



**HAL**  
open science

# Optimisation de la configuration d'un instrument superspectral aéroporté pour la classification : application au milieu urbain

Arnaud Le Bris

► **To cite this version:**

Arnaud Le Bris. Optimisation de la configuration d'un instrument superspectral aéroporté pour la classification : application au milieu urbain. Traitement du signal et de l'image [eess.SP]. Université Paris-Est, 2015. Français. NNT : 2015PESC1182 . tel-01355186

**HAL Id: tel-01355186**

**<https://theses.hal.science/tel-01355186>**

Submitted on 22 Aug 2016

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Thèse présentée pour obtenir le grade de docteur  
de l'UNIVERSITÉ PARIS-EST  
École Doctorale MSTIC

-  
Spécialité : Sciences de l'Information Géographique

Arnaud LE BRIS

**Optimisation de la configuration d'un  
instrument hyperspectral aéroporté pour  
la classification**  
-  
**Application au milieu urbain**

*Soutenue le 07/12/2015*

Composition du jury :

Paul HONEINE  
Audrey MINGHELLI-ROMAN  
Christiane WEBER  
Mathieu FAUVEL  
Sandrine MATHIEU  
Xavier BRIOTTET  
Nicolas PAPARODITIS  
Nesrine CHEHATA

Président  
Rapporteuse  
Rapporteuse  
Examinateur  
Examinatrice  
Directeur  
Directeur  
Encadrante





*Ce travail s'est déroulé au laboratoire **MATIS**  
(Méthodes d'Analyses pour le Traitement d'Images et la Stéréorestitution)  
du Service de la Recherche en Sciences de l'Information Géographique  
de l'**Institut National de l'Information Géographique et Forestière (IGN)**,  
en codirection avec l'**ONERA**.*

Laboratoire MATIS  
Service de la Recherche en Sciences de l'Information Géographique  
Institut National de l'Information Géographique et Forestière  
73 Avenue de Paris  
94165 Saint-Mandé cedex - FRANCE  
  
Téléphone : 01 43 98 80 00

```
@PhdThesis{LeBris2015,  
  author = {Le Bris, Arnaud},  
  title = {Optimisation de la configuration d'un instrument  
    superspectral a\l'eroport\l'e pour la classification -  
    application au milieu urbain},  
  school = {{U}niversit\l'e {P}aris-{E}st},  
  year = {2015},  
  month = dec,  
  address = {{I}nstitut {N}ational de l'{I}nformation {G}\l'eographique  
    et {F}oresti\l'ere ({IGN}), laboratoire {MATIS},  
    73 Avenue de Paris, 94165 {S}aint {M}and\l'e} {CEDEX}, {F}rance}}  
}
```



## Optimisation de la configuration d'un instrument hyperspectral aéroporté pour la classification : application au milieu urbain

**Résumé :** Ce travail s'inscrit dans la perspective de l'enrichissement des bases de données d'occupation du sol. La description de l'occupation du sol permet en effet de produire un certain nombre d'indicateurs environnementaux pour la gestion des écosystèmes et des territoires, en réponse à différents besoins sociétaux, réglementaires et scientifiques. Aussi, différentes bases de données décrivant l'occupation du sol existent à différents niveaux (mondial, européen, national, régional ou local) ou sont en cours de constitution. Ainsi, l'IGN a entrepris la production d'une base de données d'occupation du sol à grande échelle. Il est toutefois apparu que, dans les zones urbaines, la connaissance de l'occupation du sol nécessaire pour certaines applications de modélisation de la ville (simulateurs de micro-météorologie, d'hydrologie, ou de suivi de pollutions), voire de suivi réglementaire (imperméabilisation des sols) doit être plus fine (tant au niveau sémantique qu'au niveau spatial) que ce que doit contenir cette base de données. Ainsi, la modélisation fine du milieu urbain nécessite pour certaines applications une connaissance géospatiale des matériaux en présence, autrement dit des cartes de matériaux. De telles cartes viendraient alors constituer une couche supplémentaire, à la fois dans des bases de données sur l'occupation du sol (comme par exemple l'occupation du sol à grande échelle de l'IGN) et dans des maquettes urbaines 3D.

Aucune base de données existante ne contient actuellement cette information de cartographie des matériaux en présence. Aussi, la télédétection apparaît comme la seule solution permettant de la produire. Néanmoins, du fait de la forte hétérogénéité des matériaux en présence, de leur importante variabilité, mais aussi des fortes ressemblances entre classes distinctes, il apparaît que les capteurs optiques multispectraux "classiques" (ne comportant que les 4 canaux rouge - vert - bleu - proche infrarouge) ne sont pas suffisants pour assurer une bonne discrimination des matériaux. Un capteur hyperspectral, c'est-à-dire plus riche spectralement, pourrait donc apporter une solution à cette limite. Ce travail s'est donc positionné dans l'optique de la conception d'un tel capteur et a consisté à identifier la meilleure configuration spectrale pour la classification des matériaux urbains, ou du moins à proposer des solutions s'en approchant. Autrement dit, un travail d'optimisation spectrale a été réalisé de manière à optimiser à la fois la position des bandes dans le spectre ainsi que leur largeur. Pour ce faire, des méthodes de sélection automatique d'attributs ont été mises en œuvre. Le travail s'est donc déroulé en deux étapes distinctes.

Une première tâche a consisté à définir et préciser les méthodes d'optimisation de bandes, et à les valider sur des jeux de données de référence de la littérature. Deux heuristiques d'optimisation classiques ont été choisies du fait de leur généralité et de leur flexibilité, et donc de leur capacité à être utilisées en association avec différents critères de sélection d'attributs. Il s'agissait d'une part de l'algorithme Sequential Forward Floating Search, méthode incrémentale utilisée ici pour étudier l'impact du nombre de bandes sélectionnées sur la qualité de la classification, et d'autre part d'un algorithme génétique, méthode stochastique permettant d'explorer plusieurs solutions proches de la solution optimale. Un travail a alors été mené afin de définir une mesure de la pertinence d'un jeu de bandes, c'est-à-dire le score à optimiser lors du processus de sélection de bandes. Une comparaison de différents scores possibles a alors été effectuée. Plusieurs critères ont été pris en compte pour les comparer. Ces scores devaient conduire à des jeux de bandes les plus discriminants possible, et ceci de manière indépendante d'un classifieur particulier. Les solutions proposées devaient donc

être discriminantes pour la plupart des classifieurs et non simplement au sens du critère de sélection d'attributs utilisé. Il a également été tenu compte de leur parcimonie, à savoir leur capacité à obtenir les meilleurs résultats avec le moins de bandes possible. Par ailleurs, la stabilité des solutions proposées a aussi été prise en compte de manière qualitative par l'étude de profils d'importance des bandes générés à partir des résultats intermédiaires de l'algorithme génétique.

Les meilleurs scores identifiés sont d'une part un score de type filtre avec la distance de Jeffries-Matusita, et d'autre part deux scores de type *wrapper* associés au classifieur des Forêts Aléatoires et prenant en compte la confiance avec laquelle le classifieur labellise les échantillons, autrement dit des scores *wrapper* ne se limitant pas à de simples taux de bonne classification.

L'optimisation de la largeur des bandes a ensuite été étudiée : la méthode proposée consiste à utiliser une hiérarchie de bandes fusionnées en fonction de leur similarité. Cette stratégie permet de contrôler la croissance de la largeur des bandes, en ne basant pas tout le processus sur le critère de sélection de bande, mais en intégrant également des contraintes sur la similarité entre bandes par le biais d'un critère de fusion. On commence donc par construire une hiérarchie de bandes fusionnées, en fusionnant de proche en proche les bandes adjacentes selon un critère. Trois de ces critères ont été testés, visant à fusionner les bandes en considérant leur corrélation, leur contribution à la séparabilité entre les classes, ou leur impact sur la forme du spectre. La sélection de bandes fusionnées se déroule ensuite au sein de la hiérarchie de configurations spectrales produite.

La seconde partie du travail a consisté en l'application de ces algorithmes d'optimisation spectrale au cas d'étude des matériaux urbains.

Une collection de spectres de matériaux urbains a d'abord été réunie à partir de différentes bibliothèques spectrales (ASTER, MEMOIRES, ...). L'optimisation spectrale a ensuite été menée à partir de ce jeu de données. Il est apparu qu'un nombre limité (environ 10) de bandes bien choisies suffisait pour discriminer 9 classes de matériaux communs (à savoir ardoise - asphalte - ciment - gravier - métal - pavés en pierre - shingle - terre - tuile). L'apport de bandes issues du domaine de l'infrarouge onde courte (1400 - 2500 nm) pour la discrimination des matériaux a également été vérifié. La portée des résultats chiffrés obtenus en termes de confusions entre les matériaux reste toutefois à nuancer du fait de la très faible représentation de certains matériaux dans la bibliothèque de spectres collectés, ne couvrant donc pas la totalité de leur variabilité.

**Mots-clés :** Optimisation spectrale - Sélection d'attributs - Multispectral - Superspectral - Hyperspectral - Milieu urbain - Matériaux urbains - Occupation du sol - Carte de matériaux - Classification - Télédétection

# Spectral optimization to design an airborne superspectral sensor dedicated to land cover classification : application to urban areas

**Abstract:** This work was performed in the context of a possible enrichment of land cover databases. The description of land cover is necessary to make it possible to produce environmental indicators for the management of ecosystems and territories, in response to various societal and scientific needs. Thus, different land cover databases already exist at various levels (global, European, national, regional or local) or are currently being produced. However, it appeared that knowledge about land cover should more detailed in urban areas, since it is required by several city modeling applications (micro-meteorological, hydrological, or pollution monitoring simulators), or public regulations monitoring (e.g. concerning ground perviousness). Such materials maps would be (both semantically and spatially) finer than what is contained in existing land cover databases. Therefore, they could be an additional layer, both in land cover databases (such as in IGN High Resolution land cover database) and in 3D city models.

No existing database contains such information about urban material maps. Thus remote sensing is the only solution to produce it. However, due to the high heterogeneity of urban materials, their variability, but also the strong similarities between different material classes, usual optical multispectral sensors (with only the 4 red - green - blue - near infrared bands) are not sufficient to reach a good discrimination of materials. A multispectral sensor or superspectral, that is to say spectrally richer, could therefore provide a solution to this limit.

Thus, this work was performed intending the design of such sensor. It aimed at identifying the best spectral configuration for classification of urban materials, or at least to propose sub-optimal solutions. In other words, a spectral optimization was carried out in order to optimize both the position of the bands in the spectrum and their width. Automatic feature selection methods were used. This work was performed in two steps.

A first task aimed at defining the spectral optimization methods and at validating them on literature reference data sets. Two state-of-the-art optimization heuristics were used since they were efficient, generic and flexible enough to be used to optimize various feature selection scores. The first one was an incremental approach called Sequential Forward Floating Search (SFFS) algorithm. It was used here to assess the impact of the size of the selected band subset on classification results. The second optimization method was a genetic algorithm, i.e. a stochastic approach able to provide different sub-optimal solutions. A study was then performed to define a metric to quantify the relevance of a band subset, in other words the score to optimize during band selection process. Different possible scores were compared. Several criteria were considered to compare them. Indeed, these feature selection scores had to be able to identify band subsets that should be as discriminative as possible independently from a specific classifier. Thus, proposed solutions should be discriminative for most classifiers and not only according to the used feature selection criterion. Their sparsity, namely their ability to obtain the best results using the smallest band subsets as possible, was also considered. Furthermore, the stability of the proposed solutions was also taken into account by qualitatively considering band importance profiles derived from intermediate results provided by the genetic algorithm. At the end, three best feature selection scores were identified: a filter one (Jeffries-Matusita distance),

and two wrapper scores based on classification confidence measures provided by Random Forests classifier, that is to say wrapper scores that are more sophisticated than simple classification accuracy rates.

Band width optimization was then studied: the proposed method consisted in first building a hierarchy of bands merged according to their similarities while band selection was then processed within this hierarchy. Thus, the proposed approach used a hierarchy of merged band : adjacent bands are merged considering their similarities. Such strategy is a way to control the width of selected merged bands, not being only dependent on the band selection criterion, but also taking into account constraints about band similarities according to a merging criterion. Thus, the hierarchy of merged bands is first built, merging progressively adjacent bands according to a criterion. Three such band merging criteria were tested, merging bands considering either their correlation, their contribution to class separability or their impact on the shape of the spectra. The selection of merged bands was then processed within the obtained hierarchy of possible spectral configurations.

The second part of this work consisted in the application of these spectral optimization algorithms to the case study of urban materials.

A collection of urban materials spectra was first caught and from various spectral libraries ( ASTER , MEMORIES ...). Spectral optimization was then performed on this dataset. A limited number (about 10) of well chosen bands appeared to be sufficient to classify next common materials (slates - asphalt - cement - gravel - metal - cobblestones - shingle - earth – tiles). Bands from short wave infrared spectral domain (1400 - 2500 nm) were shown again to be very useful to discriminate urban materials. However, quantitative results assessing the confusions between the materials must be considered carefully since some materials are very uncommon in the library of collected spectra, and thus their possible variability is not completely considered.

**Key-words:** Spectral optimization - Feature selection - Multispectral - Superspectral - Hyperspectral - Urban areas - Urban materials - Land cover - Material maps - Classification - Remote sensing

# Table des matières

<b>I</b>	<b>Contexte et présentation de la problématique</b>	<b>15</b>
<b>1</b>	<b>Décrire l'occupation du sol de plus en plus finement</b>	<b>19</b>
1.1	Occupation du sol : définitions et besoins . . . . .	19
1.1.1	Définitions . . . . .	19
1.1.2	Utilité de la connaissance de l'occupation du sol . . . . .	19
1.2	Les bases de données d'occupation du sol existantes . . . . .	20
1.2.1	CORINE Land Cover et ses dérivés . . . . .	20
1.2.2	Le Mode d'Occupation du Sol d'Ile de France . . . . .	22
1.2.3	Occupation du sol à grande échelle de l'IGN . . . . .	22
1.3	Des besoins pour une occupation du sol plus fine en milieu urbain . . . . .	25
1.3.1	Suivi de flux de polluants . . . . .	26
1.3.2	Surveillance de matériaux dangereux : cas de l'amiante-ciment . . . . .	27
1.3.3	Modèles de propagation d'ondes électromagnétiques . . . . .	27
1.3.4	Suivi de la perméabilité des sols . . . . .	27
1.3.5	Détermination des revêtements routiers et de leur état . . . . .	28
1.3.6	Modèles climatologiques . . . . .	29
1.3.7	Analyse du potentiel solaire des toitures . . . . .	29
1.3.8	Caractérisation fine de la végétation . . . . .	29
1.3.9	Complétion et mise à jour de l'occupation du sol à grande échelle . . . . .	30
1.4	La télédétection pour accéder aux matériaux . . . . .	31
1.5	Bilan . . . . .	32
<b>2</b>	<b>Quel capteur ?</b>	<b>33</b>
2.1	Quel capteur utiliser pour produire des cartes de matériaux ? . . . . .	33
2.2	Capteurs hyperspectraux aéroportés . . . . .	33
2.3	Des capteurs satellitaires de plus en plus riches . . . . .	36
2.4	Une caméra superspectrale dédiée à des problèmes d'occupation du sol spécifiques . . . . .	36
2.5	Travail à mener . . . . .	37
<b>II</b>	<b>Etat de l'art sur la classification et la sélection d'attributs</b>	<b>39</b>
<b>3</b>	<b>Méthodes de classification</b>	<b>43</b>
3.1	Différents classifieurs . . . . .	43
3.1.1	Généralités . . . . .	43
3.1.2	Classifieurs spécifiques à la donnée hyperspectrale : SAM, SID et SID-SAM . . . . .	45
3.1.3	Classification bayésienne . . . . .	46
3.1.4	Séparateurs à Vaste Marge (SVM) . . . . .	47
3.1.5	Arbres de décision . . . . .	50
3.1.6	Forêts Aléatoires ou Random Forests (RF) . . . . .	51
3.1.7	Illustration du comportement de ces classifieurs . . . . .	53



3.2	Evaluation d'une classification . . . . .	55
<b>4</b>	<b>Réduire la dimension</b>	<b>57</b>
4.1	Des données de grande dimension . . . . .	57
4.2	Sélection de bandes / sélection d'attributs . . . . .	58
4.2.1	Différentes familles de méthodes . . . . .	58
4.2.2	Différentes méthodes d'optimisation . . . . .	65
<b>5</b>	<b>Jeux de données pour l'état de l'art</b>	<b>67</b>
5.1	Scène "Pavie Centre Ville" . . . . .	67
5.2	Scène "Indian Pines" . . . . .	69
5.3	Scène "Salinas" . . . . .	69
<b>III</b>	<b>Optimisation de bandes spectrales : mise en place d'une méthode</b>	<b>73</b>
<b>6</b>	<b>Mise en place d'une stratégie de sélection de bandes</b>	<b>75</b>
6.1	Introduction : approche proposée . . . . .	75
6.2	Scores testés . . . . .	76
6.2.1	Scores de type filtre . . . . .	76
6.2.2	Scores de type <i>wrapper</i> . . . . .	78
6.2.3	Scores de type <i>embedded</i> . . . . .	80
6.3	Stratégie de comparaison de scores de sélection d'attributs . . . . .	80
6.3.1	Sélection du nombre optimal de bandes avec SFFS . . . . .	83
6.3.2	Obtention d'une population de solutions avec un algorithme génétique . . . . .	85
6.3.3	Evaluation quantitative . . . . .	86
6.3.4	Analyse qualitative de la stabilité des bandes sélectionnées . . . . .	87
6.4	Résultats . . . . .	88
6.4.1	Détermination du nombre optimal de bandes avec SFFS . . . . .	88
6.4.2	Comparaison des différents critères de sélection . . . . .	90
6.4.3	Exemples de classifications obtenues en utilisant les bandes sélectionnées . . . . .	97
6.5	Conclusion . . . . .	103
6.5.1	Stratégie de sélection de bandes mise en œuvre dans la suite . . . . .	104
6.6	Perspectives . . . . .	105
6.6.1	Présélection de bandes utiles à l'aide de mesures de type filtre . . . . .	105
6.6.2	Utilisation d'indices calculés à partir des bandes . . . . .	107
<b>7</b>	<b>Sélection de bandes fusionnées</b>	<b>113</b>
7.1	Regroupement de bandes et fusion de bandes . . . . .	113
7.1.1	Regroupement et clusterisation de bandes . . . . .	113
7.1.2	Fusion de bandes . . . . .	114
7.1.3	Approche proposée . . . . .	115
7.2	Fusion hiérarchique de bandes . . . . .	116
7.2.1	Algorithme de fusion hiérarchique de bandes . . . . .	116
7.2.2	Critères pour la fusion de bandes . . . . .	117
7.2.3	Résultats . . . . .	119
7.3	Sélection mono-niveau de bandes par une méthode gloutonne . . . . .	123
7.3.1	Résultats . . . . .	124
7.4	Sélection mono-niveau de bandes prenant en compte la hiérarchie de bandes fusionnées	127
7.4.1	Algorithme . . . . .	127
7.4.2	Résultats . . . . .	127
7.5	Sélection multi-niveaux de bandes fusionnées . . . . .	128

7.6	Conclusion et perspectives . . . . .	130
<b>IV</b>	<b>Application à la classification des matériaux urbains</b>	<b>133</b>
<b>8</b>	<b>Création d'une base de données de spectres de matériaux</b>	<b>137</b>
8.1	Taxonomie de matériaux . . . . .	137
8.2	Structuration d'une librairie de spectres de matériaux . . . . .	145
8.3	Librairies spectrales de matériaux urbains . . . . .	146
8.4	Mise en forme et rangement des spectres dans la base de données . . . . .	147
8.5	Classes non considérées . . . . .	148
<b>9</b>	<b>Optimisation spectrale pour la discrimination des matériaux</b>	<b>151</b>
9.1	Approche proposée . . . . .	151
9.1.1	Constitution de "jeux de données synthétiques" . . . . .	151
9.2	Expériences et résultats . . . . .	152
9.2.1	Sélection de bandes pour la légende 1 à la résolution de 10 nm . . . . .	153
9.2.2	Impact de la prise en compte ou non de la couleur des matériaux : sous-classes	169
9.2.3	Sélection de bandes pour la légende 1 à la résolution de 1 nm . . . . .	170
9.2.4	Sélection de bandes fusionnées pour la légende 1 . . . . .	172
9.2.5	Sélection de bandes pour la légende 2 à la résolution de 10 nm . . . . .	175
9.2.6	Bilan . . . . .	177
<b>V</b>	<b>Conclusion</b>	<b>179</b>
<b>10</b>	<b>Bilan et perspectives</b>	<b>181</b>
10.1	Mise en place d'outils d'optimisation spectrale . . . . .	181
10.2	Application au cas d'étude des matériaux urbains . . . . .	183
	<b>Annexes</b>	<b>189</b>
<b>A</b>	<b>Glossaire</b>	<b>189</b>
<b>B</b>	<b>Rappel des configurations de quelques capteurs satellite</b>	<b>191</b>
<b>C</b>	<b>Publications</b>	<b>193</b>
C.1	Liste des publications et communications dans le cadre de ce travail . . . . .	194
C.2	Liste des publications et communications sur d'autres sujets en parallèle de ce travail .	195
C.3	Liste des publications et rapports techniques antérieurs à ces travaux . . . . .	196
C.4	Compilation des publications effectuées dans le cadre de ce travail . . . . .	197
	<b>Bibliographie</b>	<b>243</b>



# Table des figures

1.1	Comparaison entre CORINE Land Cover et Urban Atlas . . . . .	22
1.2	Illustration du MOS Ile de France . . . . .	22
1.3	Nomenclature de la couche couverture du sol de l'OCS GE de l'IGN (source : [Touzet 2014]) . . . . .	24
1.4	Exemple de maquette urbaine BATI3D® . . . . .	25
1.5	Interactions matériaux-environnement pour la modélisation du climat (Source : Météo-France) . . . . .	30
2.1	Exemples de capteurs hyperspectraux aéroportés. (source : [Briottet et Carrère 2012])	34
2.2	Comparaison de la résolution d'images acquises par des capteurs hyperspectraux et multispectraux . . . . .	35
3.1	Illustration de la notion de marge d'un classifieur SVM linéaire . . . . .	48
3.2	Principe des forêts aléatoires (apprentissage et classification) . . . . .	52
3.3	Application de différents classifieurs pour un problème de classification binaire linéairement séparable . . . . .	54
3.4	Application de différents classifieurs pour un problème de classification binaire où les frontières entre classes sont plus complexes . . . . .	54
5.1	Jeu de données "Pavie" : image et carte de vérité terrain . . . . .	68
5.2	Jeu de données "Indian Pines" : image et carte de vérité terrain . . . . .	70
5.3	Jeu de données "Salinas" : image et carte de vérité terrain . . . . .	71
6.1	Processus d'évaluation des scores de sélections d'attribut . . . . .	82
6.2	Evaluation des critères de sélection utilisés à partir des différents jeux de bandes sélectionnés à l'issue d'une optimisation par algorithme génétique . . . . .	83
6.3	Utilisation de résultats intermédiaires des algorithmes génétiques pour le calcul d'une mesure d'importance des bandes . . . . .	86
6.4	Jeu de données Pavie : influence du nombre de bandes sélectionnées sur le score de sélection et la qualité de la classification . . . . .	89
6.5	Jeu de données Salinas : influence du nombre de bandes sélectionnées sur le score de sélection et la qualité de la classification . . . . .	90
6.6	Qualité de la classification pour les jeux de données Pavie, Indian Pines et Salinas en fonction du critère de sélection de bandes utilisé . . . . .	91
6.7	Pavie : profils d'importance de bandes obtenus pour les critères <i>ml.K</i> , <i>svm.lin.K</i> et <i>rf.K</i>	93
6.8	Indian Pines : profils d'importance de bandes obtenus pour les critères <i>ml.K</i> , <i>svm.lin.K</i> et <i>rf.K</i> . . . . .	93
6.9	Pavie : profils d'importance de bandes obtenus pour les critères <i>rf.appart</i> , <i>rf.conf</i> et <i>rf.K</i>	94
6.10	Indian Pines : profils d'importance de bandes obtenus pour les critères <i>rf.appart</i> , <i>rf.conf</i> et <i>rf.K</i> . . . . .	94
6.11	Pavie : profils d'importance de bandes obtenus pour la distance de JM et l'information mutuelle . . . . .	96

