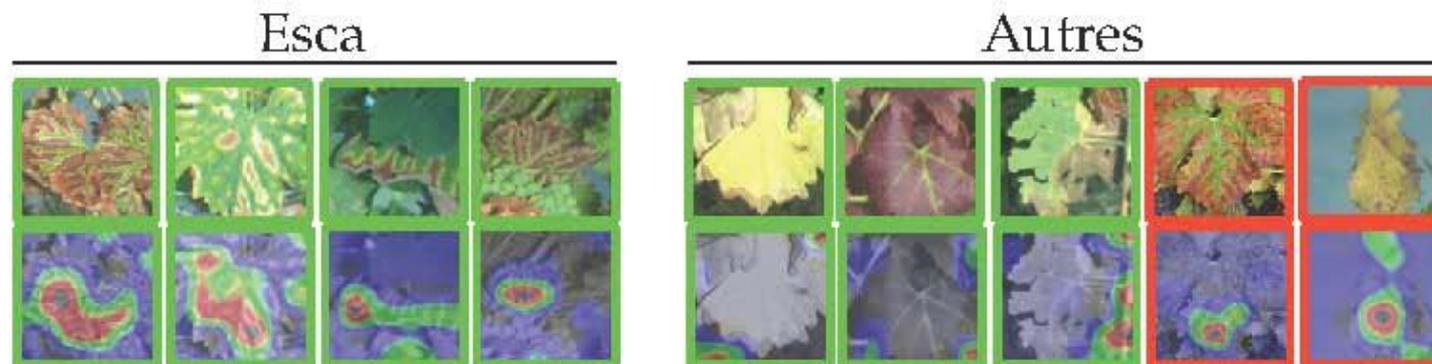
Choix de l'approche d'extraction directe de descripteurs par un réseau pré-entraîné (base ImageNet)

Visualisation du réseau convolutif

Visualisation directe parfois difficile



Adoption d'outils permettant de comprendre partiellement les bonnes et mauvaises décisions d'un réseau de neurones : **cartes d'attention**.



Résumé des performances

Utilisation du classifieur SVM noyau RBF pour tous les tests

Méthode	Précision de test			
	Globale	Esca1	Esca2	Esca3
Histogramme couleur	73.4	67.4	64.7	88.4
Grille d'histogrammes couleur	82.1	72.2	79	95.1
Encodage SIFT	89.5	86.4	92	99.1
Deep Learning	90.7	86.3	94.2	98.9

Ecart type moyen=1.4%

- Amélioration graduelle des performances, notamment pour les échantillons difficiles (esca1 et esca2)
- Difficultés à améliorer les performances au delà

Difficultés restantes

Décisions difficiles :

- Pour certains facteurs confondants similaire à l'esca (carences et sécheresses)
- Pour des feuilles très peu marquées par l'esca

Pas de prise en compte du contexte pour les imagettes de feuilles.

Imagette



Difficultés restantes

Décisions difficiles :

- Pour certains facteurs confondants similaire à l'esca (carences et sécheresses)
- Pour des feuilles très peu marquées par l'esca

Pas de prise en compte du contexte pour les imagerie de feuilles.

Imagette



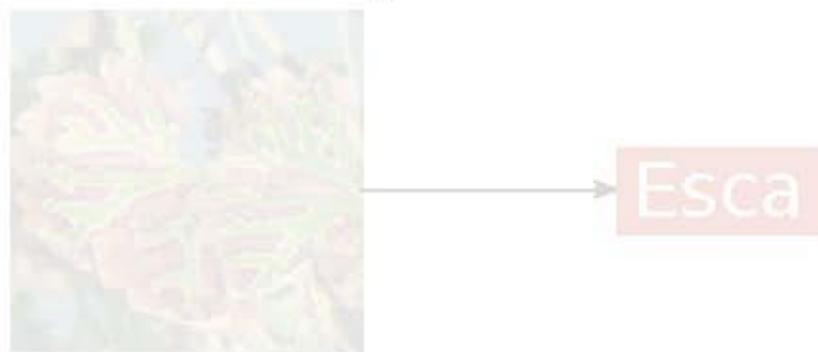
Contexte



Passage à l'étape de détection

Première étape de classification réalisée.