6.12	Indian Pines : profils d'importance de bandes obtenus pour la distance de JM et l'information mutuelle . . . . .	96
6.13	Salinas : exemple de classification obtenue par un classifieur SVM avec noyau gaussien pour un jeu de bandes optimal obtenu d'après le critère <i>rf.appart</i> . . . . .	98
6.14	Indian Pines : exemple de classification obtenue par un classifieur SVM avec noyau gaussien pour un jeu de bandes optimal obtenu d'après le critère <i>rf.appart</i> . . . . .	103
6.15	Importances de bandes pour les jeux de données Pavie et Indian Pines par différentes mesures de type filtre : corrélation entre les attributs et les classes, mesure ReliefF et incertitude symétrique par rapport à une classe . . . . .	106
6.16	Evolution du Kappa de la classification en fonction du nombre de bandes sélectionnées pour les scores <i>CorrelationAttributeEval</i> , <i>ReliefFAttributeEval</i> et <i>SymmetricalUncertAttributeEval</i> pour les jeux de données Pavie et Indian Pines . . . . .	106
6.17	Principe du codage des indices dérivés pour l'algorithme génétique . . . . .	109
6.18	Jeu de données Pavie : profil d'importance de bandes obtenus en appliquant le score <i>rf.appart</i> directement à des jeux de 7 bandes originales ou à des jeux de 7 indices dérivés des 7 bandes sélectionnées . . . . .	111
7.1	Méthode mise en œuvre pour la sélection de bandes fusionnées. . . . .	116
7.2	Groupes de bandes en surimpression d'une matrice de corrélation entre bandes (pour le jeu de données Pavie) . . . . .	118
7.3	Illustration du principe du critère de fusion de bandes basé sur l'erreur d'approximation du spectre . . . . .	119
7.4	Hierarchies de bandes fusionnées obtenues pour différents critères sur le jeu de données Pavie . . . . .	121
7.5	Kappa obtenus par un classifieur SVM gaussien pour les différentes configurations spectrales de la hiérarchie de bandes fusionnées pour Pavie, Indian Pines et Salinas . . . . .	123
7.6	Bandes sélectionnées aux différents niveaux de la hiérarchie par l'approche SFFS gloutonne, pour des hiérarchies de bandes fusionnées calculées pour différents critères de fusion, pour le jeu de données Pavie . . . . .	125
7.7	Kappa obtenus par un classifieur SVM gaussien pour les jeux de bandes sélectionnés aux différents niveaux de la hiérarchie pour le jeu de données Pavie, en utilisant l'approche SFFS gloutonne . . . . .	126
7.8	Jeu de données Pavie : bandes sélectionnées aux différents niveaux d'une hiérarchie (au sens du critère de fusion "erreur de reconstruction du spectre") en utilisant l'approche hiérarchique . . . . .	128
7.9	Kappa obtenus par un classifieur SVM gaussien pour les jeux de bandes sélectionnés par l'approche SFFS gloutonne et l'approche hiérarchique aux différents niveaux d'une hiérarchie pour le jeu de données Pavie . . . . .	129
7.10	Exemples de résultats de sélection multi-niveaux de bandes prenant en compte la hiérarchie de bandes fusionnées pour le jeu de données Pavie . . . . .	130
8.1	Taxonomie de matériaux urbains proposée par Herold (source : [Herold <i>et al.</i> 2004a]) . . . . .	138
8.2	Taxonomie de matériaux urbains proposée par Heiden (source : [Heiden <i>et al.</i> 2007]) . . . . .	139
8.3	Nomenclature hiérarchique utilisée par Heiden (source : [Kaufmann <i>et al.</i> 2010]) . . . . .	140
8.4	Nomenclature de la couche couverture du sol de l'OCS GE de l'IGN (source : [Touzet 2014]) . . . . .	141
8.5	Taxonomie proposée à partir de la nomenclature d'Heiden . . . . .	143
8.6	Taxonomie proposée à partir de la nomenclature de l'OCS GE de l'IGN . . . . .	144
8.7	Bilan des spectres disponibles pour les principales classes de matériaux . . . . .	150
9.1	Génération d'une vérité terrain synthétique à partir de la base de données . . . . .	152

---

9.2	Evolution du score de sélection suivant le nombre de bandes sélectionnées dans le domaine VNIR+SWIR pour la légende 1 . . . . .	154
9.3	Evolution de la qualité de la classification par SVM gaussien suivant le fonction du nombre de bandes sélectionnées dans le domaine VNIR+SWIR pour la légende 1 . . . . .	154
9.4	Sélection de 10 bandes dans le domaine VNIR+SWIR pour la légende 1 : profil d'importance de bandes et jeux de bandes sélectionnées . . . . .	155
9.5	Performances de classification pour différentes configurations hyperspectrales ou super-spectrales pour la légende 1 . . . . .	160
9.6	Evolution du score de sélection suivant le nombre de bandes sélectionnées dans le domaine VNIR pour la légende 1 . . . . .	161
9.7	Evolution de la qualité de la classification par SVM gaussien suivant le fonction du nombre de bandes sélectionnées dans le domaine VNIR pour la légende 1 . . . . .	161
9.8	Sélection de 10 bandes dans le domaine VNIR pour la légende 1 : profil d'importance de bandes et jeux de bandes sélectionnées . . . . .	163
9.9	Performances de classification pour différentes configurations spectrales de 4 bandes pour la légende 1 . . . . .	168
9.10	Sélection de 10 bandes dans le VNIR+SWIR à la résolution de 1 nm pour la légende 1 : profil d'importance de bandes et jeux de bandes sélectionnées . . . . .	171
9.11	Hiérarchie de bandes fusionnées obtenue pour le critère de fusion "erreur de reconstruction du spectre" pour la légende 1 . . . . .	173
9.12	Evolution de la qualité de la classification par un SVM à noyau gaussien pour les différentes configurations spectrales de la hiérarchie de bandes fusionnées de la figure 9.11	173
9.13	Jeux de 10 bandes sélectionnées (en utilisant l'approche SFFS adaptée) aux différents niveaux de la hiérarchie de bandes fusionnées de la figure 9.11 . . . . .	174
9.14	Evolution de la qualité de la classification par un SVM gaussien pour les jeux de 10 bandes de la figure 9.13 . . . . .	175
9.15	Sélection de 10 bandes dans le domaine VNIR+SWIR pour la légende 2 : profil d'importance de bandes et jeux de bandes sélectionnées . . . . .	176



# Liste des tableaux

3.1	Exemple de matrice de confusion. . . . .	55
4.1	Récapitulatif de différents critères de sélection d'attributs issus de l'état de l'art. . . . .	63
4.2	Récapitulatif avec avantages et inconvénients des différentes familles de critères de sélection d'attributs issus de l'état de l'art. . . . .	64
5.1	Classes et nombre de pixels associés pour le jeu de données "Pavie Centre Ville" . . . . .	67
5.2	Classes et nombres de pixels associés pour le jeu de données "Indian Pines" . . . . .	69
5.3	Classes et nombres de pixels associés pour le jeu de données "Salinas" . . . . .	70
6.1	Liste des scores testés pour la sélection d'attributs . . . . .	81
6.2	Salinas : indicateurs de qualité de la classification obtenue pour des jeux de bandes sélectionnées d'après les critères <i>jm</i> et <i>rf.appart</i> . . . . .	99
6.3	Indian Pines : indicateurs de qualité de la classification obtenue pour des jeux de bandes sélectionnées d'après les critères <i>jm</i> et <i>rf.appart</i> . . . . .	101
6.4	Indian Pines : matrice de confusion moyennée sur les 25 jeux de bandes proposés à l'issue des différents lancements des AG pour le score <i>rf.appart</i> . . . . .	102
6.5	Nombres de bandes conservées après pré-sélection suivant les différentes mesures filtres. . . . .	107
6.6	Kappa (en %) obtenu pour les classifications utilisant des jeux de bandes sélectionnées parmi les sous-ensembles de bandes pré-sélectionnés par les mesures filtres. . . . .	107
6.7	Résultats obtenus sur le jeu de données Indian Pines, selon que l'on utilise un jeu de 10 bandes originales ou un jeu de 10 indices . . . . .	110
6.8	Résultats obtenus sur le jeu de données Pavie, selon que l'on utilise un jeu de 7 bandes originales ou un jeu de 7 indices . . . . .	111
7.1	Temps de calcul et meilleure valeur de Kappa obtenus pour Pavie (pour un jeu de 5 bandes) et Indian Pines (pour un jeu de 10 bandes) pour une hiérarchie construite selon le critère de fusion "erreur de reconstruction du spectre" . . . . .	128
8.1	Origine des spectres récupérés . . . . .	147
8.2	Bilan des spectres disponibles pour les principales classes de matériaux . . . . .	149
9.1	Matrice de confusion obtenue à l'issue d'une classification par SVM avec noyau gaussien pour un jeu optimal de 10 bandes issues du domaine VNIR+SWIR pour la légende 1. . . . .	157
9.2	Matrice de confusion obtenue à l'issue d'une classification par RF pour un jeu optimal de 10 bandes issues du domaine VNIR+SWIR pour la légende 1. . . . .	157
9.3	Bilan de classification pour un jeu optimal de 10 bandes issues du domaine VNIR+SWIR pour la légende 1. . . . .	158
9.4	Bilan de classification pour la légende 1 pour le jeu hyperspectral complet (à la résolution spectrale de 10 nm) . . . . .	159
9.5	Bilan de classification pour la légende 1 pour la configuration spectrale de Worldview-3 . . . . .	159
9.6	Matrice de confusion obtenue à l'issue d'une classification par SVM à noyau gaussien pour un jeu optimal de 10 bandes issues du domaine VNIR pour la légende 1. . . . .	164



---

9.7	Matrice de confusion obtenue à l'issue d'une classification par RF pour un jeu optimal de 10 bandes issues du domaine VNIR pour la légende 1. . . . .	164
9.8	Bilan de classification pour un jeu optimal de 10 bandes issues du domaine VNIR (420-1000nm) pour la légende 1. . . . .	165
9.9	Bilan de classification pour un jeu optimal de 4 bandes issues du domaine VNIR (420-1000nm) pour la légende 1. . . . .	166
9.10	Bilan de classification pour la légende 1 pour la configuration spectrale de Pléiades. . .	166
9.11	Bilan de classification pour un jeu optimal de 4 bandes issues du domaine VNIR+SWIR pour la légende 1. . . . .	167
9.12	Bilan de classification pour un jeu optimal de 10 bandes issues du domaine VNIR+SWIR pour la légende 1, à partir d'un apprentissage utilisant des sous-classes. . . . .	170
9.13	Bilan de classification pour un jeu optimal de 10 bandes issues du domaine VNIR pour la légende 1, à partir d'un apprentissage utilisant des sous-classes. . . . .	170
9.14	Bilan de classification pour un jeu optimal de 10 bandes issues du domaine VNIR+SWIR à la résolution spectrale de 1 nm pour la légende 1 . . . . .	172
9.15	Bilan de la classification pour un jeu optimal de 10 bandes issues du domaine VNIR+SWIR pour la légende 2 . . . . .	177
9.16	Bilan de la classification pour la légende 2 en utilisant le jeu optimal de 10 bandes issues du domaine VNIR+SWIR sélectionné pour la légende 1 . . . . .	177
B.1	Capteur Pléiades . . . . .	191
B.2	Capteurs SPOT 6 et 7 . . . . .	191
B.3	Capteur Worldview-3 . . . . .	192

## Première partie

# Contexte et présentation de la problématique



---

## Préambule

Cette première partie a pour but de présenter le contexte de ce travail ainsi que d'explicitier sa problématique et de définir ses objectifs.

Après une rapide présentation de quelques exemples de bases de données d'occupation du sol existantes ou en cours de constitution, nous en montrerons les limites pour certaines applications en milieu urbain. Ainsi, nous recenserons des applications qui nécessitent une connaissance plus fine, tant d'un point géométrique que sémantique, de l'occupation du sol dans les zones urbaines, et requérant en particulier des cartes de matériaux.

De telles cartes de matériaux devraient présenter une résolution spatiale qui soit d'une part au moins compatible avec la base de données d'occupation du sol à grande échelle actuellement en cours de production à l'IGN, et d'autre part avec des maquettes urbaines 3D, qui pourraient toutes deux être enrichies par une connaissance sur les matériaux pour certaines applications.

Des données aussi fines n'existant pas à l'heure actuelle, la télédétection apparaît comme la seule solution permettant leur production de manière semi-automatique. On se posera donc la question du capteur à utiliser. En effet, du fait de la grande variété des matériaux présents en milieu urbain, mais aussi de leur forte variabilité intra-classe et de la similarité entre matériaux de classes différentes, les capteurs multispectraux traditionnels (limités aux 4 canaux bleu-vert-rouge-proche infrarouge) s'avèrent insuffisants pour la classification des matériaux urbains ; une plus grande richesse spectrale semble nécessaire. On verra que de ce point de vue, un capteur hyperspectral pourrait être une solution, mais présente des limites en terme de caractéristiques géométriques (résolution spatiale, fauchée). Néanmoins, si seul un nombre limité de bandes spectrales est nécessaire pour la classification des matériaux, un capteur superspectral ne comportant que les bandes utiles pour cette problématique pourrait convenir, et présenter des caractéristiques géométriques plus intéressantes. On illustrera cette notion de capteur superspectral par la tendance actuelle des capteurs spatiaux à présenter à la fois une très haute résolution spatiale et une richesse spectrale de plus en plus grande, à l'instar de missions récentes comme Worldview-3.

On terminera en présentant le travail d'optimisation spectrale à mener dans le but de concevoir un tel capteur.



---

# Chapitre 1

## Décrire l'occupation du sol de plus en plus finement

### 1.1 Occupation du sol : définitions et besoins

#### 1.1.1 Définitions

L'**occupation du sol** est la description de la couverture physique, naturelle ou anthropologique de la surface de la Terre.

La couverture et l'usage des sols sont deux notions différentes et complémentaires pour décrire le territoire.

**Couverture du sol** : La couverture du sol est donc une vue physionomique du terrain. Elle correspond à une distinction des éléments sans présager de leur fonction. Couverture et occupation du sol sont parfois confondues.

**Usage du sol** ou **fonction du sol** : L'usage du sol est une vue anthropique du territoire. Ce dernier est alors partagé en fonction du rôle que jouent les portions de terrain en tant qu'activité économique ou humaine.

Ainsi, pour illustrer ces 2 notions, une zone appartenant à la classe du bâti du point de vue de la couverture du sol pourra être une zone résidentielle, commerciale ou industrielle du point de vue de l'usage du sol.

#### 1.1.2 Utilité de la connaissance de l'occupation du sol

Des bases de données d'occupation du sol ont été constituées à différents niveaux (mondial, européen, national, régional ou local) afin de répondre à différents besoins sociétaux, réglementaires et scientifiques [Manakos et Braun 2014]. Une description de l'occupation du sol permet en effet de produire un certain nombre d'indicateurs environnementaux pour la gestion des écosystèmes et des territoires. Ainsi, une base de données sur l'occupation du sol (mise à jour au cours du temps) peut faire prendre conscience de certaines évolutions du territoire et d'assurer le suivi de certains phénomènes naturels ou humains. Ce type de constat peut déboucher sur la mise en place d'une politique publique concernant le phénomène observé. Les données sur l'occupation du sol vont alors rendre ensuite possible l'évaluation de l'impact de ces réglementations. Un exemple d'une telle application concerne le suivi de l'urbanisation du territoire, avec d'une part le suivi de l'extension de la tâche artificialisée, et d'autre part de la densification urbaine. La connaissance sur l'occupation du sol est également utilisée à des fins de planification, notamment dans des études d'impact par exemple lors de prise de décision concernant des chantiers importants.

Par ailleurs, les données d'occupation du sol peuvent aussi être fournies en entrée d'outils de simula-

tion concernant par exemple le climat ou l'hydrologie.

## 1.2 Les bases de données d'occupation du sol existantes

En conséquence, les spécifications d'une base de données d'occupation du sol vont dépendre des applications auxquelles elle doit répondre, et de l'échelle à laquelle elle doit être utilisée. Les spécifications d'une occupation du sol vont concerner à la fois :

- sa précision **géométrique**, c'est-à-dire la taille des objets qui vont s'y trouver. On définit ainsi les **unités minimales de collecte** (UMC) qui spécifient pour chaque classe de la nomenclature la taille en deçà de laquelle les objets sont considérés comme trop petits pour apparaître dans la base de données.
- sa précision **sémantique**, c'est-à-dire le niveau de détail de sa nomenclature. Les nomenclatures d'occupation du sol sont le plus souvent hiérarchiques avec un emboîtement allant de classes assez générales à des sous-classes plus fines (comme par exemple une classe générale "végétation", contenant une classe de second niveau "forêt", regroupant elle-même des classes de troisième niveau sur les types de peuplements forestiers)

Des données d'occupation du sol ont donc été constituées à différentes échelles pour répondre à différents besoins. Certaines constituent une partition de l'intégralité du territoire et ont donc une nomenclature à même de décrire l'occupation du sol de l'ensemble du territoire. D'autres sont plus spécialisées, et peuvent se focaliser sur un seul thème (comme par exemple la forêt, en détaillant les différents types de peuplements dans le cas de la Carte Forestière<sup>1</sup> de l'IGN [IGN 2012]).

Les paragraphes suivants présentent succinctement des exemples de bases de données d'occupation du sol existantes à l'échelle européenne et en France.

### 1.2.1 CORINE Land Cover et ses dérivés

#### CORINE Land Cover

CORINE Land Cover (CLC) [European Environment Agency 2012] est l'une des bases de données d'occupation du sol les plus connues. Elle a été produite à l'initiative de l'Union Européenne et de l'Agence Environnementale Européenne (EEA) dans le cadre du programme européen Copernicus, initialement nommé GMES (Global Monitoring for Environment and Security) et voué au développement de moyens européens d'observation de la Terre.

CORINE Land Cover est une base de données d'occupation du sol générique qui couvre l'intégralité du territoire européen et de certains états limitrophes.

CLC comporte plusieurs millésimes : sa première version date de 1990, et a été suivie de mises à jour pour les années 2000, 2006 et 2012. Cette base de données permet donc d'ores et déjà de mener des études de suivi de l'évolution des territoires.

Sa nomenclature a été élaborée afin de rendre possible la cartographie de l'ensemble du territoire de l'Union européenne, de connaître l'état de l'environnement et de ne pas comporter de classes ambiguës. Elle est hiérarchique avec 3 niveaux de classes et comporte en tout 44 thèmes au niveau le plus fin. Elle présente également la particularité de mélanger couverture du sol et usage du sol. Ainsi, les classes du niveau le plus grossier de CLC sont les suivantes : "territoires artificialisés"(1), "territoires agricoles"(2), "forêts et milieux semi-naturels"(3), "zones humides"(4) et "surfaces en eau"(5). Les classes de second niveau de la classe "territoires artificialisés" distinguent les "zones urbanisées", les "zones industrielles ou commerciales et réseaux de communication", "mines décharges et chantier" et "espaces verts artificialisés non agricoles".

---

1. [http://inventaire-forestier.ign.fr/spip/IMG/pdf/Guide\\_technique\\_cartographie.pdf](http://inventaire-forestier.ign.fr/spip/IMG/pdf/Guide_technique_cartographie.pdf)

Son unité minimale de collecte est fixée à 25ha, avec une largeur minimale de 100m pour les objets allongés. Son échelle d'utilisation correspond au 1/100 000. Il s'agit d'un compromis permettant un bon suivi de l'occupation du sol au niveau national ou européen avec des coûts et des délais de productions acceptables. En revanche, CLC n'est donc pas adaptée à une utilisation à un niveau géographique fin, comme la commune par exemple.

CLC a été produite par photo-interprétation assistée par ordinateur à partir d'images satellite SPOT ou LANDSAT, en s'aidant de données auxiliaires (ex : BDOrtho® de l'IGN en France).

## Urban Atlas

La base de données d'occupation du sol Urban Atlas [European Environment Agency 2008] est elle aussi produite à l'initiative de l'Agence Européenne de l'Environnement dans le cadre du programme européen Copernicus. Contrairement à CORINE Land Cover, cette base de données ne concerne que les zones urbaines les plus importantes d'Europe. Deux millésimes de la base de données Urban Atlas existent. Le millésime d'Urban Atlas de 2006 ne concernait que les zones urbaines de plus de 100 000 habitants, tandis que son millésime de 2012 s'étend aux zones urbaines de plus de 50 000 habitants.

L'objectif d'Urban Atlas est de disposer d'une description commune pour toutes les villes d'Europe, afin de pouvoir aisément les comparer de manière rigoureuse ou calculer des indicateurs les concernant.

L'unité minimale de collecte d'Urban Atlas a été fixée à 0.25ha, avec une largeur minimale de 10m pour les objets allongés. Urban Atlas est produite à partir d'images satellite de résolution 2.5m et de cartes topographiques au 1 :50 000.

Tout comme pour CORINE Land Cover, la nomenclature d'Urban Atlas est hiérarchique, avec 3 niveaux. Elle totalise 17 classes. Sa nomenclature ressemble assez à celle de CLC : seules quelques classes ont été adaptées pour mieux cadrer avec le milieu urbain. A titre d'exemple, les classes de premier niveau d'Urban Atlas sont les suivantes : "territoires artificialisés"(1), "territoires agricoles, semi-naturels et zones humides"(2), "forêts"(3) et "surfaces en eau"(5). La classe 2 d'Urban Atlas correspond donc à la fusion des classes 2 et 4 (ainsi qu'à une partie de la classe 3) de CLC, ces classes étant peu présentes dans les zones concernées par Urban Atlas. A l'inverse, les classes de troisième niveau (i.e. les plus fines sémantiquement) sont plus nombreuses pour la classe "territoires artificialisés", avec par exemple 7 classes correspondant à différents niveaux de densité du tissu urbain, là où CLC ne distinguait que le tissu urbain continu ou discontinu.

## Enrichissement de CORINE Land Cover au niveau régional

En France, certaines régions ont pris l'initiative de se doter de bases de données d'occupation du sol. Parmi ces initiatives régionales, on peut par exemple mentionner l'occupation du sol de la région Provence-Alpes-Côte d'Azur (<http://www.geoportail.gouv.fr/donnee/101/occupation-du-sol-paca>), celle de la région Languedoc-Roussillon, ou encore celle de la région Alsace ([https://www.cigalsace.org/metadata/CIGAL/FR-236700019-BdOCS20112012-CIGAL-V2/CIGAL\\_BdOCSv2\\_GuideUtilisateur\\_v131122.pdf](https://www.cigalsace.org/metadata/CIGAL/FR-236700019-BdOCS20112012-CIGAL-V2/CIGAL_BdOCSv2_GuideUtilisateur_v131122.pdf)).

Leurs nomenclatures se sont parfois inspirées de celle de CORINE Land Cover, qui a alors été adaptée à leurs besoins propres par exemple en y ajoutant des classes correspondant à des types d'occupation spécifiques à leur territoire, ou encore en ajoutant un quatrième niveau afin de découper certaines des classes les plus fines sémantiquement de CLC en sous-classes encore plus détaillées. Par ailleurs, le niveau de détail géométrique de ces bases de données est également beaucoup plus fin que celui de CLC. Par exemple, dans le cas de l'occupation du sol de la région Alsace, l'UMC varie entre 0.03 et 0.5 ha en fonction des classes concernées.






FIGURE 1.1 – Illustration des différences de niveaux de détail entre CORINE Land Cover et Urban Atlas : sur une même zone, ortho-image (en bas), CORINE Land Cover (en haut à gauche) et Urban Atlas (en haut à droite)

### 1.2.2 Le Mode d’Occupation du Sol d’Ile de France

Le Mode d’Occupation du Sol (MOS) produit par l’Institut d’Aménagement et d’Urbanisme (IAU) d’Ile de France est l’une des plus anciennes bases de données concernant l’occupation du sol et également l’une des plus fines tant au niveau sémantique que géométrique. Cette base de données produite par photo-interprétation à partir d’images aériennes est produite depuis 1982 et comporte actuellement 8 millésimes (1982, 1987, 1990, 1994, 1999, 2003, 2008 et 2012).

Sa nomenclature hiérarchique est structurée en 4 niveaux, le premier niveau comportant 11 postes d’OCS, le second 24, le troisième 47 et le dernier 81 postes. Néanmoins, cette nomenclature est très orientée vers l’usage des sols.




FIGURE 1.2 – Illustration du MOS Ile de France sur la même zone que la figure 1.1

### 1.2.3 Occupation du sol à grande échelle de l’IGN

En France, l’IGN a donc entrepris la production d’une occupation du sol à grande échelle, de précision métrique et compatible avec les autres couches du Référentiel à Grande Echelle (RGE) [Touzet

2014].

## Contexte réglementaire

En effet, malgré les initiatives régionales ou locales mentionnées plus haut, un besoin pour une occupation du sol à grande échelle couvrant l'intégralité du territoire français avec une nomenclature commune a été exprimé pour répondre à différents besoins. En effet, la présence d'informations concernant l'occupation du sol est devenue obligatoire dans un certain nombre de document produit au niveau des collectivités locales et concernant l'aménagement du territoire. Ainsi, la loi "Grenelle2"<sup>2</sup> demande une analyse de la consommation d'espace dans les documents d'urbanisme comme les Schémas de Cohérence Territoriale (SCoT) et les Plans Locaux d'Urbanisme (PLU), qui doivent notamment fixer des objectifs chiffrés de limitation de la consommation d'espace et préserver les espaces naturels, agricoles et forestiers. Il s'agit donc de mettre à disposition des intéressés les données leur permettant de fournir ces indicateurs. Par ailleurs, ces documents, ainsi que des études d'impact lors de projet de chantiers importants doivent intégrer des informations sur l'occupation du sol, et en particulier sur les Trames Vertes et Bleues<sup>3,4</sup>, c'est-à-dire sur la continuité écologique du territoire, les réservoirs de biodiversité et les corridors permettant de les relier.

En outre, l'occupation du sol à grande échelle de l'IGN a aussi pour objectif de contribuer à la mise au point d'indicateurs de la consommation de l'espace, en particulier à l'étalement urbain. Il s'agit ainsi de répondre à la Loi de modernisation de l'agriculture et de la pêche<sup>5</sup> et à la Loi d'avenir pour l'agriculture, l'alimentation et la forêt<sup>6</sup> dont un objectif est de réduire de moitié d'ici 2020 la perte des surfaces agricoles au profit de l'urbanisation, ce qui requiert une définition d'indicateurs pour quantifier le changement de destination des terres agricoles.

## Présentation de l'occupation du sol de l'IGN

La base de données d'occupation du sol à grande échelle (BD OCS GE) de l'IGN constituera une nouvelle composante du référentiel à grande échelle. Ses spécifications, et notamment sa nomenclature, ont été définies en concertation avec différents partenaires, notamment au sein d'un groupe de travail mandaté par la Direction Générale de l'Aménagement, du Logement et de la Nature (DGALN) et piloté par le Centre d'Etudes sur les Réseaux, les Transports, l'Urbanisme et les constructions publiques (CERTU). Il s'agissait d'une part de rester autant que possible compatible avec les occupations du sol existantes et d'autre part de se conformer à la directive européenne INSPIRE<sup>7</sup> dont les spécifications concernant les bases de données d'occupation du sol préconisent de séparer couverture<sup>8</sup> et usage du sol<sup>9</sup>.

En conséquence, l'OCS GE comporte 2 couches, l'une dédiée à la couverture du sol, l'autre à l'usage du sol. A chacune de ces composantes est associée une nomenclature hiérarchique.

La nomenclature de la couverture du sol (figure 1.3) comporte 4 niveaux.

Pour comprendre la logique de cette nomenclature, intéressons nous aux surfaces anthropisées. Le premier niveau ne comporte que 2 classes : "Sans végétation" (CS1) et "Avec végétation" (CS2).

La classe "Sans végétation" CS1 est alors divisée entre "surfaces naturelles" (CS1.2) et "surfaces anthropisées" (CS1.1), ces dernières étant encore divisées entre "zones imperméables" (CS1.1.1) et "zones

2. <http://www.legifrance.gouv.fr/affichTexte.do?cidTexte=JORFTEXT000022470434>

3. <http://www.trameverteetbleue.fr/>

4. <http://www.developpement-durable.gouv.fr/-La-Trame-verte-et-bleue,1034-.html>

5. <http://www.legifrance.gouv.fr/affichTexte.do?cidTexte=JORFTEXT000022521587>

6. <http://www.legifrance.gouv.fr/affichTexte.do?cidTexte=JORFTEXT000029573022&categorieLien=id>

7. <http://inspire.ec.europa.eu/index.cfm>

8. [http://inspire.ec.europa.eu/documents/Data\\_Specifications/INSPIRE\\_DataSpecification\\_LU\\_v3.0.pdf](http://inspire.ec.europa.eu/documents/Data_Specifications/INSPIRE_DataSpecification_LU_v3.0.pdf)

9. [http://inspire.ec.europa.eu/documents/Data\\_Specifications/INSPIRE\\_DataSpecification\\_LC\\_v3.0.pdf](http://inspire.ec.europa.eu/documents/Data_Specifications/INSPIRE_DataSpecification_LC_v3.0.pdf)

perméables”. Les “zones imperméables” regroupent les “zones bâties” (CS1.1.1.1) et les “zones non bâties” (CS1.1.1.2), c’est-à-dire les routes et les parkings, tandis que les “zones imperméables” regroupent les “zones à matériaux minéraux” (CS1.1.2.1), i.e. les zones de sol nu pierre-terre, et les “zones à autres matériaux” (CS1.1.2.2) (dont les décharges).

L’unité minimale de collecte varie entre 0.5 ha (en particulier dans les zones construites) et 2.5 ha.

Couverture du sol															
CS1. Sans végétation					CS2. Avec végétation										
CS1.1 Surfaces anthropisées		CS1.2 Surfaces naturelles			CS2.1 Végétation ligneuse			CS2.2 Végétation non ligneuse							
CS1.1.1.1 Zones bâties	CS1.1.1.2 Zones non bâties (routes, places, parking...)	CS1.1.2.1 Zones à matériaux minéraux (pierre-terre - voies ferrées, pistes forestières, chemins empierrés, chantiers, carrières, salines...)	CS1.1.2.2 Zones à autres matériaux composites (décharges)	CS1.1.1 Zones imperméables	CS1.1.2 Zones perméables	CS1.2.1 Sols nus (sable, pierres meubles, rochers saillants...)	CS1.2.2 Surfaces d'eau (continentale et maritime)	CS1.2.3 Névés et glaciers	CS2.1.1 Formations arborées	CS2.1.2 Formations arbustives et sous-arbrisseaux (landes basses, formations arbustives, formations arbustives organisées...)	CS2.1.3 Autres formations ligneuses (vignes et autres lianes)	CS2.2.1 Formations herbacées (pelouses et prairies, terres arables, roselières...)	CS2.2.2 Autres formations non ligneuses (lichen, mousse, bananiers ...)		
										CS2.1.1.1 Formations de feuillus	CS2.1.1.2 Formations de conifères	CS2.1.1.3 Formations de composition mixte			

FIGURE 1.3 – Nomenclature de la couche couverture du sol de l’OCS GE de l’IGN (source : [Touzet 2014])

## Production de la BD OCS GE

La BD OCS GE est produite à la fois par intégration de données existantes, par calcul à partir de données existantes, et par photo-interprétation.

En effet, dans un premier temps, la base de données est produite par intégration de bases de données existantes (base de données forêt de l’IGN, Référentiel Parcellaire Graphique (RPG) du Ministère de l’Agriculture, base de données topographique de l’IGN (BD Topo)...). Certaines de ces bases de données sont directement intégrées, d’autres sont utilisées pour générer des informations par calcul (comme par exemples les zones bâties à partir des objets de la BD Topo).

La base de données ainsi produite est ensuite corrigée et complétée par photo-interprétation. En effet,

les bases de données intégrées sont indépendantes les unes des autres et d'actualités différentes, et il s'agit donc de les mettre en cohérence et à jour, de manière à avoir une donnée millésimée. D'autre part, certaines zones ne sont couvertes par aucune de ces bases de données, et il subsiste donc des trous (par exemple, un champ qui n'est plus cultivé ne sera concerné par aucune de ces bases de données). Il s'agit donc de renseigner ces zones blanches de manière à obtenir une partition complète du territoire.

Cette dernière étape est fortement consommatrice de temps opérateur. Il serait donc intéressant de pouvoir en partie l'automatiser, par l'utilisation automatique ou semi-automatique de la télédétection, qui serait également utile dans l'optique d'une mise à jour millésimée de la base de données.

### 1.3 Des besoins pour une occupation du sol plus fine en milieu urbain

Une occupation du sol métrique sera donc bientôt disponible sur la totalité du territoire français. Néanmoins, elle restera insuffisante pour certaines applications ou milieux spécifiques. Ainsi, dans les zones urbaines, il apparaît un besoin pour des données d'occupation du sol encore plus fines tant du point de vue de leur géométrie que de leur sémantique, c'est-à-dire pour des **cartes de matériaux**. A l'heure où la population mondiale se regroupe de plus en plus dans des centres urbains, il est important de pouvoir bien modéliser la ville et de mesurer son impact sur son environnement, afin de pouvoir la gérer durablement. Or, l'environnement urbain est fortement influencé en terme d'écologie, d'énergie et de climat par les matériaux qui le constituent, que ceux-ci soient naturels ou artificiels. Il s'agit en effet d'un système complexe caractérisé par une forte hétérogénéité de la géométrie des objets qui le constituent (différents volumes et différents niveaux) et des matériaux qui s'y trouvent. Aussi, des connaissances sur la répartition des matériaux en présence sont effectivement nécessaires à différentes applications de simulation ou de suivi de la ville, comme celles listées par [Heldens *et al.* 2011, Shafri *et al.* 2012]. De telles cartes de matériaux pourraient constituer un niveau supplémentaire de l'occupation du sol à grande échelle de l'IGN dans les zones les plus urbanisées et venir s'intégrer dans une maquette urbaine en complément d'une modélisation 3D des bâtiments et de la végétation [Iovan 2009] (comme le montre la figure 1.4).




FIGURE 1.4 – Exemple de maquette urbaine BATI3D®, modélisant de manière tridimensionnelle les bâtiments et la végétation. Une carte des matériaux pourrait être une sur-couche d'une telle maquette.

Comme il n'existe actuellement pas d'informations sur les matériaux dans les bases de données existantes, ces cartes de matériaux ne pourraient être produites efficacement que de manière (semi-

)automatique par des méthodes de télédétection. Un certain nombre d'applications concernant les matériaux urbains sont décrites ci-dessous. Certaines de ces applications requièrent une connaissance de l'ensemble des matériaux (même avec une nomenclature simple) en présence, tandis que d'autres se focalisent sur un matériau précis, voire sur son niveau de dégradation. Dans ce second cas de figure, une méthode permettant d'accéder à cette information à partir de données de télédétection est souvent associée à l'application.

### 1.3.1 Suivi de flux de polluants

Le suivi de flux de polluants implique d'une part la quantification des flux de polluants émis par certains matériaux urbains, et d'autre part leurs interactions avec les matériaux en présence, notamment avec le sol [IFSTTAR 2013].

#### Quantification de flux de polluants générés par les toitures

Certains matériaux de couverture des toits peuvent générer des éléments polluants [Forster 1996]. Ainsi, dans le cadre de la directive européenne 2000/60 CE qui vise à obtenir des environnements aquatiques en bonne santé, il est nécessaire de s'efforcer de réduire la production des éléments polluants à la source. Ceci implique d'identifier les sources de pollution et de quantifier les flux de polluants réellement émis.

Plusieurs types de pollutions sont générés par les matériaux de toiture. En premier lieu, il a été prouvé que les eaux de ruissellement en provenance des toitures jouent un rôle important dans les fortes concentrations d'éléments métalliques mesurées dans les eaux de pluies urbaines. En effet, des éléments métalliques sont générés par la corrosion des matériaux de toiture, avant d'être emportés par ruissellement lors d'un épisode pluvieux.

En particulier, les matériaux à base de zinc sont employés de manière importante dans les zones urbaines, notamment pour le parement et la toiture des bâtiments, ainsi que sur des éléments linéaires comme les gouttières. Exposé aux conditions atmosphériques, ces matériaux sont progressivement corrodés, et durant un épisode pluvieux, une partie des éléments corrodés qui se sont formés à leur surface sont arrachés et emportés par ruissellement. A Paris, des expériences ont montré que la corrosion atmosphérique des matériaux de toiture pouvait être une source importante de zinc, de cadmium, de plomb et de cuivre au cours d'un épisode pluvieux [Chebbo *et al.* 2001]. Des travaux sur l'identification des métaux en provenance des matériaux de toiture ont montré que les émissions de zinc se trouvent principalement sous une forme assimilable et nocive pour les organismes aquatiques (qu'il s'agisse d'animaux ou de plantes) [Heijerick *et al.* 2002]. Les toits couverts de cuivre peuvent aussi être identifiés comme une possible source de pollution [Forster 1996].

Par ailleurs, d'autres type de matériaux de toiture peuvent relâcher des éléments polluants organiques (comme des composés aromatiques polycycliques, ou du carbone organique) à cause d'une couche invisible de bitume [Lemp et Weidner 2004; 2005].

Des expériences ont été menées en laboratoire afin de modéliser les taux de polluants dans les eaux de ruissellement en provenance des matériaux de toitures, comme par exemple dans [Robert-Sainte 2009, Robert *et al.* 2005] en ce qui concerne les éléments métalliques. Afin de pouvoir extrapoler ces résultats obtenus en laboratoire sur des bancs d'essai à l'intégralité d'un bassin versant, il devient alors nécessaire de disposer de connaissances sur la surface couverte par les différents types de matériaux de toitures. Autrement dit, une carte des matériaux de toiture est alors nécessaire [Le Bris et Robert-Sainte 2009, Cannelle-Martinelli 2005, Gromaire-Mertz *et al.* 1999].

## Interaction de flux de polluants générés par le trafic routier avec l'environnement

Le trafic routier génère des polluants qui interagissent avec le milieu environnant, à la fois lors de leur dispersion dans l'atmosphère, de leur dépôt et enfin de leur transfert dans les sols. Des travaux sont en cours pour modéliser ces interactions, et tout comme dans le cas précédent, ils nécessitent de disposer d'une occupation du sol fine et de cartes de matériaux pour pouvoir passer à l'échelle. Des travaux de ce type sont notamment menés dans le cadre du projet ANR TRAFIPOLLU<sup>10</sup>

### 1.3.2 Surveillance de matériaux dangereux : cas des toits en fibro-ciment à base d'amiante

Une autre application possible concernant les matériaux urbains concerne la surveillance de matériaux dangereux, comme l'amiante-ciment [Heldens *et al.* 2011, Bassani *et al.* 2007, Marino *et al.* 2001]. L'amiante est un matériau dangereux pour la santé humaine. Or certaines toitures sont couvertes par des plaques ou tôles ondulées en fibro-ciment qui en contiennent. En France, la pose de ces matériaux est interdite depuis 1996. Néanmoins, des toitures en amiante-ciment antérieures à cette date sont toujours en place. Par ailleurs, c'est en se détériorant que ces matériaux deviennent nocifs car la poussière qui en émane contient des poussières d'amiante. Par conséquent, il peut être intéressant pour la puissance publique de pouvoir évaluer la quantité de bâtiments encore couverts par des plaques d'amiante-ciment, mais aussi de pouvoir évaluer leur degré de dégradation.

Des méthodes permettant de réaliser ce contrôle à partir de données hyperspectrales ont été proposées et mises en œuvre dans [Bassani *et al.* 2007, Frassy *et al.* 2014, Szabo *et al.* 2014]. Par exemple, [Bassani *et al.* 2007] s'appuient sur quelques bandes spectrales identifiées à partir d'une analyse spectrale menée en laboratoire. Cette analyse se focalise sur la recherche et l'étude des bandes d'absorption de différents constituants (notamment chrysotile) des amiantes-ciments, et s'intéresse en particulier à la profondeur de ces bandes, après application de l'algorithme du "continuum removal" [Clark *et al.* 1990]. L'identification et la caractérisation des amiantes-ciment sur les images hyperspectrales se font ensuite par comparaison des spectres au niveau de ces bandes spécifiques (forme du spectre et profondeur d'absorption) par la méthode de "Spectral Feature Fitting" (SFF) [Clark *et al.* 1992].

### 1.3.3 Modèles de propagation d'ondes électromagnétiques

Cette application possible pour des cartes de matériaux est présentée dans [Carrilero *et al.* 2001]. [Carrilero *et al.* 2001] cherche en effet à obtenir des cartes de matériaux pour enrichir des maquettes 3D de villes utilisées comme donnée d'entrée de simulateurs de propagation d'ondes électromagnétiques. Ces outils sont ensuite utilisés afin de déterminer la meilleure localisation possible pour installer des infrastructures de télécommunication comme des antennes.

### 1.3.4 Suivi de la perméabilité des sols

Deux types d'applications nécessitent une connaissance concernant la perméabilité des sols. Il s'agit d'une part d'effectuer le suivi de politiques publiques concernant la problème d'imperméabilisation des sols, et d'autre part de fournir des données alimentant des modèles hydrologiques fins.

## Suivi de l'imperméabilisation des sols au bénéfice d'une politique publique

Le développement continu de l'imperméabilisation des sols, en particulier en périphérie des villes, avec la création de zones résidentielles et de grands parkings dans les zones commerciales, joue un rôle important dans l'aggravation des phénomènes de crue, à la fois en terme de magnitude et de vitesse. Par ailleurs, sans aller jusqu'à un phénomène de crue, l'accroissement du ruissellement des

10. <https://sites.google.com/site/trafipollu>

eaux pluviales dû à l'imperméabilisation des surfaces peut créer des flux parfois incompatibles avec les capacités des réseaux pluviaux qui n'ont pas toujours évolué en conséquence [Weng 2012]. En outre, l'infiltration est réduite avec pour conséquence une réduction du stockage en eau des nappes souterraines. Enfin, les eaux de pluie ont souvent été considérées comme non polluées mais se chargent par lessivage des sols de divers polluants au point d'être parfois impropres à être rejetées directement dans le milieu naturel. Aussi le degré d'imperméabilisation des sols est devenu un indicateur majeur de qualité environnementale [Weng 2012].

Pour toutes ces raisons, il serait utile de disposer d'outils permettant d'une part de surveiller l'extension des zones imperméabilisées, et d'autre part de vérifier leur conformité aux nouvelles législations.

Par ailleurs, l'article 165 de la loi Grenelle 2 (2010) a modifié la “*taxe pour la gestion des eaux pluviales urbaines*” [Tardivo 2012, Le Nouveau *et al.* 2013]<sup>11 12</sup>. La gestion des eaux pluviales relève des communes qui peuvent instituer une taxe annuelle pour son financement. Cette taxe est due par les propriétaires de terrains privés et publics et repose sur la superficie cadastrale des terrains à partir de laquelle la partie non imperméabilisée peut être déduite. Il serait donc utile de pouvoir disposer d'outils permettant de vérifier la conformité des déclarations des propriétaires de terrain.

## Modélisation hydrologique

Des modèles de simulation hydrologique requièrent comme données d'entrée des cartes de perméabilité du sol [Heldens *et al.* 2011]. Il peut s'agir de micro-hydrologie (en particulier comme expliqué précédemment pour le suivi de polluants emportés par ruissellement) ou d'applications de modélisations hydrologiques classiques.

Par exemple, [Kermadi *et al.* 2010] intègre dans des modèles hydrologiques une occupation du sol extraite par classification à partir de données multispectrales à très haute résolution spatiale (BDOrtho®, ou satellite Quickbird). Bien que cette occupation du sol ne soit pas précisément un cas de “micro”-hydrologie, une carte de matériau aurait parfaitement pu être utilisée en entrée du modèle. D'autres études cartographient la perméabilité des sols dans les zones urbaines par le biais de méthodes de démélange appliquées à des données hyperspectrales à basse résolution spatiale [Roessner *et al.* 2001, Demarchi *et al.* 2012].

### 1.3.5 Détermination du type de revêtement des chaussées et surveillance de l'état des routes

La connaissance du type de revêtement routier (pavés, asphalte, ...) peut être utile pour certaines applications listées par ailleurs, comme la perméabilité des sols et le suivi de polluants. Par ailleurs, le bitume est également une source d'éléments polluants (phénols, hydrocarbures).

Une application plus complexe et potentiellement plus importante concerne la surveillance de l'état des routes. Cette information présente en effet un grand intérêt pour les autorités en charge de la planification des projets de rénovation du réseau routier. L'extraction d'une telle information à partir de données de télédétection aéroportées pourrait être une manière d'éviter des contrôles sur le terrain longs et coûteux [Herold *et al.* 2004b]. Deux exemples de méthodes visant à déterminer l'état des routes à partir de données hyperspectrales sont présentés dans [Herold *et al.* 2004b] et [Mohammadi 2012]. Ces travaux se basent sur des bandes spectrales spécifiques identifiées à l'issue de l'analyse de spectres de routes plus ou moins détériorées.

11. [http://www.developpement-durable.gouv.fr/IMG/pdf/13193-Brochure-infog-taxe-gestion-eaux-pluviales\\_DEF\\_WEB.pdf](http://www.developpement-durable.gouv.fr/IMG/pdf/13193-Brochure-infog-taxe-gestion-eaux-pluviales_DEF_WEB.pdf)

12. [http://www.developpement-durable.gouv.fr/IMG/pdf/Gestion\\_des\\_eaux\\_pluviales\\_urbaines.pdf](http://www.developpement-durable.gouv.fr/IMG/pdf/Gestion_des_eaux_pluviales_urbaines.pdf)



### 1.3.6 Modèles climatologiques

Le climat des villes est également un enjeu important. De manière macroscopique, les villes constituent des îlots de chaleurs, mais d'autres phénomènes plus locaux (variation du vent ou de la température) peuvent être observés. Tous les éléments (végétation, bâtiments, chaussées et sous-sol) du paysage urbain participent aux échanges d'eau et d'énergie entre la surface urbaine et l'atmosphère, et donc au climat local, comme l'illustre la figure 1.5. Aussi, afin de modéliser finement le climat urbain, un modèle climatique de ville doit intégrer à la fois des connaissances sur la topographie (morphologie des bâtiments) et l'occupation du sol, notamment en termes de matériaux, de perméabilité et de végétation [Heldens *et al.* 2011; 2010, Houet et Pigeon 2011, Tournaire *et al.* 2010]. Plusieurs modèles de ville de ce type existent. Le modèle TEB (Town Energy Balance) a été développé par Météo-France,<sup>13</sup> [Tournaire *et al.* 2010]. TEB prend en compte les paramètres de surface ayant une influence significative sur l'atmosphère. La géométrie urbaine y est simplifiée : le modèle ne vise pas à simuler explicitement tous les détails d'un bâtiment ou d'une rue donnée, mais plutôt les processus à l'échelle d'un quartier. Pour chaque maille du modèle, la ville est représentée par une rue-type du quartier définie par sa largeur, la hauteur de ses immeubles, les matériaux utilisés pour le bâti, la couleur et l'isolation des toits et des façades. La résolution actuelle du modèle peut atteindre 100 mètres.