- **Classification de l'esca (imageries de feuilles)**

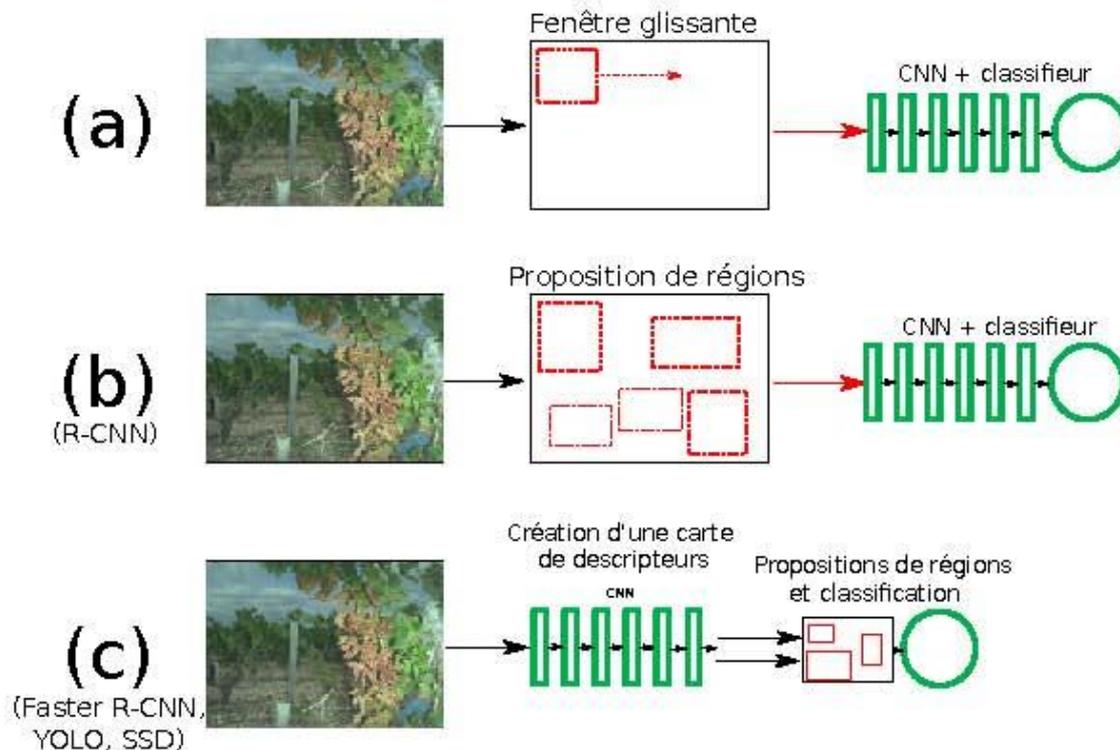


- **Détection de l'esca (images du pied)**



Choix de l'architecture

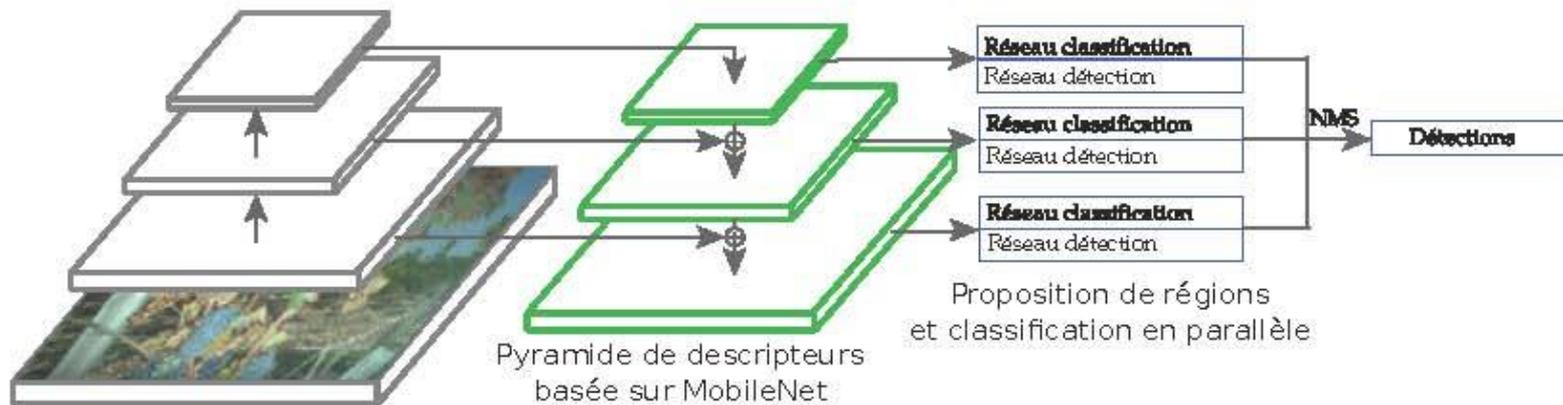
3 types d'architecture pour généraliser un réseau de classification en un réseau de détection :



Compromis entre performances et vitesse.

Création d'un réseau de détection de l'esca

Incorporation du réseau de classification *MobileNet* entraîné à l'intérieur du réseau de détection *RetinaNet*.



- Apprentissage partiel de l'architecture (gel des couches convolutives en amont).
- Apprentissage sur 20 *epochs* (itérations).

Résultats de détections - cas simples



Rectangles **rouges** : détections esca

Rectangles **orange** : détections autres symptômes

Résultats de détections - cas plus complexes



Exemples de détections - facteurs confondants



Présence d'une erreur de détection (faux positif)

Evaluation des résultats

Indicateurs rappel/précision globaux basés sur les correspondances entre **notation terrain** et **détections machine**, pour un seuil de confiance i donné :

$$\text{Rappel}_i = \frac{VP_i}{N} \quad (1)$$

$$\text{Precision}_i = \frac{VP_i}{VP_i + FP_i} \quad (2)$$

où VP_i = Nombre de vrais positifs pour le seuil de score i ,
 FP_i = Nombre de faux positifs pour le seuil de score i ,
 N le nombre total d'échantillons.

Influence de l'augmentation de données

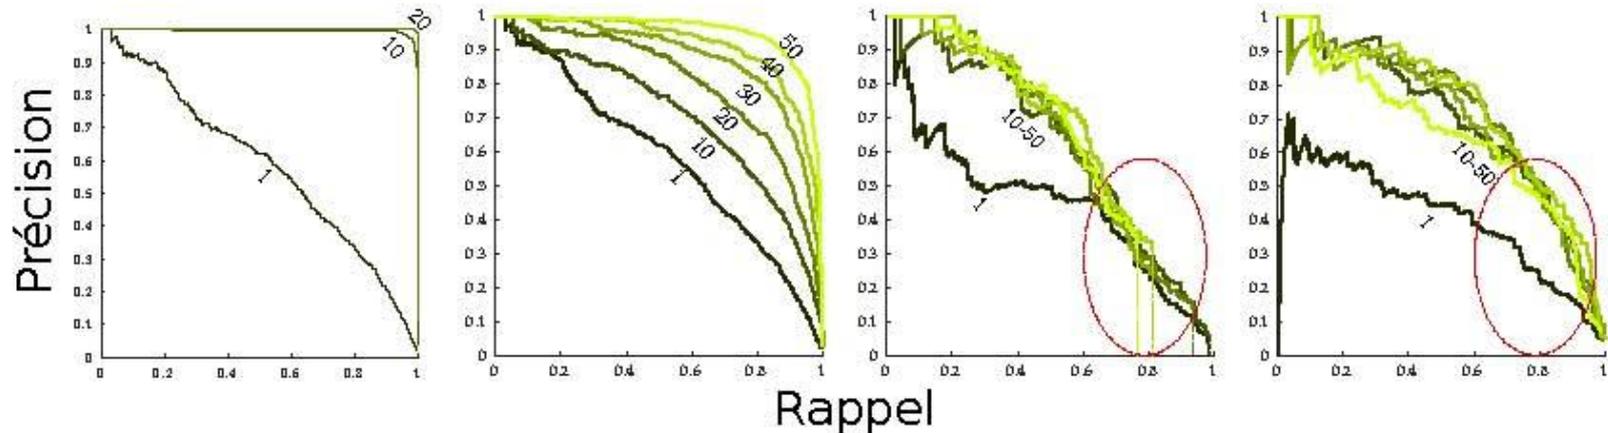
Augmentation : génération d'images supplémentaires à la volée par des transformations simples (rotations, déformations locales ,etc.)
On ne conserve que les transformations plausibles