Le modèle SOLENE-microclimat<sup>14</sup> [Bouyer 2009, Idczak *et al.* 2010] modélise les interactions thermo-aérodynamiques à l'échelle du quartier, et permet de simuler l'impact d'aménagements urbains à la fois sur le confort extérieur et la consommation énergétique des bâtiments. Ces aménagements peuvent concerner la forme urbaine, les matériaux de la surface urbaine ou des surfaces naturelles (eau ou végétation). Il peut traiter des géométries urbaines "réelles" et pas seulement des formes comprises dans une grille.

On peut également mentionner les modèles développés par l'équipe *Urban Micromet*<sup>15</sup> dans [Voogt et Grimmond 2000, Grimmond et Oke 2002, Kotthaus *et al.* 2014].

### 1.3.7 Analyse du potentiel solaire des toitures

Certaines études visant à identifier les bâtiments dont la toiture serait propice à l'installation de panneaux photovoltaïques ont pu être réalisées à la fois à des fins de politique publique pour connaître le potentiel solaire d'une région, ou pour des besoins particuliers comme la prospection de potentiels clients par des installateurs. Lorsque des données 3D sont disponibles, elles sont naturellement utilisées et fournissent des informations utiles comme la pente et l'orientation des toitures [Jochem *et al.* 2009]. En l'absence de telles données, une carte des matériaux de toitures s'avère utile [Roy 2010]. On peut en effet associer à certains matériaux certaines caractéristiques de la morphologie de la toiture.

Par ailleurs, à l'inverse, un suivi de la surface de toiture déjà équipée de panneaux photo-voltaïques relève aussi de la problématique des cartes de matériaux.

### 1.3.8 Caractérisation fine de la végétation

Même s'il ne s'agit plus à proprement parler d'un matériau, la végétation joue un rôle important pour l'écosystème urbain, et donc dans certaines des applications précédentes (en particulier celle concernant la météorologie). Il s'agit donc de la caractériser à la fois en terme de distinction entre les différentes strates (pelouse / végétation arbustive / végétation arborée) et en terme d'espèces (i.e. affecter à chaque arbre son essence). Des travaux ont déjà concerné ces différents aspects. Ainsi, [Iovan 2009] a développé une méthode de caractérisation de la végétation urbaine à partir d'images

13. <http://www.meteofrance.fr/activites-recherche/decrypter-le-climat-de-nos-villes/modeliser-la-ville>

14. <http://www.urban-modelling.org/fr/galerie-des-modeles/parcourir-la-galerie/article/solene-microclimat-interactions.html>

15. <http://www.met.reading.ac.uk/micromet/>



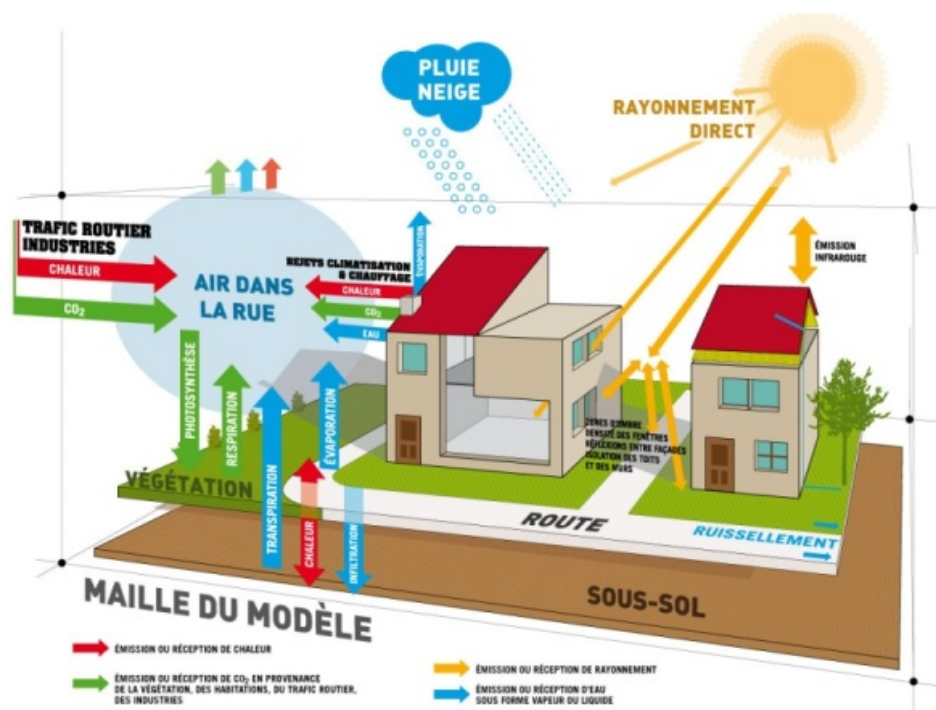


FIGURE 1.5 – Interactions matériaux-environnement pour la modélisation du climat (Source : Météo-France)

aériennes multispectrales et d'un MNS : les arbres sont séparés de la végétation basse, individualisés puis modélisés géométriquement, mais leur essence reste difficile à retrouver. En revanche, [Alonzo *et al.* 2014] utilise des images hyperspectrales pour classer les arbres en fonction de leur essence. En outre, les toitures végétalisées connaissent actuellement un développement important. Il serait donc intéressant de donner à la puissance publique des outils pour être à même d'assurer le suivi de ce phénomène, et de disposer d'indicateurs permettant de le quantifier.

### 1.3.9 Complétion et mise à jour de l'occupation du sol à grande échelle

La plupart des applications mentionnées précédemment concerne plus particulièrement des problématiques de modélisation fine de la ville et considère les cartes de matériaux comme une donnée venant par exemple enrichir une maquette 3D de ville.

A l'inverse, les méthodologies d'extraction de cartes de matériaux à partir de données de télédétection constitueraient une aide à la mise à jour et à la complétion de la BD OCS GE. Par exemple, à son niveau le plus bas, sa nomenclature impose la distinction entre "zones non bâties" (CS1.1.1.2) imperméables (c'est-à-dire les routes et les parkings) et "zones perméables" (qui regroupe les "zones à matériaux minéraux" (CS1.1.2.1) perméables, i.e. les zones de sol nu pierre-terre). Or on ne trouve pas nécessairement d'informations sur ce type de zones dans les bases de données disponibles.

Par ailleurs, la connaissance des types de matériaux en présence dans une zone urbaine donnée pourrait également aider à sa classification en tant qu'usage des sols : on ne trouve par exemple pas les mêmes matériaux dans une zone résidentielle que dans une zone industrielle ou commerciale. Par ailleurs, pour une même famille de matériaux, la signature peut également différer selon l'usage.

## 1.4 La télédétection pour accéder aux matériaux

Comme il n'existe actuellement pas d'informations sur les matériaux dans les bases de données existantes, ces cartes de matériaux ne pourraient être produites efficacement que de manière automatique ou semi-automatique par des méthodes de télédétection. Or la télédétection en milieu urbain reste un sujet de recherche. En effet, les zones urbaines présentent une grande variété de matériaux qui se ressemblent souvent ou présentent au contraire des aspects variables, et sont donc difficiles à identifier automatiquement. En particulier, la variabilité intra-classe d'un matériau peut s'expliquer par sa variabilité intrinsèque, celle liée à sa rugosité, celle liée à ses différentes utilisations et enfin celle liée à ses différentes variétés [Lacherade *et al.* 2005]. Par ailleurs, les images directement disponibles sont des images multispectrales classiques limitées aux 4 canaux bleu-vert-rouge-proche infrarouge. Les résultats que l'on peut obtenir à partir de telles données restent alors souvent limités. Une manière possible d'améliorer les résultats de classification peut alors consister à utiliser des données spectralement plus riches comme celles acquises par un capteur hyperspectral ou superspectral.

Dans la section précédente, on a déjà mentionné pour certaines applications très spécifiques (amiante, état des routes), les processus de télédétection mis en œuvre pour accéder à cette information. On présente ici quelques exemples d'extraction de cartes de matériaux un peu plus généralistes.

Des tests de classification des matériaux de toiture à partir d'images aériennes multispectrales ont été menés [Le Bris et Robert-Sainte 2009, Cannelle-Martinelli 2005]. Les surfaces ne correspondant pas à des zones de toiture étaient masquées en utilisant les objets bâtiments d'une base de données topographique existante. Des résultats considérés comme acceptables pour l'application de suivi de polluants générés par les matériaux de toiture ont été obtenus dans des conditions favorables, à savoir une seule classe de toits métalliques présente sur la zone et des images acquises dans de bonnes conditions (Soleil haut). En revanche, ces résultats se dégradent si la variété des matériaux devient plus importante, et si les conditions d'acquisition des images sont moins favorables.

Pour la même problématique, [Lemp et Weidner 2004; 2005] a utilisé des données hyperspectrales du capteur HyMap en association avec des données Lidar. L'information sur la pente des pans de toits dérivée de ces données 3D apparaît alors comme utiles pour favoriser la discrimination entre certaines classes de matériaux de toiture. Plus récemment, [Chisense 2012] a obtenu de bons résultats à partir de données hyperspectrales HyMap.

De manière plus originale, [Martinoty 2005] calcule des modèles de BRDF à partir d'images multispectrales et de modèles de données 3D, et effectue ensuite une classification non supervisée des matériaux en fonction de ces modèles de BRDF. Les 6 classes obtenues ont ensuite été identifiées comme correspondant aux "ardoise", aux "tuiles oranges", à un regroupement de "bitumes et ciments lambertiens" et à deux types de tôles métalliques. Cette nomenclature reste donc assez simple, et une de ses classes regroupent deux types de matériaux différents.

D'autres comparaisons entre données multispectrales et hyperspectrales existent pour les cartes de matériaux en milieu urbain, et penchent en faveur de l'hyperspectral [Cavalli *et al.* 2008],[Taherzadeh et Shafri 2011, Taherzadeh *et al.* 2012], ou du superspectral [Herold *et al.* 2003; 2004a].

Une méthode spécifique à l'hyperspectral pour la caractérisation des matériaux urbains est présentée dans [Heiden *et al.* 2007] et utilise de manière automatique un certain nombre de caractéristiques spectrales (position et profondeur des bandes d'absorption, ratio entre bandes, aire sous la courbe dans certains domaines spectraux) initialement identifiées par analyse physique des spectres par des experts.

Un certain nombre de travaux [Roessner *et al.* 2001, Franke *et al.* 2009, Heldens *et al.* 2010, Heiden *et al.* 2012, Heldens *et al.* 2009, Demarchi *et al.* 2012, Cavalli *et al.* 2008] utilisant la donnée hyperspectrale pour la caractérisation des matériaux urbains mettent en œuvre des approches de démelange plutôt que de classification. Les approches de classification sont en effet bien adaptées aux

cas où la résolution spatiale des données permet de disposer majoritairement de pixels purs, tandis que le démélange est mieux adapté à des résolutions spatiales moins bonnes pour peu que la résolution spectrale soit riche et que l'on puisse se contenter de ne connaître que les taux de présence des différents matériaux.

Différentes nomenclatures dédiées au traitement des zones urbaines ont été présentées par [Bendor *et al.* 2001, Herold *et al.* 2003, Heiden *et al.* 2007, Franke *et al.* 2009]. D'autres nomenclatures ont été mises en œuvre plus ponctuellement par [Martinoty 2005] ou [Lacherade 2006]. Nous reviendrons dans les chapitres 8 et 9 sur ce problème du choix d'une nomenclature.

## 1.5 Bilan

Il apparaît donc que des connaissances sur les matériaux en présence sont nécessaires pour plusieurs applications de modélisation fine de la ville. Les besoins concernent d'une part la cartographie des matériaux en présence, mais pour des cas plus spécifiques, peuvent aussi concerner la caractérisation de leur état, c'est-à-dire leur niveau de dégradation. Ces cartes de matériaux auraient vocation, d'une part, à venir constituer une couche supplémentaire des bases de données d'occupation du sol à grande échelle, comme celle actuellement en cours de production à l'IGN, et, d'autre part à venir enrichir des maquettes urbaines 3D. Elles devraient donc être fines non seulement sémantiquement, mais aussi géométriquement, avec une résolution qui soit au moins compatible avec celle, métrique, de la base de données d'occupation du sol à grande échelle de l'IGN.

Par ailleurs, la production de cartes de matériaux ne peut raisonnablement se faire que par télédétection, au moyen d'outils de classification supervisée. Toutefois, de par la grande variété des matériaux présents en milieu urbain, mais aussi de leur forte variabilité intra-classe et de leurs similarités inter classes, les matériaux sont difficiles à discriminer en utilisant les capteurs optiques multispectraux traditionnels (limités aux 4 canaux bleu-vert-rouge-proche infrarouge), et une plus grande richesse spectrale s'avère nécessaire.

Dans le chapitre suivant, on va donc se poser la question du capteur de télédétection à utiliser.

---

## Chapitre 2

# Quel capteur ?

### 2.1 Quel capteur utiliser pour produire des cartes de matériaux ?

Ainsi qu'on vient de le voir dans le chapitre précédent, on cherche à produire des cartes de matériaux fines sémantiquement et géométriquement. Elles doivent notamment présenter une résolution spatiale au moins métrique pour être compatibles avec la base de données d'occupation du sol à grande échelle actuellement en production à l'IGN. Par ailleurs, une meilleure résolution spatiale peut être souhaitable, car, lors de l'extraction de carte de matériaux par classification, il vaut mieux avoir les pixels les plus purs possibles. La ville est en effet un environnement localement très hétérogène en terme de matériaux (par exemple, les différentes parties d'un toit peuvent être recouvertes de différents matériaux), aussi une meilleure résolution est nécessaire afin d'éviter d'avoir des pixels mélangés. En outre, le milieu urbain possède un relief très accidenté, aussi les zones d'ombres y sont nombreuses. Là aussi, une résolution spatiale suffisamment fine évitera les problèmes de pixels mixtes ombre/lumière. Il sera alors possible de traiter les zones d'ombre séparément. De nombreuses méthodes permettant de les détecter automatiquement existent en effet [Adeline *et al.* 2013a, Le Bris et Chehata 2011, Boldo 2001, Guo *et al.* 2008b, Li *et al.* 2005; 2004, Liu 2011, Makarau *et al.* 2001, Massalabi *et al.* 2004, Sarabandi *et al.* 2004, Teke *et al.* 2011, Tsai 2006, Wang et Wang 2008, Chung *et al.* 2009, Dare 2005].

On a également vu que l'extraction par télédétection de cartes de matériaux nécessite un capteur plus riche spectralement que les capteurs optiques multispectraux classiques limités aux 4 canaux bleu - vert - rouge - proche infrarouge.

Dans ce chapitre, va donc être posée la question du capteur à utiliser pour cette problématique des cartes de matériaux. Seront d'abord considérés les capteurs hyperspectraux aéroportés, mais aussi leurs limites, en terme de compromis entre résolution spatiale et fauchée, pour l'acquisition de zones étendues.

On s'intéressera ensuite à la tendance actuelle des capteurs spatiaux à présenter à la fois une très haute résolution spatiale et une richesse spectrale de plus en plus grande, afin d'illustrer la notion de capteur superspectral, plus riche spectralement qu'un capteur multispectral, mais ne comportant que les bandes utiles à notre problématique de classification.

### 2.2 Capteurs hyperspectraux aéroportés

L'imagerie hyperspectrale consiste à acquérir une image avec un grand nombre (plusieurs centaines) de bandes spectrales étroites et contiguës. De par sa richesse spectrale, cette donnée offre le potentiel d'une caractérisation de l'occupation du sol plus fine qu'en utilisant les données multispectrales traditionnelles à 3 ou 4 bandes.

Il n'existe actuellement pas de capteur hyperspectral satellite permettant d'atteindre une résolution spatiale compatible avec l'application de classification des matériaux à très haute résolution

spatiale visée.

En revanche, il existe actuellement un certain nombre de capteurs hyperspectraux aéroportés, couvrant généralement à la fois le domaine spectral du visible proche infrarouge ou VNIR (allant de 400 nm à 1000 nm) et le domaine infrarouge ondes courtes ou SWIR (allant de 1000 nm à 2500 nm) (voir figure 2.1). La plupart des capteurs hyperspectraux aériens sont des systèmes à barrette (qui nécessitent donc un système de géoréférencement direct GPS+IMU). Quelques capteurs matriciels, comme par exemple les capteurs Rikola<sup>1</sup>, Cubert-UHD185-Firefly<sup>2</sup>, BaySpec OCI-UAV<sup>3</sup> ou IMEC<sup>4</sup> commencent également à être utilisés en particulier pour des acquisitions à partir de drones et dédiées à de l'agriculture de précision. Ces capteurs sont limités au VNIR.

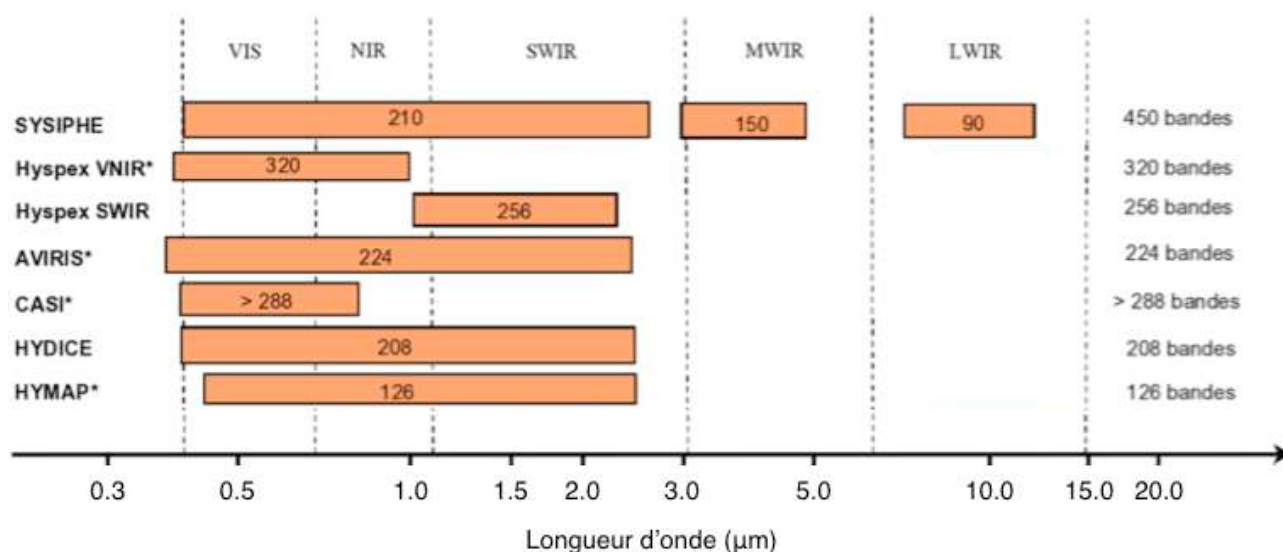


FIGURE 2.1 – Exemples de capteurs hyperspectraux aéroportés. (source : [Briottet et Carrère 2012])


Les capteurs hyperspectraux rendent possible l'acquisition d'information d'une grande richesse spectrale. Toutefois, ils présentent généralement pour une même hauteur de vol une fauchée et une taille de pixel sol moins intéressantes que celles de caméras aériennes multispectrales : à coût de vol identique, les caméras aériennes numériques actuelles permettent donc de couvrir des zones plus importantes avec une résolution spatiale plus fine. A titre d'exemple, lors de la campagne d'acquisition UMBRA [Adeline *et al.* 2013b], deux capteurs hyperspectraux Hypspx (Hypspx-VNIR1600 et Hypspx-SWIR320m-e) étaient installés à bord du même avion qu'une caméra numérique IGN de deuxième génération (CamV2) [Souchon *et al.* 2012]. Ces capteurs ont permis d'acquérir des images de résolution spatiale 0,8 m pour le capteur Hypspx-VNIR et 1,6 m pour le capteur Hypspx-SWIR, contre une résolution de 0,24 m en multispectral natif et de 12 cm en panchromatique et multispectral fusionné pour la caméra IGN (voir figure 2.2). Les fauchées des capteurs Hypspx étaient respectivement de 645 m et de 520 m pour le VNIR et le SWIR, contre 1775 m pour la caméra IGN. Ces chiffres correspondent à des capteurs bien précis, mais sont malgré tout représentatifs d'une tendance générale.

1. <http://www.rikola.fi/hyperspectralcamera.pdf>


2. <http://cubert-gmbh.de/wp-content/uploads/UHD-185.pdf>

3. [www.bayspec.com/spectroscopy/oci-uav-hyperspectral-camera/](http://www.bayspec.com/spectroscopy/oci-uav-hyperspectral-camera/)

4. <http://www2.imec.be/>



HySpex VNIR : 160 bandes / GSD 80cm  
HySpex SWIR : 256 bandes / GSD 1,6 m



IGN CamV2 : 4 bandes / GSD 12 cm





FIGURE 2.2 – Comparaison entre les images acquises par des capteurs hyperspectraux et multispectraux montés sur un même avion. Images hyperspectrales à gauche et caméra numérique (après fusion P+XS) à droite. Les images du bas sont des zooms sur une même zone afin d'illustrer la différence de résolution spatiale entre les capteurs.

## 2.3 Des capteurs satellitaires de plus en plus riches

Si l'on considère l'évolution des capteurs satellites optiques, on peut se rendre compte d'une tendance globale vers des données à la fois de mieux en mieux résolues spatialement et de plus en plus riches spectralement.

Jusqu'à récemment, on pouvait distinguer d'une part des satellites d'acquisition d'images à très haute résolution spatiale mais ne comportant que les traditionnelles bandes bleu-vert-rouge-proche infrarouge, et d'autre part des satellites de télédétection (comme par exemple des satellites comme MODIS ou la famille des Landsat) offrant un panel de bandes un peu plus riche mais une résolution spatiale basse ou moyenne.

La fin des années 1990 et le début des années 2000 ont vu l'avènement des satellites à très haute résolution spatiale, avec des capteurs comme GeoEye, QuickBird, Worldview ou Pléiades. Ces satellites permettent de bénéficier de résolution submétrique (de 0,3 à 0,7 m) en panchromatique et métrique (de 1 à 3m) en multispectral.

Dans un premier temps, les satellites superspectraux, c'est-à-dire spectralement plus riches, sont restés des satellites à basse ou moyenne résolution spatiale. Il s'agissait par exemple des satellites Landsat (Landsat 7 et 8 comportent respectivement 8 et 11 bandes, avec des résolutions spatiales de l'ordre de 30 m pour la plupart des bandes) ou MODIS (36 bandes entre 400 nm et 14 400 nm, mais avec des résolutions spatiales variant entre 250 et 1000 m).

Depuis la fin des années 2000 et le début des années 2010, on observe une tendance en faveur d'une nouvelle génération de capteurs spectralement plus riches et de meilleure résolution spatiale. Dans cette mouvance, on peut citer :

- **RapidEye** (lancés en 2009) qui possèdent une bande sur le *red-edge* en complément des traditionnelles bandes bleu-vert-rouge-proche infrarouge et acquièrent des images multispectrales de résolution 6,5 m
- **Worldview-2** (lancé en 2009) qui comporte 8 bandes spectrales (dans le domaine du visible-proche infrarouge) et acquiert des images multispectrales de résolution 0,46 m en panchromatique et 1,84 m en multispectral.
- **Worldview-3** (lancé en 2014) Il s'agit d'un véritable capteur superspectral comportant 8 bandes dans le visible-proche infrarouge et 8 bandes dans le SWIR. Les résolutions spatiales des images sont de 31 cm en panchromatique, 1,24 m pour les bandes visible - proche infrarouge et 3,7 m pour les bandes du SWIR.
- **Vénus** (lancement prévu en 2016). Ce démonstrateur de satellite superspectral dédié à l'étude de la végétation comportera 12 bandes spectrales dans le visible-proche infrarouge et aura une résolution spatiale de 5,3 m.
- **Sentinel-2** (2015). Même si ce satellite est de résolution spatiale moindre (10-20 m), ce satellite est également un capteur superspectral comportant 12 bandes (6 dans le domaine VNIR et 2 dans le SWIR, mais à une moindre résolution).

Avec les satellites Worldview-3 et la mission Vénus, on peut réellement parler de capteurs superspectraux à haute, voire très haute résolution spatiale.

## 2.4 Une caméra superspectrale dédiée à des problèmes d'occupation du sol spécifiques

Il serait donc intéressant de pouvoir également se doter d'une caméra superspectrale aéroportée dédiée à notre problématique de classification des matériaux, et combinant richesse spectrale et bonne

résolution spatiale pour une fauchée plus intéressante que les capteurs hyperspectraux aéroportés. Un tel capteur ne comporterait que les bandes réellement utiles pour l'application visée de cartographie des matériaux. Des travaux antérieurs ([Herold *et al.* 2003]) ont en effet montré qu'un nombre limité de bandes spectrales était suffisant pour la classification du milieu urbain. Par ailleurs, cette idée de concevoir un capteur superspectral dédié à une application spécifique a déjà été investiguée pour d'autres thématique comme par exemple la pédologie dans [Tavin 2008, Minghelli-Roman 2010].

On pourrait envisager de mettre au point un tel système à partir des caméras numériques modulaires qui ont été développées au laboratoire LOEMI de l'IGN. Actuellement, deux systèmes de prise de vue développés par le LOEMI existent :

- le système CamV2 [Souchon *et al.* 2012] basé sur des capteurs de technologie CCD et dédié aux prises de vue aériennes classiques
- la caméra CamLight [Souchon *et al.* 2015] basée sur des capteurs CMOS. Cette nouvelle caméra est bien plus légère que la précédente, en particulier afin d'être compatible à des prises de vue depuis un drone ou des applications de métrologie terrestre.

Ces systèmes de prise de vue sont en fait constituées de plusieurs têtes de caméras équipées de filtres spectraux, correspondant actuellement aux canaux rouge-vert-bleu et proche infrarouge. L'acquisition de ces différentes têtes de caméra est simultanée. Ces systèmes sont modulaires, et des têtes de caméras supplémentaires pourraient y être ajoutées (jusqu'à une vingtaine dans le cas de la CamLight).

Un tel système de caméra superspectrale ne comportant que les bandes utiles pour notre application présenterait par rapport à un capteur hyperspectral un certain nombre d'intérêts :

- uniquement les bandes utiles (et donc moins de données superflues à stocker)
- la possibilité d'image de résolution spatiale plus fine, tout en ayant une fauchée plus importante
- un capteur matriciel et photogrammétrique, et donc une dépendance plus faible au géoréférencement direct des images
- un capteur matriciel et photogrammétrique permettant des acquisitions d'images multi-stéréoscopique et donc le calcul de modèles de BRDF ([Martigny 2005, Doz 2011])
- moins de contraintes en terme d'étalonnage spectral que pour un capteur hyperspectral

Un bémol important est toutefois à apporter : les capteurs des caméras numériques de l'IGN sont limités au domaine du visible - proche infrarouge, et excluent donc d'utiliser des bandes appartenant au SWIR, or les travaux de [Oltra-Carrio *et al.* 2015] ont montré l'apport de ce domaine spectrale pour améliorer la classification urbaine.

## 2.5 Travail à mener

Dans l'optique de la conception d'une caméra superspectrale dédiée à la problématique des cartes de matériaux urbains, il s'agira donc d'identifier les jeux de bandes spectrales optimaux pour cette problématique d'occupation du sol, autrement dit de déterminer les configurations spectrales qui conduisent à la meilleure discrimination des différents matériaux.

Il s'agit donc de mener un travail d'optimisation spectrale, où l'on s'efforcera de déterminer le nombre de bandes utiles, ainsi que d'optimiser à la fois la position de ces bandes le long du spectre, mais aussi leur largeur. Des bandes plus larges permettent en effet d'intégrer davantage de photons et par conséquent à la fois de nécessiter des temps de pose moins longs et de réduire le bruit. Néanmoins, si elles sont trop larges, on risque également de perdre des informations utiles pour discriminer les matériaux.



Pour mener à bien cette tâche d'optimisation spectrale, des algorithmes de sélection automatique d'attributs seront mis en œuvre.

Ce travail se déroulera en deux temps avec un travail plus méthodologique de mise en place d'outils d'optimisation spectrale suivi de leur application à la problématique de la classification des matériaux.

### **Mise en place d'outils d'optimisation spectrale**

Cette première tâche consistera à définir les méthodes à mettre en œuvre pour ce travail d'optimisation de bandes, et à les valider sur des jeux de données de référence de la littérature.

Il s'agira donc d'abord de faire un inventaire des méthodes de sélection de bandes existantes et de les comparer sur des jeux de données de la littérature. Cette comparaison s'intéressera non seulement à leur capacité à fournir des jeux de bandes discriminants pour la classification, mais aussi à proposer des solutions stables. Cette stabilité des jeux de bandes proposés sera analysée de manière qualitative par le biais de l'étude de profils d'importance des bandes générés à partir de résultats intermédiaires du processus de sélection de bandes.

Ensuite, on s'intéressera à l'optimisation de la largeur des bandes, en étudiant en particulier le processus de fusion des bandes adjacentes. Des critères de fusion de bandes ayant différentes significations (ressemblance/corrélation entre bandes, aptitude à discriminer les différentes classes, ...) seront ainsi testés.

### **Application à la problématique de la classification des matériaux**

La seconde partie du travail consistera à appliquer des algorithmes d'optimisation spectrale définis à l'étape précédente au cas d'étude des matériaux urbains.

On commencera par se poser la question des matériaux pouvant être en présence, en reprenant et en complétant des taxonomies de matériaux urbains.

Des spectres de matériaux urbains seront ensuite collectés à partir de différentes bibliothèques spectrales (ASTER, MEMOIRES, ...) et rangés dans une base de données selon cette nomenclature. C'est à partir de ces données que seront ensuite menées les expériences d'optimisation spectrale.

Au cours du travail d'optimisation spectrale, il s'agira en particulier d'étudier l'impact du nombre de bandes utilisées sur la qualité de la classification. On verra aussi, dans la mesure du possible, l'impact de la légende utilisée sur les configurations spectrales proposées, ainsi que celui de la prise en compte de l'aspect des matériaux (couleur/état) sur la qualité de la classification.

Par ailleurs, il s'agira aussi d'évaluer l'impact sur la classification des matériaux de l'utilisation de bandes appartenant au domaine spectral du SWIR, par rapport à des configurations spectrales composées exclusivement de bandes issues du domaine VNIR. Dans l'optique de la conception d'une caméra superspectrale, ce résultat répondra à l'importante question de savoir s'il est possible de se limiter au domaine du VNIR (ce qui simplifierait la réalisation de la caméra), ou si au contraire il est nécessaire d'étendre le domaine spectral au SWIR.

## Deuxième partie

# Etat de l'art pour la classification et la sélection d'attributs - présentation des bases méthodologiques



## Préambule

Cette partie a pour but de présenter rapidement différents outils, algorithmes et connaissances de l'état de l'art qui seront utilisés dans la suite.

Ainsi, le chapitre 3 présente les algorithmes de classification qui seront utilisés, ainsi que la manière d'évaluer le résultat d'une classification. Les algorithmes de classification seront en effet au cœur des différentes expériences d'optimisation spectrale qui suivront et de la validation des solutions qui seront proposées.

Le chapitre 4 s'intéresse quant à lui à dresser un état de l'art des méthodes de sélection d'attributs. (Une partie de ces méthodes seront testées et comparées dans les expériences du chapitre 6 de la partie III.)

Enfin, le chapitre 5 présente 3 jeux de données hyperspectrales de la littérature qui seront utilisés dans les expériences de la partie III consacrée à la mise en place et à la validation d'outils d'optimisation spectrale.



---

## Chapitre 3

# Méthodes de classification

L'extraction de cartes de matériaux à partir de données de télédétection se fera au moyen d'outils de classification. Aussi les algorithmes de classification seront au cœur des différentes expériences d'optimisation spectrale et de la validation des solutions qui seront proposées. Le but de ce chapitre est donc, après un rapide inventaire de différentes méthodes de classification, de présenter les différents algorithmes de classification qui seront utilisés. On présentera ensuite la manière d'évaluer le résultat d'une classification.

### 3.1 Différents classifieurs

#### 3.1.1 Généralités

##### Définitions

La classification consiste à répartir en fonction d'un critère de similarité un ensemble d'échantillons en plusieurs sous-ensembles appelés classes.

Les échantillons à classer sont décrits par un certain nombre d'attributs, autrement dit par des vecteurs d'une certaine dimension.

On distingue deux types d'algorithmes de classification :

- les algorithmes de classification non supervisée ou clustering, pour lesquels on ne dispose pas de connaissances *a priori* sur la nature des classes en présence. Il s'agit alors de répartir les différents échantillons du jeu de données à classer en différentes classes de manière à ce que les échantillons appartenant à une même classe soient les plus semblables possibles, et que les échantillons appartenant à deux classes distinctes soient au contraire les plus différents possibles. Parmi les algorithmes de clustering, on distingue les méthodes par agglomération comme la classification ascendante hiérarchique, les méthodes de partitionnement comme les k-moyennes (et leurs différentes variantes : k-médoïdes, nuées dynamiques et ISODATA), et les méthodes de type Espérance-Maximisation pour lesquelles on formule l'hypothèse que les échantillons à classer suivent un modèle de mélange gaussien.
- les algorithmes de classification supervisée pour lesquels on fournit au classifieur des connaissances sur les différentes classes que l'on souhaite retrouver. Une méthode de classification supervisée comprend donc une phase d'apprentissage ou d'entraînement au cours de laquelle un modèle de classification est calculé à partir d'échantillons d'apprentissage fournis pour chacune des classes. Le modèle calculé à l'issue de cette étape décrit donc la manière dont le classifieur va modéliser les différentes classes. Par la suite, la classification proprement dite consiste à prédire la classe de tout nouvel échantillon en fonction de ce modèle.

Dans notre cas, les différentes classes seront connues : on utilisera donc exclusivement des algorithmes de classification supervisée.

### Classifieurs génériques

Différents algorithmes de classification supervisée existent. Parmi ceux utilisés de manière générale en télédétection, on peut citer de manière non exhaustive les suivants :

- classification bayésienne avec le classifieur par maximum de vraisemblance (*Maximum Likelihood* ou ML) ou sa variante par Maximum A Posteriori (MAP) [Fauvel *et al.* 2014, Trias-Sanz 2006, Trias-Sanz et Boldo 2005]
- Séparateurs à Vaste Marge (SVM) ou *Support Vector Machines* [Boser *et al.* 1992, Cortes et Vapnik 1995, Vapnik 1998, Belousov *et al.* 2002, Melgani et Bruzzone 2004, Camps-Valls et Bruzzone 2005, Tuia *et al.* 2010, Li *et al.* 2011, Fauvel 2012, Fauvel *et al.* 2012, Roussel 2012]
- Import Vector Machines (IVM) [Zhu et Hastie 2005, Braun *et al.* 2012, Roscher *et al.* 2012a;b]
- Arbres de Décisions ou *Decision Tree* (DT) [Breiman *et al.* 1984]
- Forêts Aléatoires ou *Random Forests* (RF) [Breiman 2001, Pal 2005, Cheung-Wai Chan et Paelinckx 2008, Genuer 2010, Criminisi et Shotton 2013]
- Réseaux de neurones artificiels dont le perceptron multicouche [Le Cun *et al.* 1998, Riedmiller et Braun 1993, Atkinson *et al.* 1997]

### Classifieurs adaptés aux données de grande dimension et en particulier aux données hyperspectrales

Le phénomène de fléau de la dimension ou phénomène de Hughes [Hughes 1968] désigne le fait qu'au delà d'un certain nombre d'attributs, le fait d'ajouter de nouveaux attributs pour décrire les échantillons à classer n'améliore pas la classification, mais risque au contraire de la dégrader. Toutefois, si les classifieurs classiques comme par exemple les classifieurs bayésiens sont sensibles à ce phénomène, les approches plus modernes comme les SVM, les IVM ou les RF y sont peu sensibles [Melgani et Bruzzone 2004, Camps-Valls et Bruzzone 2005, Braun *et al.* 2012] et parviennent malgré tout à produire de bons résultats, sauf dans des cas où très (trop) peu de données d'apprentissage sont disponibles [Pal et Foody 2010]. Ces classifieurs sont également capables dans une certaine mesure de gérer des variabilités intra-classe importante, autrement dit des classes multimodales présentant des aspects différents.

D'autres méthodes utilisées plus généralement pour les données de grande dimension, dont la donnée hyperspectrale, sont par exemple les méthodes basées sur des graphes [Camps-Valls *et al.* 2007] : chaque pixel est considéré comme un nœud du graphe, tandis que les arêtes portent des mesures de similarité entre nœuds, le problème de classification devenant alors un problème de coupe de graphe. Ces méthodes peuvent s'adapter à un apprentissage semi-supervisé ainsi qu'à l'introduction directe d'une régularisation spatiale.

Il est aussi possible de combiner plusieurs classifieurs de manière à construire un **ensemble de classifieurs** permettant d'obtenir de meilleurs résultats. Ainsi, dans le cas de données hyperspectrales, [Prasad et Bruce 2008, Bigdeli *et al.* 2013, Bruce 2014] proposent de définir par clusterisation des groupes de bandes corrélées. Un classifieur SVM est alors associé à chacun de ces groupes de bandes. Le label finalement attribué à un échantillon à classer est obtenu par vote majoritaire de ces différents classifieurs.

Certains classifieurs sont plus spécifiques à la donnée hyperspectrale : il s'agit notamment des classifieurs basés sur les mesures suivantes :

- l'angle spectral ou Spectral Angle Mapper [Price 1994]
- la mesure "Spectral Information Divergence" ou SID [Chang 2000]
- une mesure nommée SID-SAM et combinant les deux mesures précédentes du SAM et du SID [Du *et al.* 2004]

Dans le cas de l'analyse de données hyperspectrales, certaines méthodes très spécifiques basées sur des connaissances expert existent également (comme le système Tetracorder [Clark *et al.* 2003] pour la caractérisation de certains minéraux, ou [Heiden *et al.* 2007] pour différents matériaux urbains). Elles se basent sur des analyses des spectres d'un point de vue plus physique et prennent notamment en compte la présence de comportements particuliers le long du spectre comme par exemple des bandes d'absorption spécifiques à certains composés, ainsi que la profondeur de ces bandes d'absorption. Ainsi, [Clark *et al.* 1992; 2003] identifient des minéraux dans les images hyperspectrales par comparaison des spectres avec les spectres de l'image au voisinage de bandes spécifiques identifiées préalablement pour chaque minéral par des experts. Sont alors comparées à la fois la forme du spectre et la profondeur de cette bande d'absorption, par la méthode de "Spectral Feature Fitting" (SFF) [Clark *et al.* 1992]. L'approche d'[Heiden *et al.* 2007] utilise quant à elle dans un processus de classification supervisée (SVM) un certain nombre de indices décrivant différentes caractéristiques spectrales (position et profondeur des bandes d'absorption, ratio entre bandes, aire sous la courbe dans certains domaines spectraux) initialement identifiées par analyse physique des spectres par des experts.

Un autre point concerne d'ailleurs le fait d'utiliser directement les données radiométriques (qu'elles soient en luminance ou réflectance), ou des indices dérivés à partir de ces mesures. De tels indices peuvent être des différences, des ratios entre bandes, ou encore des différences normalisées à l'exemple du célèbre indice *NDVI*, voire d'autres indicateurs de la forme du spectre (comme par exemple la pente ou encore l'aire sous la courbe) [Heiden *et al.* 2007]. Ce type d'indice peut en effet s'avérer plus discriminant que les bandes originales pour certains phénomènes.

Dans les expériences qui suivront, les classifieurs qui seront utilisés seront le classifieur par maximum de vraisemblance, les SVM, les arbres de décisions et les RF, ainsi que le SAM, le SID et le SID-SAM. Le principe de ces classifieurs est rapidement décrit dans les paragraphes qui suivent. Ces différents classifieurs ont été choisis car ils présentent l'intérêt d'avoir des caractéristiques et des comportements différents. En particulier, certains d'entre eux modélisent directement la radiométrie des classes (au sens d'une distribution statistique pour le classifieur ML/MAP, par des spectres de référence pour le SAM ou le SID), tandis qu'à l'inverse d'autres algorithmes (SVM, DT et RF) cherchent à modéliser les frontières entre classes. Ces derniers seront dès lors plus enclins à tolérer une multimodalité des classes, c'est-à-dire une variabilité intra-classe importante.

### 3.1.2 Classifieurs spécifiques à la donnée hyperspectrale : SAM, SID et SID-SAM

Ces différents classifieurs fonctionnent tous de la même manière qui consiste à calculer une mesure de similarité entre un échantillon à classer et un spectre de référence. L'échantillon à classer se voit alors attribuer le label du spectre de référence dont il est le plus similaire.

**SAM** L'angle spectral ou *Spectral Angle Mapper* ou **SAM** consiste à calculer l'angle entre deux spectres. Plus cet angle est faible, plus les deux spectres se ressemblent. Le spectre à classer se voit donc affecter la classe du spectre dont il est le plus proche au sens du SAM. Ce classifieur offre l'avantage de faire preuve d'une bonne robustesse aux variations d'intensité, et est donc relativement indépendant des conditions d'illuminations de la scène. L'angle spectral se calcule comme suit (avec 2



spectres  $\vec{a}$  et  $\vec{b}$ , i.e. 2 vecteurs de dimension  $N$ ,  $N$  désignant le nombre de bandes).

$$SAM(\vec{a}, \vec{b}) = \cos^{-1} \left( \frac{\vec{a} \cdot \vec{b}}{\|\vec{a}\| \cdot \|\vec{b}\|} \right)$$

**SID** Le **SID** ou **Spectral Information Divergence** présenté dans [Chang 2000] trouve son origine dans les mesures de dissimilarité entre distributions statistiques, et notamment la formule de Kullback-Leibler.

$$SID(\vec{a}, \vec{b}) = \sum_{i=1}^N p(\vec{a})_i \cdot \log \left( \frac{p(\vec{a})_i}{p(\vec{b})_i} \right) + p(\vec{b})_i \cdot \log \left( \frac{p(\vec{b})_i}{p(\vec{a})_i} \right)$$

pour  $\vec{a} = [a_1 \dots a_i \dots a_N]$  et  $\vec{P}(\vec{a}) = [p(\vec{a})_1 \dots p(\vec{a})_i \dots p(\vec{a})_N]$  avec  $p(\vec{a})_i = \frac{a_i}{\sum_{i=1}^N a_i}$

**SID-SAM** : les deux mesures précédentes peuvent être combinées de manière à être utilisées conjointement, ainsi que le proposent [Du *et al.* 2004] en calculant :

$$SID(\vec{a}, \vec{b}) \cdot \sin(SAM(\vec{a}, \vec{b}))$$

Un exemple d'utilisation récente de cette mesure est donné par [Mende *et al.* 2011].

En pratique, dans les expériences qui suivront, on prendra comme spectre de référence pour chacune des classes le spectre médian des différents échantillons d'apprentissage.

Remarque : On utilise parfois sur la valeur de ces mesures un seuil au delà duquel on renonce à donner un label au spectre à classer considérant qu'il est trop différent du spectre de référence le plus proche. Dans les expériences qui suivront, on souhaite classer tous les échantillons, et on n'utilisera donc pas de tel seuil.

### 3.1.3 Classification bayésienne

Dans les expériences qui suivent, on a utilisé un classifieur par **maximum de vraisemblance** (*Maximum Likelihood* ou *ML*) avec modélisation de distribution de la radiométrie des classes par un modèle de mélange gaussien. Ce modèle suppose que chaque échantillon est la réalisation d'un vecteur de variables aléatoires de dimension  $d =$  nombre de bandes tel que :

$$p(\mathbf{x}) = \sum_{c=1}^{N_c} p(c)p(\mathbf{x}|c)$$

avec  $p(c)$  la probabilité *a priori* de rencontrer la classe  $c$  et  $N_c$  le nombre de classes. Dans le cas où les classes sont équiprobables,  $p(c) = \frac{1}{N_c} \forall c$  et  $p(\mathbf{x}|c)$  modélisant la distribution radiométrique de la classe  $c$  par une gaussienne  $\mathcal{N}(\mu_c, \Sigma_c)$ . Autrement dit,

$$p(\mathbf{x}|c) = \frac{1}{(2\pi)^{\frac{d}{2}} \det(\Sigma_c)^{\frac{1}{2}}} e^{-\frac{1}{2} (\mathbf{x}-\mu_c) \Sigma_c^{-1} (\mathbf{x}-\mu_c)}$$

On pourra toutefois remarquer qu'il aurait également été possible d'utiliser des lois statistiques paramétriques différentes de la loi gaussienne ou non paramétriques (histogramme lissé) pour modéliser la distribution radiométrique de chacune des classes, comme par exemple dans [Trias-Sanz 2006, Trias-Sanz et Boldo 2005].

Par application de la formule de Bayes,

$$p(c)p(\mathbf{x}|c) = p(\mathbf{x})p(c|\mathbf{x})$$

On en déduit donc la probabilité d'appartenance à la classe  $c$  connaissant l'échantillon  $\mathbf{x}$  :

$$p(c|\mathbf{x}) = \frac{p(c)p(\mathbf{x}|c)}{p(\mathbf{x})}$$

Comme  $p(\mathbf{x}) = cte$  et que l'on fait l'hypothèse que les classes sont équiprobables ( $p(c) = \frac{1}{N_c}$ ),

$$p(c|\mathbf{x}) = cte.p(\mathbf{x}|c)$$

La classe  $\hat{c}$  qui sera attribuée à l'échantillon  $\mathbf{x}$  est la plus probable connaissant sa radiométrie, autrement dit

$$\hat{c} = \operatorname{argmax}_c p(c|\mathbf{x}) = \operatorname{argmax}_c p(\mathbf{x}|c)$$

On parlera de classifieur par maximum de vraisemblance lorsque l'on considère que les différentes classes sont *a priori* équiprobables et de classifieur par maximum *a posteriori* dans le cas contraire. Dans le cadre des expériences qui suivent, on a considéré que les classes étaient *a priori* équiprobables.

### 3.1.4 Séparateurs à Vaste Marge (SVM)

Les classifieurs de type séparateurs à vaste marge ont été introduits progressivement au cours des années 1990 par [Boser *et al.* 1992, Cortes et Vapnik 1995, Vapnik 1998]. Ils ont depuis été utilisés pour de nombreuses applications, et notamment dans le domaine de la télédétection où leur forte capacité de généralisation leur permet d'obtenir de bons modèles et donc de bons résultats à partir de jeux d'apprentissage réduits. Par ailleurs, ce classifieur est peu sensible au phénomène de fléau de la dimension, et permet donc de traiter des données de grande dimension [Melgani et Bruzzone 2004, Camps-Valls et Bruzzone 2005] parvenant à produire de bons résultats, sauf dans des cas où très (trop) peu de données d'apprentissage sont disponibles [Pal et Foody 2010].

Les SVM ont été définis originellement pour des problèmes de classification binaire entre deux ensembles linéairement séparables, puis ont été étendus à des problèmes impliquant davantage de classes pas nécessairement linéairement séparables. Leur principe repose sur un certain nombre de notions importantes.

#### Notion de marge maximale

Soit un ensemble de  $n$  échantillons d'apprentissage  $\{\mathbf{x}_i, y_i\}_{i=1, \dots, n}$ ;  $y_i \in \{-1, +1\}$ , avec  $\mathbf{x}_i$  le vecteur d'observations (i.e. les attributs) associé à l'échantillon  $i$  et  $y_i$  le label qui lui est associé.