Influence de l'augmentation de données

Base d'apprentissage

Base de test



Pas d'augmentation

Augmentation

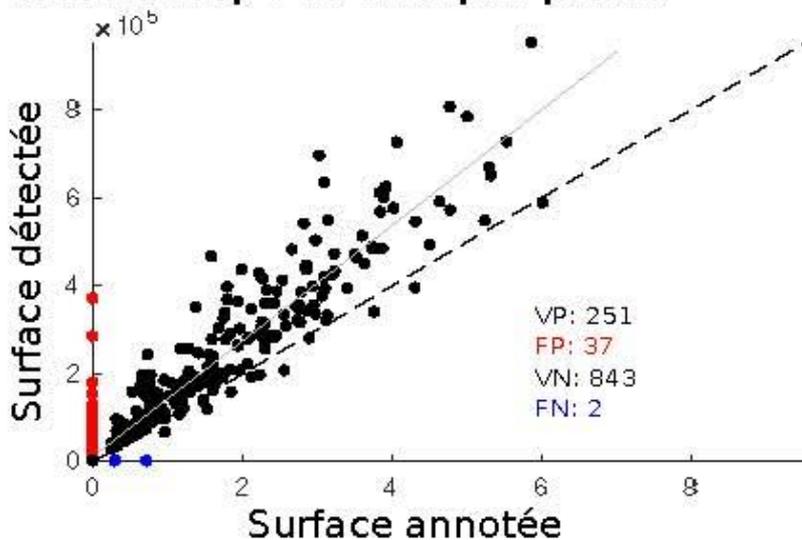
Pas d'augmentation

Augmentation

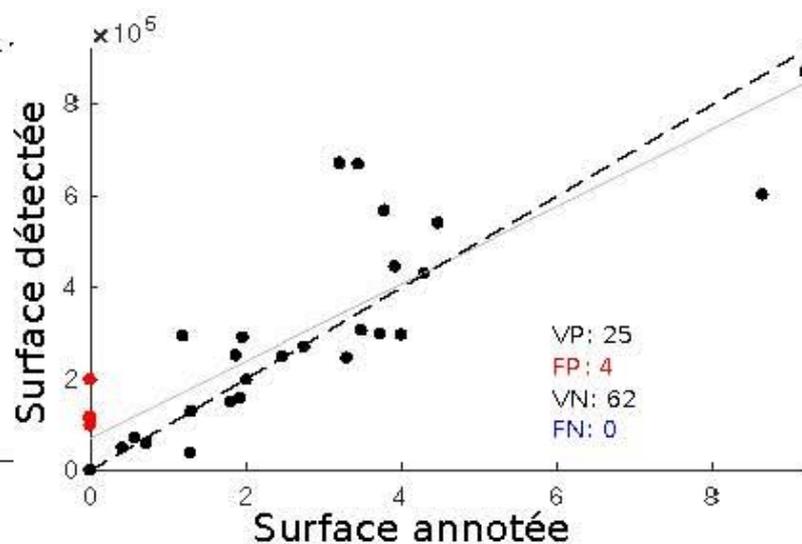
- Effet bénéfique de l'augmentation de données : limitation du surapprentissage.
- Stagnation des performances après la 20ème epoch.

Estimation de l'atteinte à l'esca

Nécessité d'un indicateur tenant compte de l'atteinte par pied.
Évaluation de la correspondance entre surface annotée et surface détectée pour chaque pied.



Base d'apprentissage



Base de test

Création d'une cartographie de l'atteinte à l'esca possible.

Capteurs mobiles: applications

- Thématiques:
 - Vigne:
 - Segmentation/classification des organes
 - Détection des maladies
 - Rendement
 - Vigueur
 - Arboriculture fruitière
 - Pilotage de l'éclaircissage
 - Détection précoce des maladies

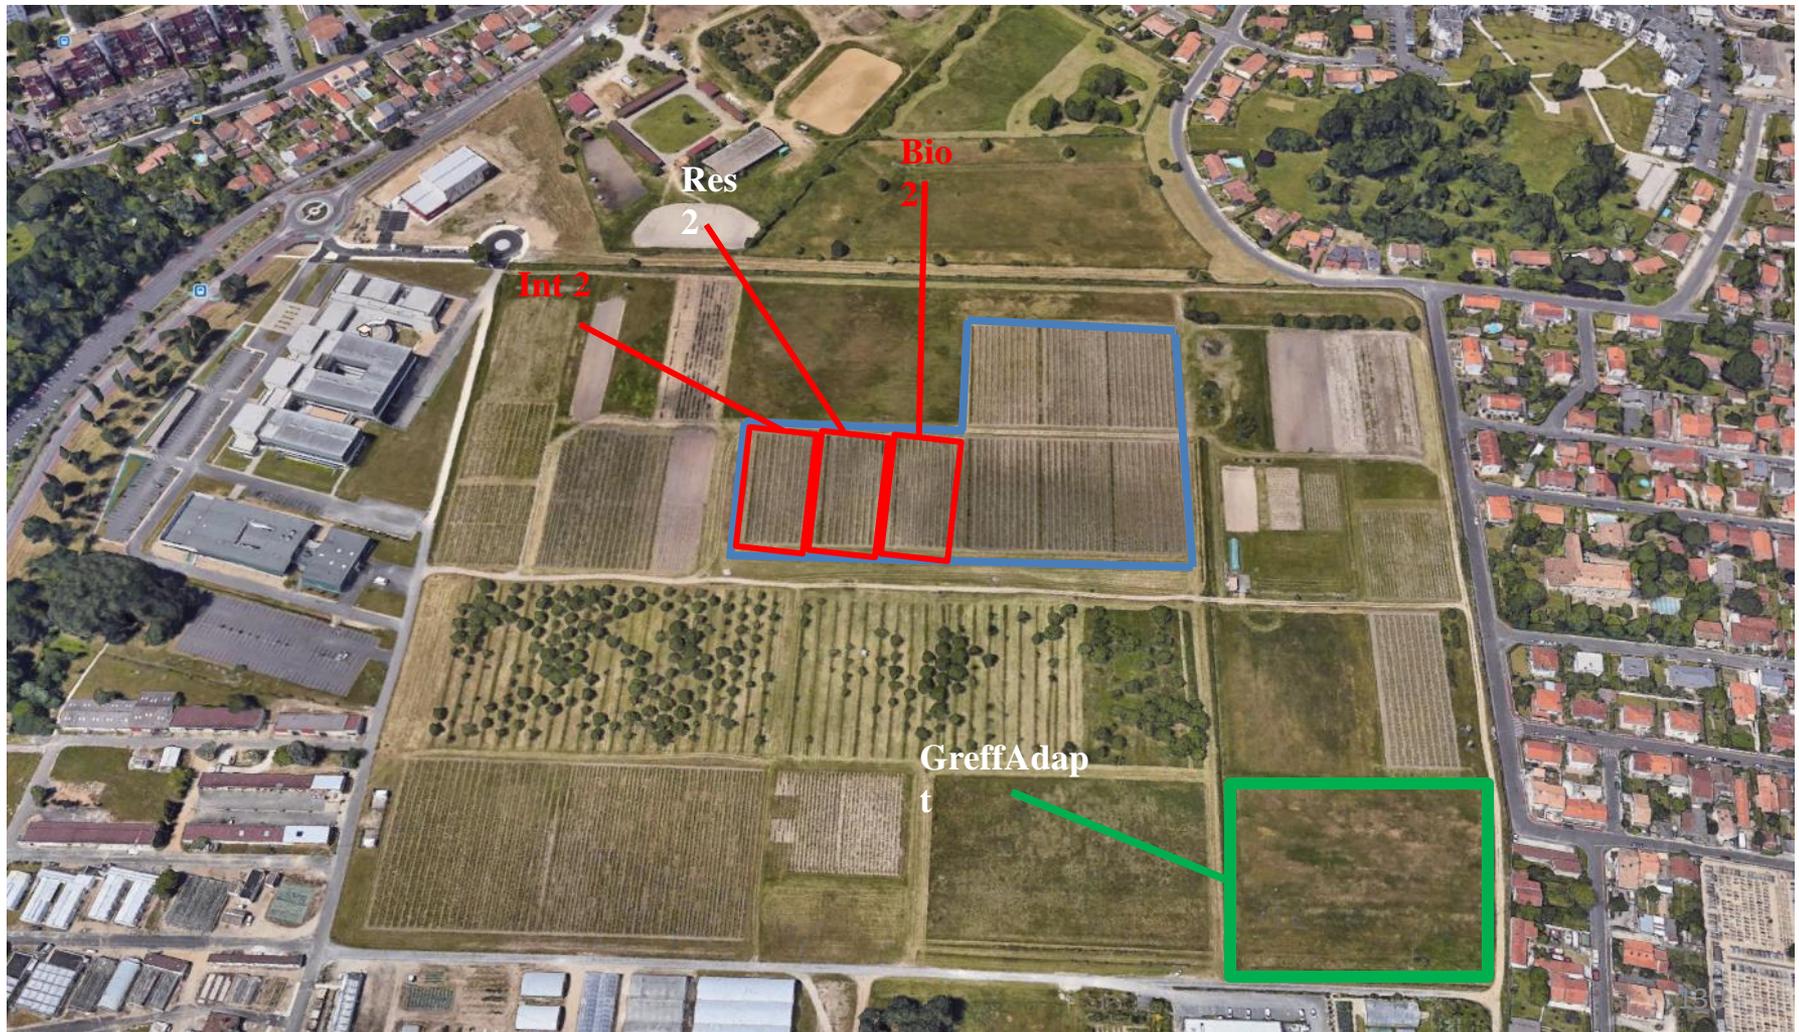
Modèles log-Euclidiens texture-couleur pour l'analyse du couvert végétal en proxidtection viticole