Le principe des SVM a été originellement établi pour des problèmes de classification binaire pour lesquelles les 2 classes sont linéairement séparables, autrement dit des cas où il est possible de séparer les 2 classes par un hyperplan dans l'espace des attributs. Néanmoins, sans contrainte complémentaire, cette solution n'est pas unique : il peut même exister une infinité d'hyperplans séparant les 2 classes (voir figure 3.1). La première idée des SVM a été d'introduire la notion de marge maximale. Autrement dit, les SVM vont rechercher l'hyperplan séparant les 2 classes, en maximisant la généralisation de la classification, c'est-à-dire en recherchant l'hyperplan qui sépare le mieux les échantillons d'apprentissage (d'où la notion de vaste marge). L'apprentissage d'un classifieur SVM consiste donc à rechercher la meilleure frontière linéaire entre les classes dans le sens de celle qui maximise la marge, cette dernière étant définie comme la distance entre la frontière de séparation et les échantillons les plus proches.

Mathématiquement, cela revient à chercher un vecteur  $\mathbf{w}$  et un biais  $b$  vérifiant l'équation suivante :

$$\min_{\mathbf{w}, b} \|\mathbf{w}\|^2 \text{ avec } \forall i, y_i. (\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1$$

Il a été montré que la solution  $\mathbf{w}$  à ce problème peut s'exprimer à partir des échantillons de l'ensemble d'apprentissage sous la forme suivante :

$$\mathbf{w} = \sum_{i=1}^n \alpha_i y_i \mathbf{x}_i \quad \text{avec} \quad \forall i, \alpha_i \geq 0$$

Les échantillons d'apprentissage  $\mathbf{x}_i$  pour lesquels les coefficients  $\alpha_i$  sont non nuls sont appelés **vecteurs support**, et suffisent donc à définir l'équation de l'hyperplan séparateur entre les classes. Ce sont également les échantillons de l'ensemble d'apprentissage les plus proches de cet hyperplan. La largeur de la marge vaut alors  $\frac{2}{\|\mathbf{w}\|}$  et constitue une mesure du degré de généralisation du modèle calculé.

Classifier une nouvelle observation  $\mathbf{x}$  revient donc à savoir de quel côté de l'hyperplan elle se trouve, autrement dit à s'intéresser au signe de  $\mathbf{w} \cdot \mathbf{x} + b$ .

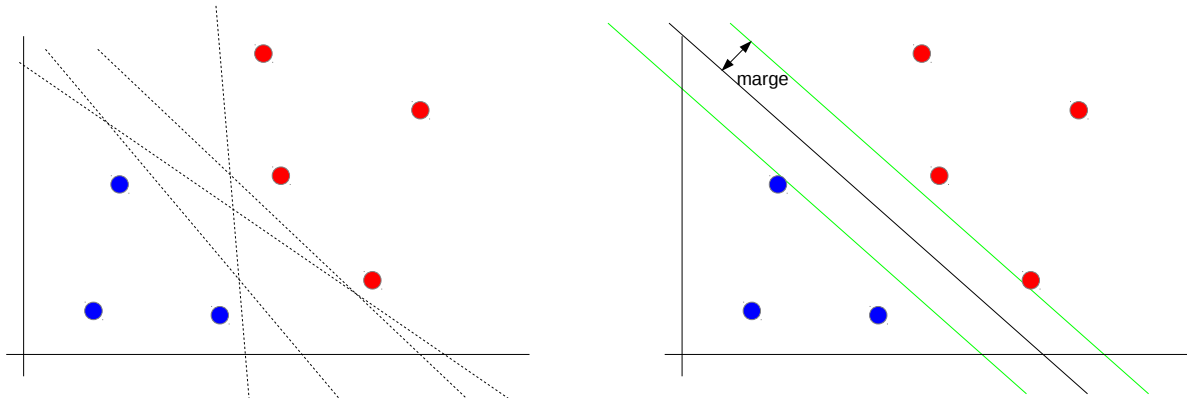


FIGURE 3.1 – A gauche, multiplicité de frontières linéaires possibles sans contrainte de marge. A droite, une seule frontière possible maximisant la marge.

### Prise en compte d'une certaine souplesse par rapport à la présence d'*outliers*

Toutefois, les classes ne sont généralement pas parfaitement linéairement séparables (à cause de bruit dans les observations des échantillons d'apprentissage, voire de la présence d'*outliers*). Dans ce cas, la contrainte introduite précédemment ne peut pas être respectée. Il est alors possible de relâcher cette contrainte en introduisant un terme de distance à l'hyperplan  $\{\xi_i\}_{i=1\dots n}$  et une contrainte pénalisant les  $\xi_i$  trop forts, qui correspondent alors vraisemblablement à des valeurs aberrantes. L'équation à résoudre pour calculer la séparatrice devient alors :

$$\min_{\mathbf{w}, b} \left\{ \|\mathbf{w}\|^2 + C \sum_{i=1}^n \xi_i \right\} \quad \text{avec} \quad \forall i, y_i(\mathbf{w} \cdot \mathbf{x}_i + b) \geq 1 - \xi_i.$$

Le paramètre  $C$  introduit dans cette formule va permettre de régler la pénalisation liée aux valeurs aberrantes présentes parmi les échantillons d'apprentissage. Il va donc contrôler le niveau de généralisation du modèle calculé par les SVM. Plus la valeur de  $C$  sera forte, et plus les mauvaises classifications seront pénalisées, mais parfois au risque de faire du sur-ajustement et de manquer de généralisation. À l'inverse, une trop faible valeur de  $C$  pourrait conduire à une généralisation trop importante. Cependant, en pratique les SVM restent assez peu sensibles à de grandes variations de  $C$  [Belousov *et al.* 2002].

## Extension à des problèmes non linéairement séparables : changement d'espace et utilisation de noyaux

Il existe toutefois des problèmes qui ne sont pas vraiment linéairement séparables. La solution proposée pour pouvoir les traiter à l'aide des SVM consiste à transformer au moyen d'une fonction non-linéaire  $\phi$  les données de manière à les reprojeter dans un espace de plus grande dimension, dans lequel le problème devient linéairement séparable.

Ainsi qu'il a été dit plus tôt, classer une nouvelle observation  $\mathbf{x}$  revient simplement dans le cas linéairement séparable à savoir de quel côté de l'hyperplan elle se trouve, autrement dit à s'intéresser au signe de  $\mathbf{w} \cdot \mathbf{x} + b$ , c'est-à-dire à s'intéresser à la valeur du produit scalaire entre les vecteurs  $\mathbf{w}$  et  $\mathbf{x}$ . Dans le cas initialement non linéairement séparable, classer une nouvelle observation va donc revenir à s'intéresser au signe de  $\phi(\mathbf{w}) \cdot \phi(\mathbf{x}) + b$ .

En pratique, cette projection ne se calcule pas de manière explicite, mais s'effectue par le biais de l'utilisation d'une fonction noyau (définie positive)  $K$  :

$$K(\mathbf{a}, \mathbf{b}) = \phi(\mathbf{a}) \cdot \phi(\mathbf{b}).$$

Classer une nouvelle observation revient alors simplement à considérer le signe de  $K(\mathbf{w}, \mathbf{x}) + b$ .

On peut donc considérer que l'apprentissage d'un classifieur SVM revient à définir un indice dérivé à partir des attributs  $K(\mathbf{w}, \mathbf{x})$  et un seuil ( $-b$ ) permettant de classer les échantillons en fonction de cet indice.

Une multitude de noyaux sont possibles. Le noyau gaussien ou RBF (*radial basis function*)  $K(\mathbf{a}, \mathbf{b}) = \exp^{-\gamma \|\mathbf{a} - \mathbf{b}\|^2}$  apparaît comme l'un des plus utilisés dans la littérature. Le paramètre  $\gamma$  permettant de paramétrer l'écart-type de la gaussienne. Il s'agit de bien le choisir, car, tout comme la contrainte  $C$  de tolérance de généralisation du classifieur, il a un impact sur la qualité de la classification. En pratique, ces deux paramètres sont généralement déterminés conjointement par validation croisée [Hsu *et al.* 2003], ce qui peut prendre un peu de temps. On notera toutefois que d'autres méthodes plus rapides pour l'optimisation de ces paramètres existent [Fauvel 2012, Li *et al.* 2012].

D'autres noyaux sont également utilisés, comme les noyaux polynomiaux ou sigmoïdes existent également [Hsu *et al.* 2003]. On pourra aussi noter que des noyaux reprenant la fonction du SAM ont été proposés spécifiquement pour les données hyperspectrales [Fauvel *et al.* 2006, Fauvel 2007, Mercier et Lennon 2003]. Par ailleurs, l'utilisation de noyaux composites comme la somme de plusieurs noyaux élémentaires peut permettre une meilleure prise en compte de données hétérogènes (comme par exemple des informations de texture et des informations radiométriques) [Fauvel 2007]. Le cas extrême est alors d'utiliser un noyau par attribut : on parle alors de SVM à noyaux multiples [Tuia *et al.* 2010, Gu *et al.* 2012].

## Gestion des problèmes multi-classes

Les SVM ont été initialement conçus pour des classifications binaires. Plusieurs stratégies ont été proposées pour les adapter à des problèmes de classification impliquant davantage de classes. Les approches proposées consistent principalement à transformer un problème multi-classes impliquant  $n_c$  classes en un ensemble de classifications binaires. Deux stratégies sont alors possibles [Huang *et al.* 2002, Melgani et Bruzzone 2004, Camps-Valls et Bruzzone 2005] : le "un-contre-tous" (on essaie alors de séparer chaque classe par rapport à l'ensemble des autres classes, ce qui conduit à  $n_c$  problèmes binaires) ou le "un-contre-un" (on a alors  $\frac{n_c \cdot (n_c - 1)}{2}$  problèmes binaires impliquant à chaque fois deux des classes). Dans les deux cas, il s'agit ensuite de fusionner les résultats de ces différents sous-problèmes binaires, par exemple par vote majoritaire dans le cas du "un-contre-un".

## Mesures d'appartenance aux classes

De par leur principe, les SVM multi-classes se limitent à fournir une labellisation. Or, il est utile de disposer également d'une mesure d'appartenance, i.e. de probabilités d'appartenance, aux différentes

classes, afin notamment d’avoir une idée de la confiance du résultat obtenu.

Différents modèles ont donc été proposés afin de fournir des probabilités d’appartenances aux différentes classes, comme par exemple [Platt 2000, Xu *et al.* 2014]. La méthode de Platt [Platt 2000] permet d’abord d’estimer des probabilités d’appartenance à chacune des classes dans le cas d’une classification binaire. La probabilité est alors estimée en ajustant un modèle de régression logistique aux résultats de la classification. [Wu *et al.* 2004] utilisent ensuite les probabilités des différentes classifications de type un-contre-un pour calculer une probabilité d’appartenance à chacune des classes d’un problème multi-classe.

## Variantes des SVM

De nombreuses variantes des SVM existent. On peut notamment citer parmi ces variantes le classifieur *Support Vector Data Description* (SVDD) proposé dans [Tax et Duin 2004]. L’idée de base des SVDD est de considérer qu’il est possible pour chaque classe de définir une hypersphère contenant tous les échantillons appartenant à cette classe et en dehors de laquelle se trouvent les échantillons des autres classes. Si cette situation n’est pas vérifiée pour certains problèmes, il est possible de s’y ramener par l’utilisation de fonctions noyaux tout comme les SVM les utilisaient pour ramener les cas non linéairement séparables à des problèmes linéairement séparables.

## Utilisation des SVM en pratique

Dans les expériences qui suivront, on se trouvera toujours face à des problèmes multi-classes. En pratique, c’est l’implémentation du classifieur SVM “un-contre-un” de la *LibSVM* [Chang et Lin 2011] qui sera utilisée. Lorsque le classifieur SVM sera utilisé avec un noyau gaussien, l’optimisation des paramètres se fera par validation croisée. En pratique, l’utilisation d’un classifieur SVM avec un noyau gaussien optimisé permet généralement d’obtenir de très bons résultats de classification, et de trouver de bonnes frontières entre classes, même dans des cas où celles-ci présentent un aspect plutôt chaotique. En revanche, l’optimisation des paramètres de noyau et de généralisation peut être coûteuse en temps de calcul. Aussi, dans la suite, lorsque l’on aura besoin de travailler assez vite, par exemple pour tester différentes combinaisons de bandes, et d’utiliser un classifieur permettant de bien décrire les frontières des classes, on utilisera plutôt les Forêts Aléatoires, plus rapides.

### 3.1.5 Arbres de décision

Il existe plusieurs types d’arbres de décision. Dans notre cas, on s’est limité aux arbres CART (*Classification and Regression Tree*) proposés par [Breiman *et al.* 1984].

La construction d’un arbre de décision (i.e. son apprentissage) s’effectue de manière récursive. On part d’un nœud racine contenant la totalité des échantillons d’apprentissage. Ce nœud est ensuite scindé en deux parties par un seuil sur les valeurs d’un des attributs de manière à optimiser un certain critère, puis de manière récursive, chaque nouveau nœud est également découpé.

Dans le cas présent, le critère utilisé est l’indice de Gini. Cet indice permet de mesurer la pureté d’un nœud, autrement dit dans quelle mesure les échantillons d’apprentissage qu’il contient constituent un mélange de classes. Il se calcule de la manière suivante pour un nœud  $\mathcal{N}$  constitué d’échantillons appartenant à  $n_c$  classes distinctes :

$$Gini(\mathcal{N}) = 1 - \sum_{c=1}^{n_c} p_c^2$$

avec  $p_c$  désignant la fréquence d’apparition relative de la classe  $c$  parmi les échantillons de  $\mathcal{N}$ .

On souhaite ici découper notre nœud  $\mathcal{N}$  en deux nœuds  $\mathcal{N}_1$  et  $\mathcal{N}_2$  ( $\mathcal{N}_1 \cap \mathcal{N}_2 = \emptyset$  et  $\mathcal{N} = \mathcal{N}_1 \cup \mathcal{N}_2$ ) les plus purs possibles au sens de l’indice de Gini. On cherche donc à trouver à la fois l’attribut et le seuil

sur cet attribut qui permet de minimiser  $card(\mathcal{N}_1).Gini(\mathcal{N}_1) + card(\mathcal{N}_2).Gini(\mathcal{N}_2)$ . (Ce découpage peut aussi s'effectuer sur plusieurs attributs.)

Ce découpage récursif s'arrête quand un critère d'arrêt est atteint (comme par exemple, lorsque l'effectif des nœuds devient inférieur à un seuil ou lorsque la profondeur de l'arbre dépasse un certain seuil). Il est aussi possible d'appliquer des post-traitements, notamment afin d'élaguer l'arbre *a posteriori* [Breiman *et al.* 1984].

D'un point de vue pratique, dans les expériences qui suivent, c'est l'implémentation des arbres de décision de la librairie de traitement d'image *OpenCV* qui a été utilisée [Bradski 2000].

### 3.1.6 Forêts Aléatoires ou Random Forests (RF)

#### Principe

Les Forêts Aléatoires ou Random Forests ont été proposées par [Breiman 2001]. Ce classifieur est en fait un ensemble de classifieurs : il se présente en effet comme l'agrégation d'un ensemble d'arbres de décisions CART) (figure 3.2).

L'idée des RF repose sur deux grands principes permettant d'améliorer les performances d'un classifieur : le *bagging* et le *random subspace*. Le *bagging* [Breiman 2001] consiste à construire un ensemble de classifieurs en dupliquant un même classifieur et en l'entraînant sur différents ensembles d'apprentissage, composés d'échantillons sélectionnés aléatoirement avec remise dans l'ensemble d'apprentissage original. On obtient alors des prédicteurs différents qui fournissent chacun une prédiction de label pour un échantillon à classer. Le label finalement attribué est alors par exemple déterminé par vote majoritaire. Le bagging permet d'améliorer la qualité de la classification obtenue, par rapport à un classifieur unique dont l'apprentissage aurait été calculé à partir de tous les échantillons de l'ensemble d'apprentissage. Le *random subspace* [Ho 1998] consiste à construire un ensemble de classifieurs en dupliquant un même classifieur, mais cette fois en l'entraînant à partir de sous-ensemble d'attributs sélectionnés aléatoirement.

L'apprentissage d'un classifieur RF à partir d'un ensemble d'échantillons d'apprentissage  $A$  se déroule de la manière suivante. Le classifieur RF construit un ensemble d'arbres de décisions  $i$ . Chacun de ces arbres de décision  $i$  est construit à partir d'un sous-ensemble d'apprentissage  $A_i$  composé d'échantillons sélectionnés aléatoirement (avec remise) dans le jeu de données d'apprentissage initial  $A$  (avec  $card(A) > card(A_{T_i})$ ). Par ailleurs, les différents attributs ne sont pas tous pris en compte lors de la construction de ces arbres. Ainsi lors du découpage d'un nœud d'un des arbres, seul un sous-ensemble de  $m$  attributs (choisis aléatoirement) est pris en considération ; le meilleur attribut au sens de la mesure de Gini est alors utilisé pour découper le nœud.

Les paramètres qui entrent en jeu lors de la construction d'un classifieur RF sont donc le nombre d'arbres (fixé arbitrairement à une valeur importante) et le nombre  $m$  d'attributs tirés lors de chaque découpage du nœud d'un des arbres (généralement fixé à la valeur de la racine carré du nombre d'attributs).

La fusion de ces différents classifieurs s'effectue ensuite par vote majoritaire : chacun de ces arbres de décision prédit ensuite un label à un nouvel échantillon à classer, et le label qui lui est finalement attribué est celui qui reçoit le plus grand nombre de votes.

Remarque : Différentes variantes du classifieur RF existent [Criminisi et Shotton 2013], parmi lesquelles on peut citer les *Random Ferns* plus rapides et donnant des résultats similaires.

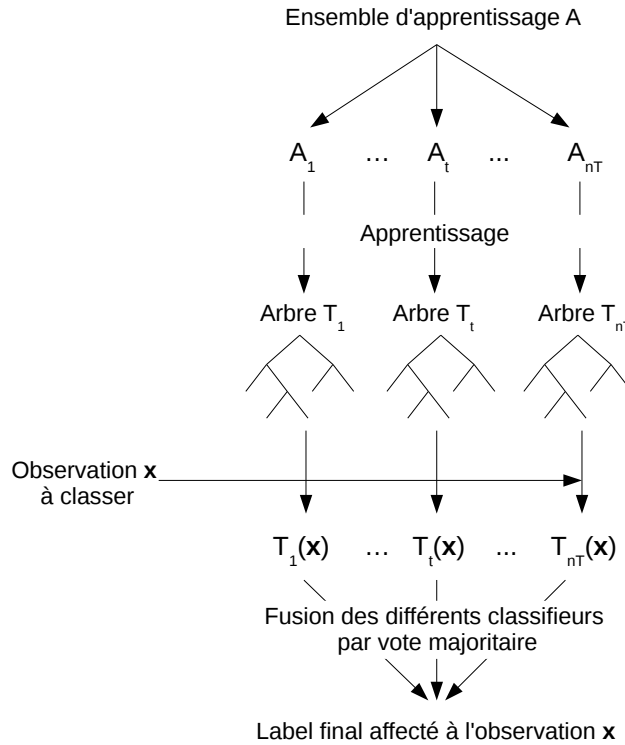


FIGURE 3.2 – Principe des forêts aléatoires (apprentissage et classification)

### Mesure d'appartenance aux différentes classes

Les RF fournissent spontanément des mesures d'appartenance des échantillons à classer aux différentes classes. En effet, la fusion des différents arbres de décision constituant la forêt s'effectue par vote majoritaire. Aussi, pour un échantillon donné, le nombre de votes  $v_c$  obtenus par une classe  $c$  constitue une mesure d'appartenance à cette classe  $c$ . Il est alors possible de normaliser cette valeur en la divisant par le nombre total  $n_T$  d'arbres.

Il est aussi possible d'en déduire une mesure de confiance de la classification d'un échantillon. Cette mesure de confiance nommée "marge" a été introduite par [Breiman 2001]. La marge non supervisée d'un échantillon se définit comme la différence normalisée par le nombre total  $n_T$  d'arbres entre le nombre de votes reçus par la classe en ayant reçu le plus et le nombre de votes reçus par la classe ayant reçu le second plus grand nombre de votes. La marge non supervisée d'un échantillon  $\mathbf{x}$  s'obtient donc par la formule suivante :

$$\text{marge\_non\_supervisée}(\mathbf{x}) = \frac{v_{c1} - v_{c2}}{n_T} \quad \text{avec } c1 = \operatorname{argmax}_c v_c \quad \text{et } c2 = \operatorname{argmax}_{c \neq c1} v_c$$

La marge supervisée d'un échantillon se définit comme la différence normalisée par le nombre total  $n_T$  d'arbres entre le nombre de votes reçus par la classe de cet échantillon et l'ensemble des votes reçus par les autres classes. La marge supervisée d'un échantillon  $\mathbf{x}$  de classe  $y$  se calcule donc par la formule suivante :

$$\text{marge\_supervisée}(\mathbf{x}, y) = \frac{v_y - \sum_{c \neq y} v_c}{n_T}$$

Si l'échantillon a été bien classé, cette mesure est positive. Dans le cas contraire, elle est négative.

Cette mesure donne donc une information sur la confiance du classifieur. Plus la valeur absolue de la marge est forte (i.e. proche de 1) et plus le classifieur est confiant dans sa prédiction. A l'inverse, plus elle est proche de 0 et moins le classifieur est confiant.

## Utilisations des échantillons *Out-Of-Bag*

Chaque arbre  $T$  de la forêt n'a été construit qu'à partir d'une partie  $A_T$  de l'ensemble d'apprentissage  $A$ . Les échantillons d'apprentissage *Out-Of-Bag* d'un arbre  $T$  sont donc l'ensemble  $OOB_T$  des échantillons de  $A$  qui n'ont pas été utilisés pour la construction de  $T$ . Autrement dit :  $OOB_T = A \setminus A_T$ .

Ces données *Out-Of-Bag* permettent donc d'avoir une estimation non biaisée du taux d'erreur en généralisation. On définit ainsi l'erreur de classification sur les échantillons OOB, comme suit :

$$Erreur_{OOB} = 1 - \frac{1}{n_T} \sum_{t=1}^{n_T} \frac{1}{Card(OOB_T)} \sum_{(\mathbf{x}, y) \in OOB_T} \delta(T(\mathbf{x}), y)$$

avec  $\delta(i, j) = 1$  si  $i = j$  et 0 sinon, et  $T(\mathbf{x})$  désignant la classe attribuée à l'observation  $\mathbf{x}$  par l'arbre de décision  $T$ .

Par ailleurs, [Breiman 2001] a également proposé de dériver une mesure d'importance de variable à partir de ces échantillons *Out-Of-Bag*. Une telle mesure permet de quantifier l'importance des différents attributs en mesurant leur influence au sein du modèle, et donc leur impact sur la classification. L'importance d'un attribut  $f$  se calcule en permutant aléatoirement les valeurs de cet attribut : on mesure alors sur les données OOB la différence de précision de la classification avant et après cette permutation. Plus cette précision se dégrade après la permutation, plus l'attribut  $f$  est important.

## Utilisation pratique

Dans les expériences qui suivent, l'implémentation des RF de la librairie *OpenCV* a été utilisée [Bradski 2000].

### 3.1.7 Illustration du comportement de ces classifieurs

Les figures 3.3 et 3.4 illustrent le comportement des différents classifieurs sur deux problèmes de classification artificiels. Tous deux sont des problèmes binaires pour lesquels les échantillons sont décrits par 2 attributs. Le premier problème (figure 3.3) implique deux classes linéairement séparables, tandis que dans le cas du second (3.4), la frontière entre les nuages de points est plus complexe. Pour le problème linéaire, les classifieurs ML (avec modèle de distribution gaussienne), SVM linéaire et SVM avec noyau gaussien parviennent à retrouver une frontière linéaire entre les deux classes. Le classifieur RF parvient également à trouver une frontière entre les deux classes approximant à peu près une droite, avec des mesures d'appartenance aux classes présentant un dégradé perpendiculairement à cette frontière. En revanche, la frontière théorique entre les deux classes est moins bien modélisée par les arbres de décision.

Dans le cas du second problème, les classifieurs ML (avec modèle de distribution gaussienne) et SVM linéaire échouent à bien traiter le problème. En revanche, les classifieurs SVM avec noyau gaussien, RF et (de manière plus grossière) les arbres de décision parviennent à assez bien restituer les frontières entre classes. On peut aussi constater ici tout l'intérêt des mesures d'appartenance aux classes pour transcrire l'incertitude quant aux labellisations obtenues.



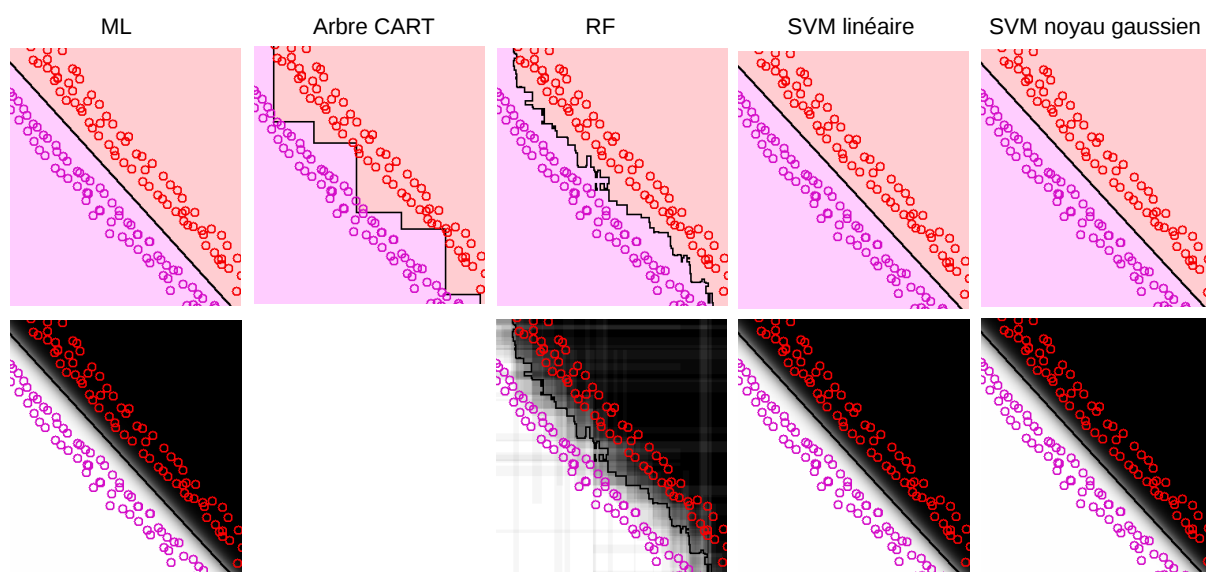


FIGURE 3.3 – Application de différents classifieurs pour un problème de classification binaire linéairement séparable. Chaque cercle représente un échantillon d'apprentissage. La frontière entre les classes calculée d'après les classifieurs est représentée par une ligne noire. En haut, labellisation des échantillons ; en bas, mesure d'appartenance aux classes.

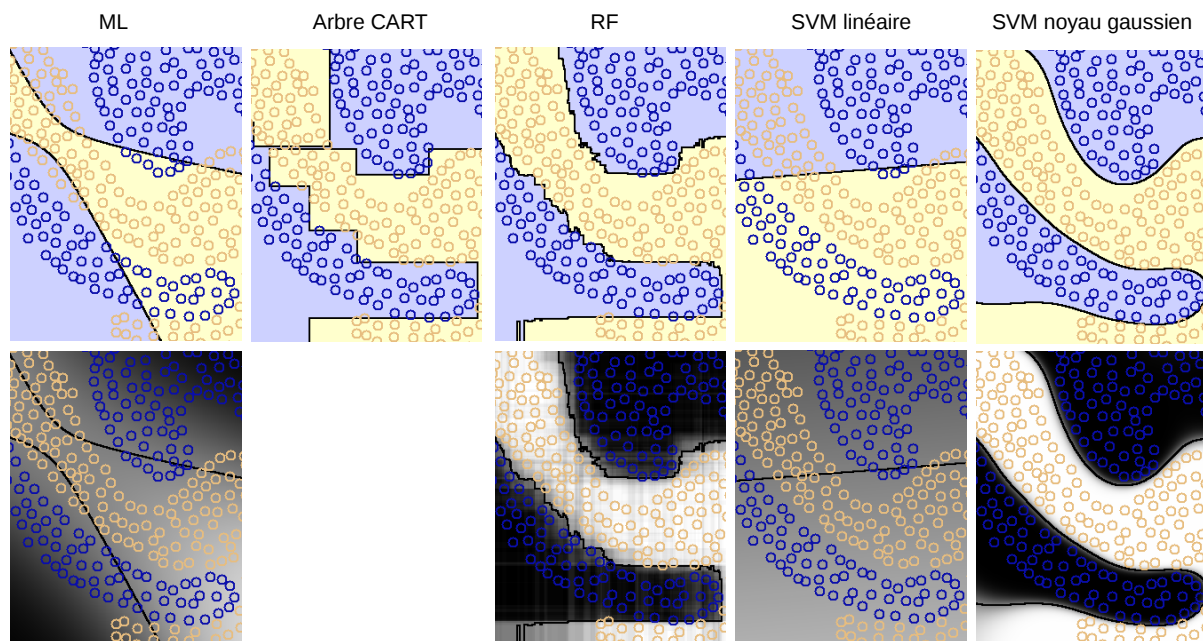


FIGURE 3.4 – Application de différents classifieurs pour un problème de classification binaire où les frontières entre classes sont plus complexes. Chaque cercle représente un échantillon d'apprentissage. La frontière entre les classes calculée d'après les classifieurs est représentée par une ligne noire. En haut, labellisation des échantillons ; en bas, mesure d'appartenance aux classes.

### 3.2 Evaluation d'une classification

On s'intéresse ici à la mesure quantitative de la qualité d'une classification par rapport à un jeu de données de vérité terrain. Les indicateurs mis en jeu ne sont donc pas spécifiques à une méthode de classification donnée, mais communs à toutes.

Pour évaluer la qualité de la classification, on établit une matrice de confusion. Pour  $n$  classes, la matrice de confusion est un tableau  $n \times n$  où la case  $(i, j)$  représente le nombre de pixels de la classe  $i$  déclarés en tant que classe  $j$ . Une lecture en colonne permet de savoir dans quelles classes  $j$  se répartissent les pixels d'une classe  $i$  de la vérité terrain, c'est le point de vue producteur. Une lecture en ligne permet de savoir à quelles classes  $i$  appartiennent les pixels qui sont déclarés dans la classe  $j$  à l'issue de la classification, c'est le point de vue utilisateur.

A partir de cette matrice on peut calculer pour chaque classe la précision producteur, le pourcentage de pixels issus de la vérité terrain qui sont bien classés, et la précision utilisateur, le pourcentage de pixels qui appartiennent effectivement à la classe qui leur est assignée à l'issue de la classification. Cette matrice rend enfin possible le calcul de la précision globale, c'est-à-dire du nombre de pixels bien classés par rapport au nombre total de pixels. Le tableau 3.1 donne un exemple de matrice de confusion.

		Vérité terrain			Utilisateur
		Classe a	Classe b	Classe c	
Résultat	Classe a	$n_{aa}$	$n_{ab}$	$n_{ac}$	$P_u(a)$
	Classe b	$n_{ba}$	$n_{bb}$	$n_{bc}$	$P_u(b)$
	Classe c	$n_{ca}$	$n_{cb}$	$n_{cc}$	$P_u(c)$
Producteur		$P_p(a)$	$P_p(b)$	$P_p(c)$	

TABLE 3.1 – Exemple de matrice de confusion.

Si la matrice de confusions est utile pour mener une analyse détaillée des résultats afin d'examiner comment se répartissent les confusions entre les classes, il est nécessaire d'en tirer des mesures plus synthétiques pour quantifier la qualité du résultat obtenu, en particulier si l'on souhaite comparer de manière automatique plusieurs classifications.

Il est possible de dériver de la matrice de confusion les **précisions producteur et utilisateur**, ainsi que les **erreurs d'omission et de commission**, pour chacune des classes.

- La **précision producteur** ( $P_p$ ) va mesurer l'aptitude du classifieur à bien retrouver les éléments de la vérité terrain : elle va fournir la probabilité qu'un élément appartenant à une certaine classe dans la vérité terrain soit effectivement bien affecté à cette classe par le classifieur. Elle se calcule comme suit :

$$P_p(a) = \frac{n_{aa}}{\sum_i n_{ai}}$$

On en déduit l'**erreur d'omission** définie par  $Omission(a) = 1 - P_p(a)$ .

- La **précision utilisateur** ( $P_u$ ) va mesurer l'aptitude du classifieur à ne pas se tromper de classe : elle va donner la probabilité qu'un élément affecté à une certaine classe par le classifieur en fasse réellement partie dans la vérité terrain. Elle se calcule comme suit :

$$P_u(a) = \frac{n_{aa}}{\sum_i n_{ia}}$$

On en déduit l'**erreur de commission** définie par  $Commission(a) = 1 - P_u(a)$ .

Il est possible de déduire une mesure synthétique de ces deux précisions avec le **F-score**. En général, c'est le  $F_1$ -score qui est utilisé. Il s'agit en fait de la moyenne harmonique des taux de précision utilisateur et producteur. On a donc

$$Fscore(c) = 2 \cdot \frac{P_p(c) \cdot P_u(c)}{P_p(c) + P_u(c)} = \frac{2}{\frac{1}{P_p(c)} + \frac{1}{P_u(c)}}$$

On notera qu'il existe une formule générale qui permet de pondérer l'importance donnée à ces deux critères.

$$Fscore(c) = (1 + \beta^2) \cdot \frac{P_p(c) \cdot P_u(c)}{\beta^2 \cdot P_p(c) + P_u(c)}$$

Les trois mesures qui précèdent (précision producteur, précision utilisateur et F-score) sont calculées pour chacune des classes. Là encore, on a besoin d'indicateurs plus globaux pour pouvoir comparer différentes classifications. On pourra dès lors synthétiser ces différentes mesures en ne s'intéressant par exemple qu'à leur valeur moyenne ou à leur valeur minimale (en particulier si l'on s'intéresse aux classes les plus mal classées).

Les autres mesures globales de qualité d'une classification les plus souvent utilisées sont les suivantes :

- **Précision globale** ou *Overall Accuracy* (notée ensuite *OA*)

$$OA = \frac{\sum_i n_{ii}}{\sum_i \sum_j n_{ij}}$$

- **Précision moyenne** ou *Average Accuracy* (notée ensuite *AA*).

Il s'agit de la moyenne des précisions producteurs.

$$AA = \frac{1}{\text{nb\_classes}} \sum_i P_p(i)$$

- le coefficient **Kappa** ( $\kappa$ ) [Cohen 1960, Fleiss et Cohen 1973, Pontius et Millones 2011] :

Le coefficient Kappa exprime la réduction proportionnelle de l'erreur obtenue par la classification comparée à l'erreur d'une classification complètement au hasard. (Exemple : un Kappa de 0,75 signifie que 75% de la classification ne sont pas dus au hasard.)

$$\kappa = \frac{|N \cdot \sum_i n_{ii} - \sum_i (\sum_k n_{ik}) \cdot (\sum_k n_{ki})|}{N^2 - \sum_i (\sum_k n_{ik}) \cdot (\sum_k n_{ki})}$$

avec  $N = \text{nb\_classes}^2$  = nombre d'éléments de la matrice.

---

## Chapitre 4

# Réduire la dimension

Le problème d'optimisation spectrale présent rejoint les problèmes plus généraux de réduction automatique de la dimension.

### 4.1 Des données de grande dimension

Les données de télédétection de très grande dimension, comme l'imagerie hyperspectrale, génèrent des volumes de données importants. Ainsi, dans le cas de l'hyperspectral, ces données vont consister en plusieurs centaines de bandes spectrales contiguës. La corrélation entre ces bandes, et en particulier entre bandes voisines est souvent importante, d'où une information redondante. Aussi est il possible de réduire ce volume d'information sans perte excessive d'information utile.

Cette forte dimension des données a pour conséquence de générer un certain nombre de difficultés. En premier lieu, le phénomène bien connu de malédiction de la dimension ou phénomène de Hughes [Hughes 1968] risque de se produire lorsque l'on va chercher à procéder à une classification de ces données. Ceci est toutefois à nuancer car les classifieurs "modernes" plus robustes comme les Séparateurs à Vaste Marge (SVM) ou les Forêts aléatoires (ou Random Forests (RF)) sont moins sensibles à ces problèmes [Melgani et Bruzzone 2004, Camps-Valls et Bruzzone 2005] et parviennent malgré tout à produire de bons résultats, sauf dans des cas où très (trop) peu de données d'apprentissage sont disponibles [Pal et Foody 2010].

En second lieu, les temps de calcul requis pour traiter ces grands volumes de données vont également être importants. En troisième lieu, le stockage de ces données prend beaucoup de place. En dernier lieu, la question de l'affichage de l'imagerie hyperspectrale peut aussi se poser. Il s'agit alors de décider de ce que l'on va afficher quand la vision humaine est limitée à trois couleurs [Demir *et al.* 2009, Le Moan *et al.* 2011].

Il va donc souvent s'avérer intéressant de réduire la dimension de ces données. Cela va consister à réduire le volume de données (i.e. le nombre de bandes) de manière à optimiser un certain critère, comme par exemple minimiser la perte d'information utile, et en particulier dans le contexte d'une classification supervisée, de s'efforcer de conserver la meilleure séparabilité, la meilleure distinction entre les classes. Les méthodes de réduction de la dimension peuvent être distinguées en 2 catégories : les méthodes d'**extraction de caractéristiques** (*feature extraction*) et celles de **sélection d'attributs**.

Les méthodes d'extraction de caractéristiques consistent à reformuler et à résumer l'information contenue dans le jeu de données initial, par exemple en reprojétant les bandes initiales sur des axes choisis de manière optimale. Parmi les algorithmes d'extraction de caractéristiques les plus connus, on peut citer l'Analyse en Composantes Principales (ACP), le *Minimum Noise Fraction* (MNF) ou l'Analyse en Composantes Indépendantes (ACI) pour le cas non supervisé ainsi que l'Analyse Discriminante Linéaire, ou Analyse Discriminante de Fisher pour le cas supervisé.

A l'inverse, les méthodes de sélection d'attributs vont choisir un sous-ensemble d'attributs issus du jeu de données initial, c'est-à-dire ne conserver que les quelques attributs les plus utiles, les plus pertinents, au sens d'un certain critère.

Cette seconde classe de méthodes de réduction de la dimension offre certains avantages par rapport à la première. En effet, elle conserve le sens physique des bandes qui sont sélectionnées, contrairement à une extraction d'attributs où cette information est noyée lors du calcul des attributs "synthétiques". On notera d'ailleurs au passage que cela correspond à ce qui a pu être fait de manière non automatique en spectroscopie : la détermination des bandes spectrales les plus intéressantes a souvent été faite par des spécialistes qui ont identifié des bandes d'absorption ou des comportements du spectre caractéristiques d'un matériau. Ces connaissances ont ensuite pu être intégrées dans des systèmes expert (comme par exemple [Clark *et al.* 2003] pour la caractérisation de certains minéraux, [Bassani *et al.* 2007] pour celle de l'amiante, [Mohammadi 2012] pour celle des revêtements routiers asphaltés ou [Heiden *et al.* 2007] pour différents matériaux urbains). Néanmoins, ce genre d'approche peut s'avérer complexe et pas nécessairement compatible avec une situation où l'on recherche à identifier un jeu limité, voire très limité, de bandes qui soit un compromis pour la discrimination des différentes classes : la combinatoire est alors importante et l'ensemble des bandes identifiées comme discriminantes pour chaque classe indépendamment des autres peut s'avérer plus important que le nombre de bandes que l'on est autorisé à sélectionner.

Les méthodes de sélection d'attributs sont donc parfaitement adaptées à la sélection d'un jeu de bandes spectrales optimal dans le cas de la conception d'un capteur multispectral/superspectral dédié à des applications spécifiques. On parle alors de **sélection de bandes**. En revanche, si l'on souhaite également définir la largeur optimale des bandes spectrales (et pas uniquement leur position le long du spectre), on se trouve à mi-chemin entre sélection de bandes et extraction de caractéristiques, puisque l'on reformule la donnée originale. On parlera alors d'**extraction de bandes spectrales** ou de **fusion de bandes spectrales**.

## 4.2 Sélection de bandes / sélection d'attributs

La sélection d'attributs fait partie de la famille des problèmes d'optimisation. En effet, ce travail va consister à sélectionner le sous-ensemble d'attributs permettant d'optimiser un certain critère. Un algorithme de sélection d'attributs est donc l'association d'un critère de sélection que l'on va chercher à optimiser et d'une méthode d'optimisation. Ce critère de sélection d'attributs est une mesure/un score mesurant la pertinence du sous-ensemble d'attributs sélectionnés.

### 4.2.1 Différentes familles de méthodes

Les méthodes de sélection d'attributs (et en particulier le critère de sélection) sont souvent distinguées en 3 catégories : "filtres", "*wrapper*" and "imbriquées (*embedded*)" : un récapitulatif d'un certain nombre d'approches de la littérature triées selon cette grille est présenté dans le tableau 4.1. Dans le cas des filtres, on peut également distinguer les cas supervisés et non supervisés, selon que la notion de classes est prise en compte ou non.

#### Filtres

Les méthodes de type filtre utilisent un critère de sélection d'attribut indépendant de tout classifieur.

Ainsi, de nombreuses méthodes de sélection d'attributs vont calculer pour chaque attribut un score d'importance individuelle, classer les attributs en fonction de ce score puis n'en conserver que

les  $n$  meilleurs. De tels scores, calculés pour chaque attribut, peuvent être supervisés ou non. Par exemple, le score utilisé par l’algorithme ReliefF [Kira et Rendell 1992, Kononenko *et al.* 1997], le score de Fischer, ou encore d’autres scores mesurant la corrélation des bandes avec la vérité terrain [Hall et Holmes 2003] sont des scores supervisés. Ces mesures d’importance ne prennent toutefois pas en compte les dépendances entre attributs sélectionnés. Aussi un jeu d’attributs sélectionnés comme étant les  $n$  meilleurs attributs d’après ces mesures ne constituera pas forcément une solution optimale, ou du moins ne sera pas parcimonieuse, ainsi qu’on pourra le voir dans la section 6.6.1.

Des méthodes non supervisées vont dériver de tels scores d’importance individuelle des attributs à partir du résultat d’une décomposition en ACP comme par exemple [Chang *et al.* 1999]. Les bandes les plus corrélées à l’ensemble des autres sont alors progressivement retirées. [Du *et al.* 2003, Hasanlou et Samadzadegan 2010] emploient des approches similaires, mais en utilisant l’ACI au lieu de l’ACP. D’autres approches non supervisée exploitent également les résultats d’une ACP en sélectionnant les attributs les plus semblables aux premières composantes principales [Kandasamy *et al.* 2009b;a].

Il est aussi possible de calculer des scores de pertinence, non plus pour chaque attribut indépendamment des autres, mais directement pour des jeux composés de plusieurs attributs. Ces mesures permettent donc de comparer des jeux d’attributs sélectionnés entre eux, et pas uniquement des attributs individuels.

Ainsi, dans le cas non supervisé, [Chang et Wang 2006] propose encore une autre approche consistant à minimiser une énergie contrainte (*constrained energy minimization*) afin de sélectionner un sous-ensemble d’attributs les moins corrélés entre eux.

Dans le cas supervisé, des mesures de séparabilité comme celle de Fisher [Fisher 1936], celle de Bhattacharyya ou celle de Jeffries-Matusita (JM) permettent de mesurer la capacité d’une bande ou d’un ensemble de bandes à discriminer différentes classes [Bruzzone et Serpico 2000, Herold *et al.* 2003, De Backer *et al.* 2005, Serpico et Moser 2007]. D’autres mesures existent, comme par exemple *Minimum Estimated Abundance Covariance (MEAC)* proposée par [Yang *et al.* 2012] et liée à la capacité du jeu de bandes sélectionnées à bien démêler différentes sources.

D’autres mesures statistiques issues de la théorie de l’information, comme la divergence, l’entropie ou l’information mutuelle, sont aussi utilisées pour sélectionner les meilleurs jeux de bandes, à la fois pour des problèmes non supervisés comme dans [Martínez-Usó *et al.* 2007, Le Moan *et al.* 2011] ou dans des problèmes supervisés comme dans [Battiti 1994, Guo *et al.* 2008a, Estévez *et al.* 2009, Sotoca et Filiberto 2010, Cang et Hongnian 2012]. Dans le cas non supervisé, on va ainsi s’efforcer de sélectionner un jeu d’attributs les plus représentatifs possible du jeu de donnée initial, tout en étant les moins redondants entre eux. Ainsi, [Martínez-Usó *et al.* 2007] commence par regrouper les bandes les plus “corrélées” puis sélectionne la bande la plus représentative de chaque groupe. Pour répondre à un problème de visualisation de la donnée hyperspectrale, [Le Moan *et al.* 2011] souhaite sélectionner 3 bandes appartenant aux domaines rouge, vert et bleu du spectre, sous la contrainte que les 3 bandes sélectionnées soient les moins “corrélées” possible entre elles. Dans des cas supervisés, [Battiti 1994, Guo *et al.* 2008a, Estévez *et al.* 2009, Sotoca et Filiberto 2010, Cang et Hongnian 2012] sélectionnent des attributs les plus corrélés à la vérité terrain (i.e. aux différentes classes) et les moins redondants entre eux. La difficulté est alors de réussir à pondérer ces deux critères.

Une autre manière de mesurer la similarité entre bandes spectrales est l’OPD (*Orthogonal Projection Divergence*) utilisée par [Du et Yang 2008] : la similarité entre bandes est mesurée par l’erreur entre une bande et sa modélisation par combinaison linéaire des bandes déjà sélectionnées. Une méthode de sélection non supervisée peut donc consister à sélectionner les bandes de manière incrémentale, de façon à ne conserver que les bandes les plus différentes au sens de l’OPD.

Enfin, une dernière méthode proposée dans [Campedel *et al.* 2004] utilise l’algorithme de *Support Vector Clustering* (un algorithme de classification non supervisée) en l’appliquant aux attributs afin

d'identifier ceux qui sont les plus caractéristiques.

En résumé, les critères de sélection d'attributs de type filtre sont nombreux et recouvrent des approches très différentes. Les approches, en particulier supervisées, qui trient les attributs selon un score d'importance individuelle, et n'en conservent que les  $n$  meilleurs restent limitées, car elles ne prennent pas en compte les dépendances entre les attributs sélectionnés. Les approches associant directement des scores de pertinence à des jeux d'attributs sont dans ce sens plus intéressantes. On y distingue approches supervisées et non supervisées. Notre problématique concernant la classification supervisée, nous nous intéresserons principalement aux critères supervisés dans les expériences qui suivront. Les critères non supervisés sont également intéressants, mais présentent un risque de sélectionner des attributs qui ne seraient pas tous également utiles à la classification.

### ***Wrappers***

Dans le cas des méthodes de sélection d'attributs de type *wrapper*, le score mesurant la pertinence du jeu de bandes sélectionnées correspond à la mesure de qualité d'une classification effectuée en utilisant ce jeu de bandes. Une méthode *wrapper* sera donc associée à un classifieur. Quelques exemples de ce type d'approches peuvent être trouvés dans [Estévez *et al.* 2009, Li *et al.* 2011, Yang *et al.* 2007, Zhuo *et al.* 2008] en utilisant un classifieur de type SVM, dans [Zhang *et al.* 2007, Fauvel *et al.* 2014] avec un classifieur par maximum de vraisemblance, dans [Díaz-Uriarte et De Andres 2006] avec un classifieur Forêts Aléatoires, dans [Kandasamy *et al.* 2009b, Minghelli-Roman 2010] avec une mesure de SAM ou même un détecteur de cibles dans [Minet *et al.* 2010, Minet 2011].