Thèse de Florent ABDELGHAFOR (fin 2019)

Objectif

- Etude des potentialités des systèmes d'imagerie embarquée quant à la reconnaissance et au suivi du mildiou
 - Proxidétection, dans le plan de palissage
 - Approche algorithmique texture / couleur
 - Evaluation de robustesse en conditions réelles
 - Transcription des attributs statistiques en indicateurs agronomiques

Expérimentation



Capteur / Vecteur



Bilan des acquisitions

– 60 000 images (**0.3 ha**)

– 2 saisons



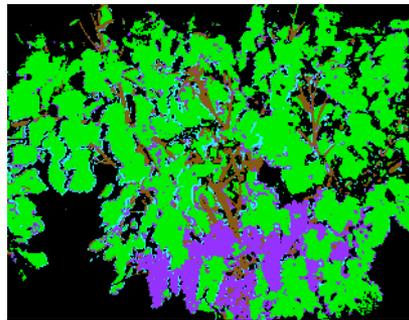
– 5 stades phénologiques clés

– **Mildiou**, Blackrot (et Oïdium)

– Sévérité symptômes variés



Classification Bayésienne & modélisation paramétrique



Chaine de traitement

Prétraitement (suppression de l'arrière plan) :
seuillage HSV

Calcul des descripteurs et modélisation

- Tenseur de structure étendu à la couleur
- Transformation dans l'espace log-Euclidien

Classification paramétrique pixelaire

- Modélisation paramétrique (PDF mvGauss)
- Estimation MAP bayésien

Régularisation spatiale

- Relaxation probabilistique (Markov ICM)
- Filtrage morphologique

Pré-traitement



Texture : tenseurs de structures (LST)

- Champs de gradients orientés de l'image I :

$$\vec{\nabla}I = [I_x, I_y]^t = [I * G_x, I * G_y]$$

- Estimation de la covariance du champ de Gradient $\vec{\nabla}I \vec{\nabla}I^t$:

$$Y = W_T * \vec{\nabla}I \vec{\nabla}I^t = W_T * \begin{bmatrix} I_x \cdot I_x & I_x \cdot I_y \\ I_x \cdot I_y & I_y \cdot I_y \end{bmatrix}$$

→ sur chaque site (i, j) , $Y(i, j)$ on a une matrice SPD 2×2
décrivant **la structure, les orientations locales, l'anisotropie et les contrastes**

Adapter les LST au problème

- ❖ Inclure l'information couleur au descripteur / modèle
- ❖ Représenter le descripteur dans l'espace de modélisation

- ❖ Approche LEEST (Log-euclidean Extended Structure Tensor)

$$\vec{V}_{I_{ce}} = [I_x, I_y, R, G, B]; \quad Y_{EST} = W_T * [\vec{V}_{I_{ce}} \vec{V}_{I_{ce}}]^t \quad (\text{Matrice SPD } 5 \times 5)$$

(De Luis-Garcia et al., 2008)

Dans l'espace log-euclidien : $Y_{LEEST} = \log_m(Y_{EST})$ (15 d vecteur)

$$Y_{CELEST} = [\log(\lambda_1), \log(\lambda_2), R', G', B'] \quad \text{Avec } [R', G', B'] = W_T * [R, G, B]$$

(5 d vecteur)

- ❖ Approche CELEST (Colour Extended Log-Euclidean Structure)

Classification bayésienne : MAP

On attribue à chaque pixel une classe λ_{opt} maximisant la probabilité *a posteriori* $p(\lambda | Y)$:

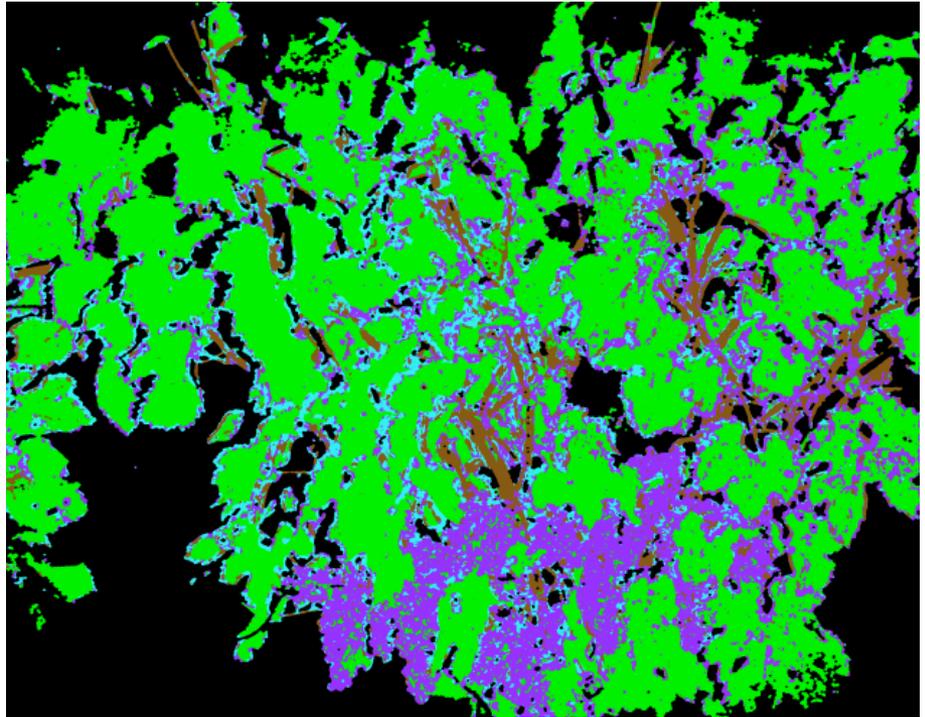
$$\lambda_{opt} = \arg \max_{\lambda \in \{1, \dots, L\}} p(\lambda | Y) = \arg \max_{\lambda \in \{1, \dots, L\}} f(Y|\lambda)p(\lambda)$$

Apprentissage {
Vraisemblance à la classe λ
Probabilité a priori de la classe λ
(variable en h)

Apprentissage

- Vraisemblances : Covariance(s) et barycentre(s) des modèles : PDF Gaussienne ou mélange
- Probabilités *a priori* proportions relatives des classes.

Résultats pour la cartographie des organes sains



Résultats de classification

MAP $\arg \max_{\lambda \in \{1, \dots, L\}} f(Y|\lambda)$ Comparaison des représentations

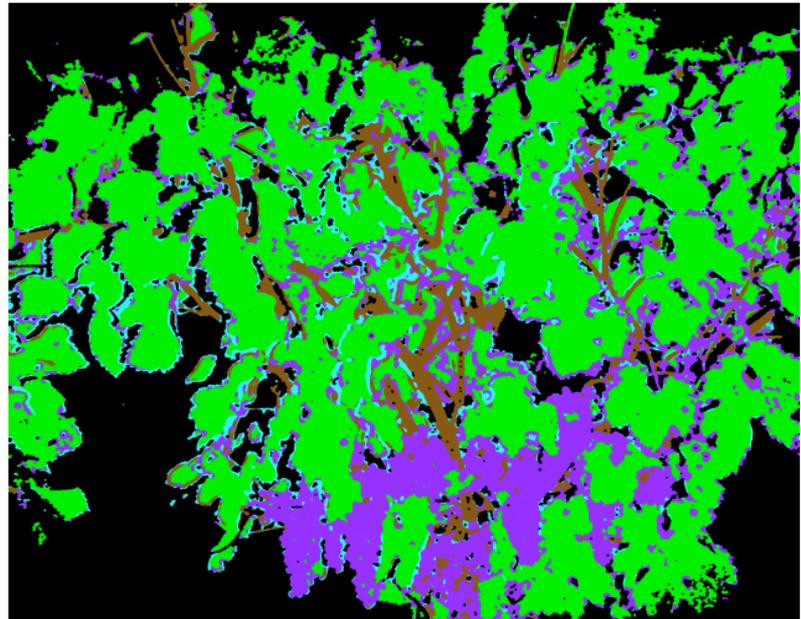
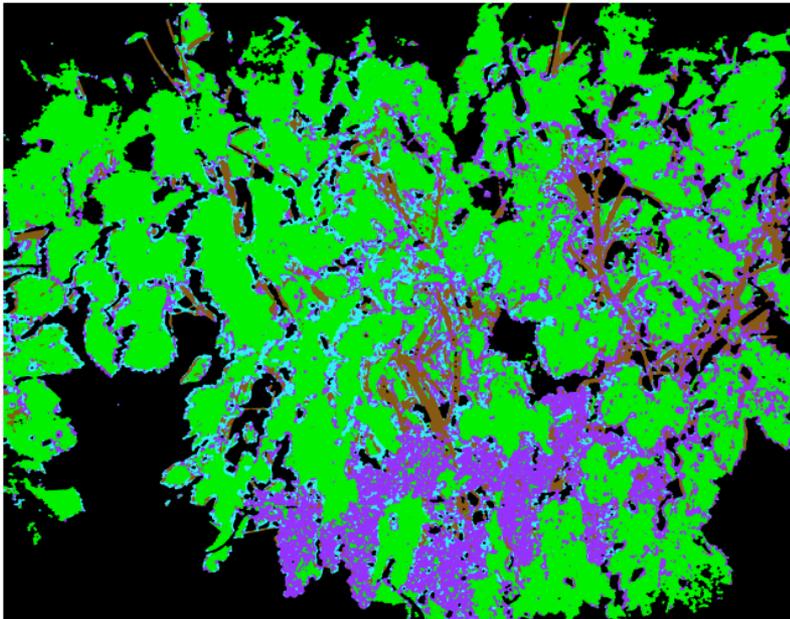
Representation	Precision					Recall				
	leaf	core	berries	stems	edges	leaf	core	berries	stems	edges
RGB	0.48	0.37	0.29	0.17		0.69	0.51	0.43	0.22	
LST	0.96	0.61	0.68	0.27		0.79	0.74	0.53	0.55	
LEEST	0.95	0.79	0.80	0.45		0.86	0.79	0.81	0.75	
CELEST	0.98	0.80	0.82	0.67		0.88	0.88	0.89	0.87	

Résultats de classification

Comparaison des méthodes de modélisation, décision, post-traitement

Representaion	Methods		Precision				Recall					
	Decision	PP	leaf	core	berries	stems	edges	leaf	core	berries	stems	edges
	mvG	∅	0.98	0.80	0.82	0.67	0.88	0.88	0.89	0.87		
	mvG + sprob	∅	0.94	0.88	0.89	0.82	0.95	0.89	0.86	0.76		
	mvG + sprob	ICM	0.97	0.85	0.86	0.77	0.94	0.90	0.89	0.90		
CELEST	mvGM	∅	0.98	0.83	0.87	0.75	0.90	0.91	0.92	0.86		
	mvGM + sprob	∅	0.94	0.89	0.95	0.86	0.96	0.92	0.86	0.73		
	mvGM+ sprob	ICM	0.91	0.94	0.95	0.81	0.97	0.93	0.84	0.93		
	mvGM + sprob	ICM + Morph	0.96	0.94	0.93	0.86	0.97	0.96	0.84	0.89		

Relaxation probabiliste : ICM



Application à la détection de symptômes de mildiou

❖ Modéliser les symptômes de mildiou:

- Moins abondants
- Plus disparates (répartition spatiale)
- Degré d'infestation variable
- Tailles et faciès variés (classe peu homogène)
- Facteurs confondants nombreux

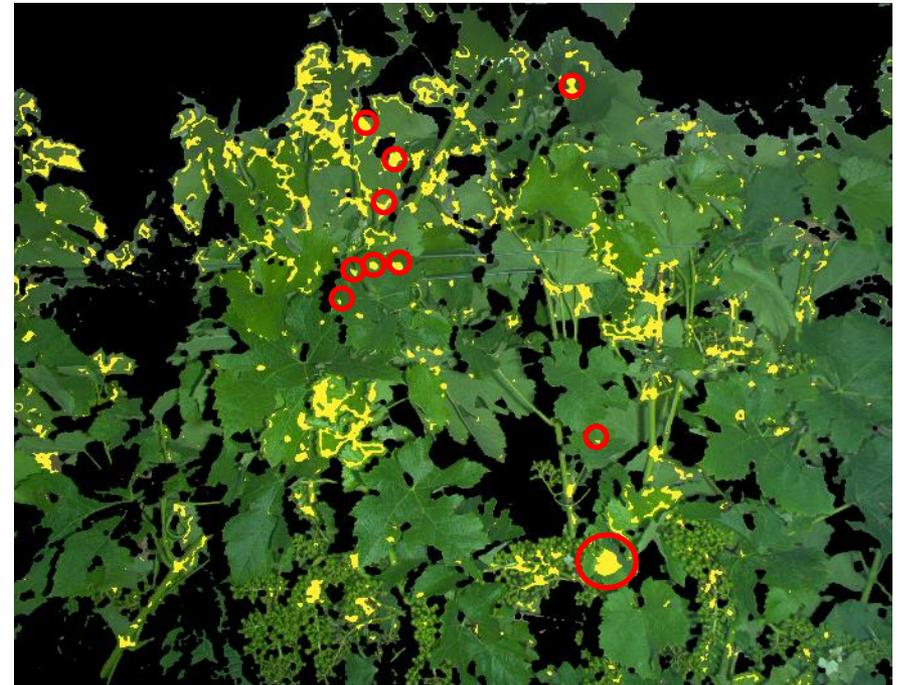


Classification des pixels vraisemblablement mildiou

$$p(\text{mildiou}) < 5\%$$



$$p(\text{mildiou}) = 1/K$$



Limiter les FP avec une classe de rejet

Cas 1: le descripteur Y n'est vraisemblable a aucune des classes

$$H_0: Y \sim \mathcal{N}(\mu_\lambda, \Sigma_\lambda); \quad \text{Sous } H_0 : d^2_{\text{mahal}}(Y, \mu_\lambda) \sim \chi^2(N)$$

=>: si $p(\chi^2 > d^2_{\text{mahal}}(Y_{\text{obs}}, \mu_\lambda)) < \alpha$
alors on rejette H_0 et Y_{obs} n'appartient pas à λ

Cas 2 : difficile de trancher entre 2 classes
i.e. Y_{obs} est aussi vraisemblable pour les 2 classes

$$H_0: \frac{d^2(Y, \mu_{\lambda_2})}{d^2(Y, \mu_{\lambda_1})} = 1; \quad \text{sous } H_0: \\ R_{\text{obs}} = \frac{d^2(Y, \mu_{\lambda_2})}{d^2(Y, \mu_{\lambda_1})} \sim F(N, N)$$

=> si $p(F > R_{\text{obs}}) < \alpha$
alors Y_{obs} est significativement plus proche de λ_1 que de λ_2

Si : $Y \sim \mathcal{N}(\mu, \Sigma)$:

$$f(Y|\lambda) = f(Y|\mu_\lambda, \Sigma_\lambda) \\ = \frac{1}{(2\pi)^{\frac{N}{2}} |\Sigma|^{\frac{1}{2}}} \exp\left[-\frac{1}{2} \underbrace{(Y - \mu)^t \Sigma^{-1} (Y - \mu)}_{d^2(\text{Mahalanobis})}\right]$$

Limiter les FP avec une classe de rejet

MAP

$\chi^2(0.05)$

$F(0.1)$

$F_{tige}(0.2)$



Capteurs mobiles: applications

- Thématiques:
 - Vigne
 - Segmentation/classification des organes
 - Détection des maladies
 - Rendement
 - Vigueur
 - Arboriculture fruitière
 - Pilotage de l'éclaircissage
 - Détection précoce des maladies

EARN

Estimation Automatique du Rendement de la vigne

Projet de maturation (fin 2017)



EARN: estimation de rendement

Rendement de la vigne :

- un paramètre déterminant de la qualité d'un vin
- conditionne en partie le revenu du viticulteur.

Connaissance précoce du rendement => pilotage de l'exploitation:

- optimisation des vendanges en vert,
- sélection parcellaire plus fine,
- planification plus fine des cuiviers,
- adaptation de la vinification selon le rendement parcellaire voire intra-parcellaire,

Inconvénients des méthodes existantes :

- Très couteuses en temps
- Taux d'erreurs importants (généralement entre 20% et 50%)

EARN: estimation de rendement

Un dispositif autonome d'analyse d'images intégrant :

- 1 caméra
- 1 flash
- 1 ordinateur industriel
- 1 batterie
- 1 antenne GPS
- 1 capteur ultra-son



Intelligence du capteur:

- Algorithme de détection des baies
- Extrapolation au rendement



Procédé et dispositifs protégés par une demande de FR étendue PCT

EARN: estimation de rendement

Algorithme de détection des baies:

- Permet d'obtenir, le nombre, la position et la taille de chaque baie détectée,
- de construire des groupes de baies (mais pas de retrouver les grappes!).



Extrapolation au rendement:

- Transformer le nombre de baies détectées en un rendement en tonne de raisin par parcelle.



$$\text{Rendement} = N_b \times L \times \alpha \times P_u$$

- N_b : les baies comptées par analyse d'image par mètre de rang de vigne,
- L : longueur cumulée des rangs de la parcelle,
- α : proportion de baies détectées par rapport aux total des baies présentes,
- P_u : poids moyen d'une baie.

L est connu.

N_b est fourni par le système de vision.

α et P_u doivent être estimés.

EARN: estimation de rendement

5 campagnes de mesures :

- du stade petit pois, à la veille des vendanges.

2 modalités de conduite:

- Vignes effeuillées
- Vignes non effeuillées

2 parcelles :

- 1 parcelle Merlot
- 1 parcelle Sauvignon



Mesures manuelles :

- pour chaque parcelle
 - Nb moyen de baies par grappe x 3 stades
 - Poids moyen des baies x 5 stades x 2 méthodes (200 baies)
- Pour chaque placettes (15 placettes de 4 ceps par parcelle)
 - Nb de grappes
 - Poids à la vendange



EARN: estimation de rendement

Coté effeuillé

Sur la parcelle de Merlot :

Date	Estimation	Rendement	Erreur
10/08 (véraison)	5435	4705	15%
9/09 (maturité)	5131		9%
30/09 (vendange)	4981		6%



Sur la parcelle de Sauvignon :

Date	Estimation	Rendement	Erreur
5/08 (véraison)	5651	5185	9%
27/08 (maturité)	4565		12%
3/09 (vendange)	5161		0,5%

Suivi complet => paramètre α calculé pour chaque parcelle et à chaque stade
 P_u : celui mesuré avant vendange

EARN: estimation de rendement

- Résultats globalement conformes aux attentes sur cotés effeuillé
 - Mais abandon du coté non effeuillé pour 2016
- Confirmation nécessaire en 2016 sur les mêmes parcelles
 - Ajouter d'autres parcelles moins homogènes
- Ajouter un cépage
 - Cabernet Sauvignon
- Trop de mesures de terrain couteuses pour l'étalonnage
 - Maintenir le dispositif de terrain 1 an de plus
 - Ajouter des parcelles sans suivi de terrain
- Envisager différentes stratégies pour estimer P_u

EARN: estimation de rendement

Protocole 2016

3 campagnes de mesures :

- de la fermeture de la grappe, à la veille des vendanges.

1 modalité de conduite :

- Vignes effeuillées

6 parcelles en suivi complet (+ 6 parcelles sans aucun suivi) :

- 2+2 parcelles Merlot
- 2+2 parcelles Cabernet Sauvignon
- 2+2 parcelles Sauvignon



Mesures de terrain :

- idem 2015 pour les parcelles en suivi complet
- rien pour les autres



EARN: estimation de rendement

Parcelle	Date	Rendement Estimé	Rendement réel	Erreur
Merlot 1	13/7	Pb capteur	7009	Panne GPS
	6/9	7794		-11.2%
	6/10	6835		2.5%
Merlot 2	18/7	9475	7209	-31.4%
	6/9	8317		-15.4%
	6/10	7090		1.6%
Sauvignon 1	19/7	7427	7898	6.0%
	Annulée	Annulée		Annulée
	12/9	Pb couleur		Pb couleur
Sauvignon 2	18/7	3632	5651	35.7%
	Annulée	Annulée		Annulée
	12/9	Pb couleur		Pb couleur
Cabernet Sauvignon 1	19/7	2911	3830	24.0%
	12/9	4442		-16.0%
	19/10	4119		-7.6%
Cabernet Sauvignon 2	25/7	3408	4203	18.9%
	12/9	3957		5.9%
	19/10	4122		1.9%

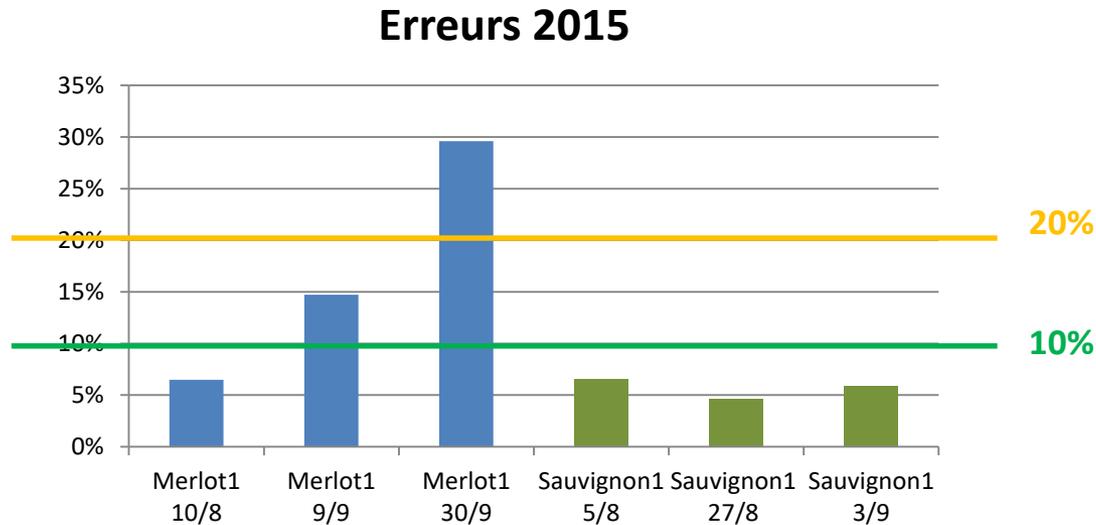
**Parcelles en suivi complet,
Coté effeuillé**

α : fixé à 6.5

pour toutes les parcelles
tous les cépages
et à tous les stades

P_u : celui mesuré avant
vendange

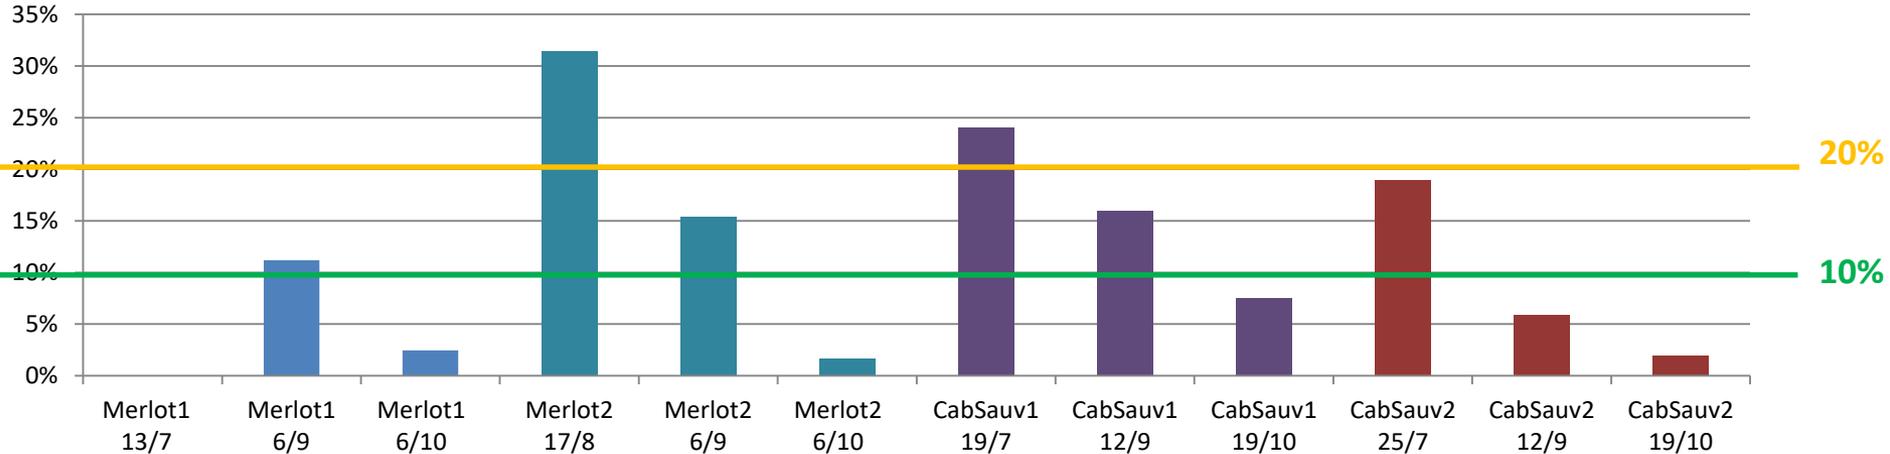
EARN: estimation de rendement



Coté effeuillé, sur les parcelles en suivi complet avec un paramètre α constant ($\alpha = 6.5$)

EARN: estimation de rendement

Erreurs 2016



Sur les parcelles (cépages rouge) en suivi complet avec un paramètre α constant ($\alpha = 6.5$)

EARN: estimation de rendement

- Améliorer l'éclairage
 - Pour réduire l'impact de l'anti-botrytis
- Améliorer les algorithmes
 - Détection des baies
 - Stratégie de choix de α et de P_u
- Mieux maîtriser la variabilité
 - Une année de plus sur les parcelles 2016 (variabilité temporelle)
 - Des parcelles avec effeuillage manuel (vérifier l'influence de ce facteur)
 - Exploiter les données 2016 des parcelles sans suivi

CONCLUSION

Perspectives et sujets émergents

Conclusion / Perspectives

- Questions méthodologiques
 - Bouleversement Deep Learning... mais beaucoup reste à faire
- Télédétection
 - Satellites Sentinel: gratuité + séries temporelles
 - Fusion de données multisource (Optique + Radar ...)
- Proxidétection
 - Nouveaux vecteurs (robots)
 - Du Cloud à l'Edge computing
 - Fusion de données fixes et mobiles
- Applications
 - Des maladies difficiles à diagnostiquer
 - Des grandes surfaces à traiter
 - De nouveaux enjeux (désherbage)

Quelques références sur ces travaux

- Champion I., Germain Ch., Da Costa JP., Alborini A., Dubois-Fernandez P., "Retrieval of forest stand age from SAR image texture for varying distance and orientation values of the Grey Level Co-occurrence Matrix", IEEE Geosciences and Remote Sensing Letters, Vol.11, Issue 1, Pages 5-9, Jan. 2014.
- Regniers O., Bombrun L., Germain Ch., "Modélisation de texture basée sur les ondelettes pour la détection de parcelles viticoles à partir d'images Pléiades panchromatiques", Revue Française de Photogrammétrie et de Télédétection, Vol.208, pp.111-116, Nov. 2014.
- Regniers, O., Bombrun, L., Guyon, D., Samalens, J.C., Germain Ch., "Wavelet-based texture features for the classification of age classes in a maritime Pine forest", IEEE Geoscience and Remote Sensing Letters, Vol.12(3), pp. 621-625, Mar. 2015.
- Regniers O., Bombrun L., Lafon, V., Germain Ch., "Supervised classification of Very High Resolution optical images using wavelet-based textural features", IEEE Trans. on Geoscience and Remote Sensing, Vol.54(6), pages 3722 - 3735, 2016.
- Xia J., Bombrun L., Tulay Adali T., Berthoumieu Y., and Germain Ch., "Spectral-Spatial Classification of Hyperspectral Images using ICA and Edge Preserving Filter via an Ensemble Strategy", IEEE Trans. on Geoscience and Remote Sensing, Vol.54(8), pages 4971-4982, Aug. 2016.
- Ilea I., Bombrun L., Terebes R., Borda., Germain Ch., "An M-estimator for Robust Centroid Estimation on the Manifold of Covariance Matrices", IEEE Signal Processing Letters, Vol.23(9), pages 1255-1259, Sept. 2016
- Rançon F., Bombrun L., Keresztes B., Germain Ch.. "Spatial pattern analysis of flavescence dorée repartition in vineyards from the Bordeaux region", Journal of Agricultural Informatics, 8 (2), pp.1-11, 2017.
- Xia J, Bombrun L, Berthoumieu Y., Germain Ch., Du P., "Spectral-Spatial Rotation Forest for Hyperspectral Image Classification", IEEE JSTAR, Vol.10(10), pp.4605-4613, oct. 2017.
- M. Nouri, N. Gorretta, P. Vaysse, M. Giraud, Ch. Germain, B. Keresztes, J-M Roger; "Near Infra Red Hyperspectral Data Set of Healthy and Infected Apple Tree Leaves Images for the Early Detection of Apple Scab Disease"; Data in Brief journal, Vol. 16, pp.967-971, Juin 2018.
- R. Terebes, R. Malutan, M. Borda, Ch. Germain, L. Bombrun, I. Ilea ; "Polarimetric Radar Image Classification using Directional Diffusion and Descriptive Statistics", Revue Roumaine des Sciences Techniques, série Électrotechnique et Énergétique, Vol. 63(1), pp. 83-88, 2018.
- Akodad S., Bombrun L., Yaacoub C., Berthoumieu Y. and Germain Ch., "Image classification based on log-Euclidean Fisher Vectors for covariance matrix descriptors", Proc. Of I`TA 2019, Xi'an, Chine, Dec. 2018.
- Rançon F., Bombrun L., Keresztes B., Germain Ch; "Comparison of SIFT encoded and Deep Learning features for the classification and detection of esca disease in Bordeaux vineyards", Remote sensing journal, vol.11(1), pp. 1-26, Janv. 2019
- Abdelghafour F., Rosu R., Keresztes B., Germain Ch., Da Costa J.P. "A Bayesian framework for joint structure and colour based pixel-wise classification of grapevine proximal images, Computer and Electronic in Agriculture, Vol. 158, pp. 345-357, Mars 2019.



**BORDEAUX
SCIENCES
AGRO**

Analyse d'images agricoles: Télédétection et imagerie embarquée

Christian GERMAIN
Professeur à Bordeaux Sciences Agro
Laboratoire IMS
(CNRS / Univ. Bordeaux / Bordeaux INP)
Groupe Signal & Image