Les score de type *wrapper* peuvent être utilisés pour la sélection d'attributs en association avec différentes méthodes d'optimisation. Ils conduisent généralement à sélectionner des jeux d'attributs réduits mais permettant d'atteindre de très bonnes performances de classification. Néanmoins, ces solutions peuvent aussi parfois manquer de généralité et être trop dépendantes du classifieur à partir duquel est calculé le score *wrapper* utilisé pour la sélection d'attributs. On pourra alors risquer d'obtenir de moins bons résultats si l'on utilise ensuite ce jeu d'attributs avec un autre classifieur.

Les temps de calcul sont généralement plus importants lorsque l'on utilise des scores de type *wrapper* : ceux-ci nécessitent en effet à la fois de réaliser l'apprentissage d'un classifieur, de classifier un jeu d'échantillons témoins suivant ce modèle et d'évaluer la qualité de la classification obtenue.

### ***Embedded***

Les méthodes de sélection d'attributs de type "imbriqué" ou "*embedded*" sont également liées à un classifieur, mais à la différence d'une méthode *wrapper*, le score mesurant la pertinence, la performance du jeu d'attributs sélectionnés sera différent d'une simple mesure de la qualité de la classification. En général, avec ce type d'approche, la sélection d'attributs est effectuée directement lors de la phase d'apprentissage. On peut distinguer plusieurs types de méthodes de sélection d'attributs *embedded* [Tang *et al.* 2014].

Modèles de régularisation : Certaines approches se basent sur des modèles de régularisation : un classifieur est entraîné de manière à optimiser une fonction objectif qui comprend un terme d'attache aux données (i.e. qui minimise le taux d'erreur de classification) et un terme de régularisation qui va pénaliser davantage le modèle au fur et à mesure que celui-ci utilise un nombre important d'attributs, ou qui va contraindre les coefficients attribués à certains attributs dans le modèle à rester les plus faibles. Les attributs avec les coefficients les plus proches de 0 sont alors éliminés. Des exemples de ce type d'approches sont présentés dans [Ma et Huang 2008, Tuia *et al.* 2014b;a]. Des méthodes de sélection d'attributs comme le L1-SVM [Zhu *et al.* 2004] ou le LASSO (Least Absolute Shrinkage and Selection Operator) [Tibshirani 1996, Tuia *et al.* 2014a] font partie de ce type d'approches. Ces différentes approches ont l'avantage d'être efficaces et rapides. En revanche, il est plus difficile de les

modifier par exemple pour y intégrer simplement des contraintes complémentaires. Critère de sélection d'attributs et méthode d'optimisation y sont également complètement liés.

Mécanisme d'apprentissage menant spontanément une sélection d'attributs : D'autres classifieurs sélectionnent d'emblée les attributs lors de la phase d'apprentissage, de part la nature même de leur méthode d'apprentissage. Ainsi, les Random Forests (RF) [Breiman 2001] (et certains arbres de décision) peuvent être considérés comme des méthodes de sélection d'attributs. En effet, pour ces classifieurs, seuls les attributs les plus discriminants (par exemple au sens du critère d'impureté de Gini [Breiman 2001]) sont utilisés lors du découpage d'un nœud. Cette sélection d'attributs à la volée élimine les attributs les moins utiles mais n'est pas pour autant nécessairement parcimonieuse : elle ne garantit pas de ne pas conserver des attributs redondants (en particulier du fait de l'utilisation de sous-ensembles d'attributs choisis aléatoirement dans le cas des RF).

Mesures d'importances des attributs : Outre cette sélection d'attributs utiles lors de l'apprentissage, les Random Forests fournissent également une mesure d'importance des différents attributs au sein de son modèle [Breiman 2001]. Cette importance est calculée pour chaque attribut à partir des échantillons *Out-Of-Bag* ou OOB, c'est-à-dire non pris en compte pour la construction d'un arbre de la forêt. Ainsi, pour chaque arbre et pour un attribut donné, on va permuter aléatoirement ses valeurs pour tous les échantillons OOB. On calcule alors la différence entre le taux de bonne classification de ces échantillons OOB avant et après cette permutation. L'importance d'un attribut est alors estimée en moyennant ces différences sur l'ensemble des arbres de la forêt [Breiman 2001]. Les problèmes déjà rencontrés pour les mesures d'importance individuelle des attributs de type filtre sont également présents, mais dans une moindre mesure. En effet, l'importance individuelle RF d'un attribut prend en compte les autres bandes de manière sous-jacente. Toutefois, l'importance d'une bande aura tendance à diminuer si celle-ci est très corrélée avec de nombreuses autres bandes [Genuer *et al.* 2010].

Le score utilisé par les SVM-RFE peut aussi être considéré comme une mesure d'importance individuelle des attributs [Guyon *et al.* 2002]. Une autre approche *embedded* pour la sélection d'attributs associée à un classifieur SVM multi-noyau (*multiple kernel SVM*) a été proposée par [Tuia *et al.* 2010] : on associe alors un noyau différent à chaque attribut, on estime le modèle du classifieur SVM multi-noyau, puis on utilise les poids estimés associés à chacun de ces noyaux comme des mesures de l'importance des différents attributs.

Méthodes d'élagage : Les importances individuelles des attributs peuvent ensuite être utilisés pour la sélection d'attributs par des méthodes d'élagages. Ces méthodes utilisent dans un premier temps l'intégralité des attributs disponibles pour entraîner un classifieur, avant d'en éliminer progressivement tout en maintenant à peu près à l'identique la performance du modèle de classification obtenu. Par exemple, l'algorithme SVM-RFE (SVM - Recursive Feature Elimination) proposé par [Guyon *et al.* 2002] est une méthode *embedded* de sélection d'attributs bien connue qui estime l'importance des différents attributs sélectionnés au sein d'un modèle SVM, c'est-à-dire leur influence dans ce modèle. On part d'une situation où tous les attributs sont pris en compte dans le modèle, puis on élimine progressivement les attributs les moins importants au sens de ce critère. Cette approche SVM-RFE lie donc complètement le score de pertinence des attributs et le processus d'optimisation.

Mesure de la qualité du modèle, de sa performance de généralisation : Contrairement aux exemples précédents pour lesquels on calculait des importances associées aux bandes individuelles, d'autres approches *embedded* mesurent directement la pertinence d'un jeu d'attributs. Ainsi, dans [Fröhlich *et al.* 2003, Pal 2009] la marge d'un classifieur SVM est utilisée à la manière d'une mesure de séparabilité comme critère pour comparer des jeux d'attributs. Dans le même ordre d'idée, le taux de bonne classification des échantillons OOB d'un classifieur Forêt Aléatoire peut aussi être considéré comme un tel critère [Breiman 2001]. Ces scores se calculent sur des jeux de bandes et mesurent la généralisation du modèle fourni par le classifieur. Ils peuvent donc constituer une alternative intéressante aux mesures



de séparabilité de type filtre et aux scores de type *wrapper*.

Enfin, on peut citer un cas d'approche *embedded* liée à un algorithme de démixage, et non pas à un classifieur : [Zare et Gader 2007] intègre directement la sélection des bandes les plus utiles au sein d'un algorithme de démixage incluant la détection d'*endmembers* et la détermination de leur abondance. Pour ce faire, des mesures d'importance associées aux différentes bandes ainsi qu'un terme de parcimonie (*sparsity*), i.e. pénalisant la sélection d'un nombre trop important de bandes, sont introduits comme contrainte dans la fonction objectif de l'algorithme. Cette approche est très spécifique à la donnée hyperspectrale et au démixage, c'est-à-dire à des cas de figures où l'on traite des échantillons qui ne sont pas purs.

### **Des approches hybrides**

La limite entre ces trois familles de méthodes de sélection d'attributs reste parfois floue. Par ailleurs, des critères appartenant à différentes familles peuvent être utilisés conjointement. Par exemple, [Estévez *et al.* 2009] et [Li *et al.* 2011] sélectionnent des attributs à l'aide d'une approche *wrapper* (taux de bonne classification) respectivement guidée ou associée à des critères de type filtre (information mutuelle entre les bandes sélectionnées et avec les différentes classes).

TABLE 4.1 – Récapitulatif de différents critères de sélection d’attributs issus de l’état de l’art.

<b>Filtres</b>	
<b>Non supervisés :</b>	
<b>Scores d’importances individuelles :</b> ACP ou ACI ou corrélation inter-bandes	[Chang <i>et al.</i> 1999, Du <i>et al.</i> 2003], [Hasanlou et Samadzadegan 2010] [Chang et Wang 2006]
<b>Scores calculés pour un jeu d’attributs :</b> Information mutuelle	[Martínez-Usó <i>et al.</i> 2007, Le Moan <i>et al.</i> 2011]
<b>Combinaison linéaire de bandes</b>	[Du et Yang 2008]
<b>Autre :</b> SVC (Support Vector Clustering)	[Campedel <i>et al.</i> 2004]
Méthode basée sur la corrélation inter-bandes	[Chang et Wang 2006]
<b>Supervisés :</b>	
<b>Scores d’importances individuelles :</b> ReliefF	[Kira et Rendell 1992, Kononenko <i>et al.</i> 1997]
Autres mesures basées sur la corrélation ou l’information mutuelle	[Hall et Holmes 2003]
<b>Scores calculés pour un jeu d’attributs :</b> <b>Mesures de séparabilité :</b> Mesures de séparabilité : distance de Bhattacharyya ou distance de Jeffries-Matusita	[Bruzzone et Serpico 2000, Herold <i>et al.</i> 2003] [De Backer <i>et al.</i> 2005],[Serpico et Moser 2007], [Zhang <i>et al.</i> 2007] [Yang <i>et al.</i> 2012]
<i>Minimum Estimated Abundance Covariance</i>	[Yang <i>et al.</i> 2012]
<b>Corrélation à la vérité terrain :</b> Information mutuelle	[Battiti 1994, Guo <i>et al.</i> 2008a] [Estévez <i>et al.</i> 2009, Sotoca et Filiberto 2010] [Cang et Hongnian 2012]
<b>Wrapper</b>	
<b>Taux de bonne classification obtenu par :</b> Classifieur SVM	[Estévez <i>et al.</i> 2009, Li <i>et al.</i> 2011] [Yang <i>et al.</i> 2007, Zhuo <i>et al.</i> 2008]
Classifieur par maximum de vraisemblance	[Zhang <i>et al.</i> 2007, Fauvel <i>et al.</i> 2014]
Classifieur Random Forests	[Díaz-Uriarte et De Andres 2006]
Détecteur de cibles	[Minet <i>et al.</i> 2010]
<b>Embedded</b>	
<b>Modèle de régularisation :</b> L1-SVM	[Zhu <i>et al.</i> 2004]
Lasso	[Tibshirani 1996, Tuia <i>et al.</i> 2014a]
Autres modèles de régularisation	[Ma et Huang 2008, Tuia <i>et al.</i> 2014b]
<b>Sélection directe lors de l’apprentissage :</b> Classifieur Random Forests	[Breiman 2001]
Classifieur Arbre de décision	[Breiman <i>et al.</i> 1984]
<b>Mesure d’importance individuelle des attributs :</b> Importances d’attributs fournies par Random Forests	[Breiman 2001]
SVM multi-noyaux	[Tuia <i>et al.</i> 2010]
<b>Méthodes d’élagage :</b> SVM-RFE	[Guyon <i>et al.</i> 2002]
<b>Performance de généralisation :</b> Marge d’un SVM	[Fröhlich <i>et al.</i> 2003, Pal 2009]
Erreur OOB d’un classifieur Random Forests	[Fröhlich <i>et al.</i> 2003, Pal 2009]
Basée sur SAM	[Keshava 2002]
<b>Autre :</b> Processus de démélange	[Zare et Gader 2007]

TABLE 4.2 – Récapitulatif avec avantages et inconvénients des différentes familles de critères de sélection d’attributs issus de l’état de l’art.

<p><b>Filtres</b></p> <p><b>Non supervisés :</b></p> <p><b>Scores d’importances individuelles :</b>  <u>Avantage</u> : Rapide.  <u>Inconvénient</u> : Sélection par tri, mais sans prise en compte des redondances entre attributs sélectionnés, avec pour conséquence des solutions non parcimonieuses. Donc plutôt pour guider la recherche.</p> <p><b>Scores calculés pour un jeu d’attributs et combinaison linéaire de bandes :</b>  <u>Avantage</u> : Sélection des attributs à la fois les plus représentatifs et les moins redondants entre eux.  <u>Inconvénient</u> : Comment pondérer ces deux termes ?  <u>Inconvénient</u> : Pas nécessairement la meilleure solution (parcimonie/performance) pour un problème de classification précis.</p>
<p><b>Supervisés :</b></p> <p><b>Scores d’importances individuelles :</b>  <u>Avantage</u> : Rapide.  <u>Inconvénient</u> : Sélection par tri, mais sans prise en compte des redondances entre attributs sélectionnés, avec pour conséquence des solutions non parcimonieuses.</p> <p><b>Scores calculés pour un jeu d’attributs :</b></p> <p><b>Mesures de séparabilité :</b>  <u>Avantage</u> : Rapide.  <u>Avantage</u> : Donne de généralement de bons résultats.  <u>Avantage</u> : Prise en compte des redondances entre attributs sélectionnés.  <u>Inconvénient</u> : Modélisation des classes par une loi statistique paramétrique sous-jacente (ex : gaussienne).</p> <p><b>Corrélation à la vérité terrain :</b>  <u>Avantage</u> : Plutôt rapide.  <u>Avantage</u> : Sélection des attributs à la fois les plus corrélés à la vérité terrain et les moins redondants entre eux.  <u>Inconvénient</u> : Comment pondérer ces deux termes ?</p>
<p><b>Wrapper</b></p> <p><u>Avantage</u> : Donne de bons résultats, en particulier pour le classifieur utilisé pour le score.  <u>Avantage</u> : Prise en compte à la fois des redondances entre attributs sélectionnés et de leur performance.  <u>Inconvénient</u> : Temps de calcul plus ou moins long selon le classifieur utilisé  <u>Inconvénient</u> : Risque d’être plus dépendant du classifieur utilisé</p>
<p><b>Embedded</b></p> <p><b>Modèle de régularisation :</b>  <u>Avantage</u> : Bons résultats.  <u>Avantage</u> : Rapide.  <u>Avantage</u> : Prise en compte des redondances entre attributs sélectionnés.  <u>Inconvénient</u> : Formulation plus verrouillée (plus difficile d’y introduire d’autres contraintes)  <u>Inconvénient</u> : Méthode d’optimisation spécifique, pas générique</p> <p><b>Sélection directe lors de l’apprentissage :</b>  <u>Avantage</u> : Rapide.  <u>Inconvénient</u> : Pas parcimonieux.</p> <p><b>Mesure d’importance individuelle des attributs / méthode d’élagage :</b>  <u>Avantage</u> : Rapide.  <u>Inconvénient</u> : Solution pas nécessairement parcimonieuse (surtout si simple tri).  <u>Inconvénient</u> : Méthode d’optimisation spécifique, pas générique dans le cas d’une méthode d’élagage.</p> <p><b>Performance de généralisation :</b>  <u>Avantage</u> : Utilisable comme un <i>wrapper</i>, mais plus rapide.  <u>Avantage</u> : Prise en compte des redondances entre attributs sélectionnés.  <u>Inconvénient</u> : Différence possible entre généralisation du modèle et performance de classification.</p>

## 4.2.2 Différentes méthodes d'optimisation

Une fois le critère à optimiser choisi, le problème de sélection d'attributs consiste à identifier le meilleur jeu d'attributs au sens de ce critère.

Une recherche exhaustive est bien souvent impossible, en particulier dans le cas des *wrappers* où les temps de calcul liés à la classification/évaluation peuvent être importants. L'ensemble des solutions possibles est en effet généralement trop important pour pouvoir être visité dans sa totalité. Aussi, des heuristiques permettant de trouver une solution “proche” de la solution optimale tout en ne visitant qu'un nombre raisonnable de configurations vont être utilisées. On peut généralement distinguer ces méthodes d'optimisation en méthodes séquentielles ou incrémentales et méthodes stochastiques.

### Stratégies séquentielles ou incrémentales

Ces méthodes vont consister à progressivement rajouter ou retirer des attributs au jeu d'attributs sélectionnés.

Plusieurs de ces méthodes sont présentées dans [Pudil *et al.* 1994]. Par exemple, la méthode Sequential Forward Search (SFS) commence par sélectionner un attribut puis ajoute progressivement à la sélection l'attribut non encore sélectionné permettant à la nouvelle sélection d'optimiser le critère de sélection. A l'inverse, la méthode Sequential Backward Search (SBS) commence par sélectionner l'ensemble des attributs puis supprime progressivement de la sélection le plus mauvais attribut au sens du critère de sélection. Les algorithmes d'optimisation  $(l, p)$  sont un compromis entre ces méthodes, ajoutant alternativement  $l$  nouveaux attributs et en retirant  $p$  de la sélection. Des variantes de ces stratégies comme les algorithmes Sequential Forward Floating Search (SFFS) ou Sequential Backward Floating Search (SBFS) ont été proposées [Pudil *et al.* 1994] : ces approches dites “flottantes” autorise la remise en question la sélection d'attributs obtenue au niveau précédent, et donc dans une certaine mesure d'éviter de figer d'emblée les attributs sélectionnés. [Serpico et Bruzzone 2001] propose une autre variante de ces méthodes SFS et SBS avec l'algorithme Steepest Ascent (SA).

Dans le cas de notre problématique de conception d'un capteur, on souhaite finalement être parcimonieux en sélectionnant un nombre de bandes très limité par rapport à la donnée initiale. Il semble donc plus pertinent d'utiliser des approches ascendantes comme les algorithmes SFS, SA ou SFFS qui ajoutent progressivement des attributs à la sélection, plutôt que des approches descendantes (SBS ou SBFS) qui partent de l'intégralité des attributs et les éliminent progressivement.

Par ailleurs, on utilisera plus volontiers une approche “flottante” comme SFFS, qui remet en question les sélections obtenues aux étapes précédentes, et évitent donc de figer d'emblée à chaque niveau les attributs déjà sélectionnés, alors que l'ajout de nouveaux attributs peut avoir pour conséquence de trouver une configuration encore meilleure en changeant certains attributs sélectionnés précédemment.

### Algorithmes stochastiques

Les algorithmes stochastiques vont faire intervenir le hasard dans leur exploration de l'espace des solutions. Ce caractère en partie aléatoire d'initialisation et de recherche d'une solution peut donc permettre de proposer différentes solutions de qualité équivalente à partir d'un même jeu de données. Plusieurs algorithmes d'optimisation stochastiques ont été mis en œuvre pour la sélection d'attributs. On peut notamment citer :

- les algorithmes génétiques (AG) [Li *et al.* 2011, Estévez *et al.* 2009, Fröhlich *et al.* 2003, Zhuo *et al.* 2008, Minet *et al.* 2010],
- l'algorithme Particle Swarm Optimization (PSO) [Yang *et al.* 2007; 2012],
- l'algorithme clonal selection [Zhang *et al.* 2007],
- l'algorithme des colonies de fourmis [Zhou *et al.* 2009]
- le recuit simulé [De Backer *et al.* 2005, Chang *et al.* 2011]

Parmi ces différentes heuristiques, les algorithmes génétiques et PSO sont parmi ceux qui sont les plus utilisés. L'algorithme PSO semble être l'un des plus rapides et être apte à fournir de bons résultats. Les algorithmes génétiques donnent généralement de bons résultats. Ils présentent aussi l'avantage de pouvoir prendre en compte facilement des contraintes complémentaires pour guider la recherche d'une solution [Estévez *et al.* 2009]. Par ailleurs, leur principe même de fonctionnement conduit à la création de populations de solutions intermédiaires mais déjà assez bonnes, et susceptibles de nous intéresser dans la suite pour caractériser la stabilité des solutions proposées (voir section 6.3.2).

### **Prise en compte de la corrélation entre bandes**

Dans le cas de la donnée hyperspectrale, les bandes voisines sont le plus souvent corrélées. Certaines approches de sélection d'attributs prennent en compte le fait que des groupes d'attributs sont fortement corrélés. Il ne s'agit alors pas pour autant de fusionner ces bandes très corrélées en bandes plus larges (comme on le fera dans le chapitre ), mais simplement d'utiliser cette information pour guider et accélérer leur processus de sélection d'attributs

Ainsi, la clusterisation ou le regroupement de bandes est donc parfois mis en œuvre conjointement avec une méthode de sélection de bandes individuelles. Par exemple, [Li *et al.* 2011] regroupent d'abord les bandes adjacentes corrélées au sens de leur information mutuelle conditionnelle. La sélection de bandes est ensuite effectuée, avec la contrainte qu'une seule bande soit sélectionnée par cluster. [Su *et al.* 2011] effectue une clusterisation des différentes bandes en appliquant l'algorithme des k-moyennes (k-means) à la matrice de corrélation des bandes. Ensuite, les clusters les moins homogènes et les bandes trop différentes de la bande représentante du cluster auxquelles elles appartiennent sont progressivement éliminées.

[Martínez-Usó *et al.* 2007, Jia *et al.* 2012] commencent par rassembler les attributs "corrélés" puis sélectionnent l'attribut le plus représentatif (au sens de l'information mutuelle pour [Martínez-Usó *et al.* 2007]) de chaque cluster.

## Chapitre 5

# Jeux de données pour l'état de l'art

Les expériences effectuées dans la partie suivante III le seront sur les trois jeux de données hyperspectrales “Pavie Centre Ville”, “Indian Pines” et “Salinas”, associant chacun une image hyperspectrale et une carte de vérité terrain. Il s’agit de jeux de données classiques de la littérature, souvent utilisés pour comparer différentes méthodes de sélection de bandes ou de classification.

### 5.1 Scène “Pavie Centre Ville”

Ce premier jeu de données (figure 5.1) est une scène hyperspectrale acquise par un capteur aéroporté ROSIS au dessus du centre ville de Pavie. La résolution spatiale des images est de 1,3 m. Il s’agit d’une image hyperspectrale en réflectance couvrant uniquement la zone de visible proche infra-rouge (VNIR) entre 430 nm et 860 nm. Les bandes bruitées ont été supprimées et seules 102 bandes spectrales ont été conservées parmi les 115 bandes originales.

Cette scène couvre une zone urbaine (un centre ville plutôt dense). Une vérité terrain lui est associée : elle est constituée de 9 classes urbaines (listées dans le tableau 5.1) qui concernent aussi bien des matériaux que de la végétation. A l’exception de la classe des ombres, ces classes ne sont pas des classes de mélange : elles ne concernent chacune qu’un seul type de matériau urbain ou de végétation.

Ce jeu de données mis à disposition par l’Université de Pavie est disponible à l’adresse suivante : [http://www.ehu.eus/ccwintco/index.php?title=Hyperspectral\\_Remote\\_Sensing\\_Scenes](http://www.ehu.eus/ccwintco/index.php?title=Hyperspectral_Remote_Sensing_Scenes).

TABLE 5.1 – Classes et nombre de pixels associés pour le jeu de données “Pavie Centre Ville”

Classes	Nombre de pixels associés
Eau ( <i>Water</i> )	824
Arbres ( <i>Trees</i> )	820
Asphalte ( <i>Asphalt</i> )	816
Pavés auto-bloquants ( <i>Self-blocking bricks</i> )	808
Bitume ( <i>Bitumen</i> )	808
Tuiles ( <i>Tiles</i> )	1260
Ombres ( <i>Shadows</i> )	476
Pelouses ( <i>Meadows</i> )	824
Sol nu ( <i>Bare soil</i> )	820

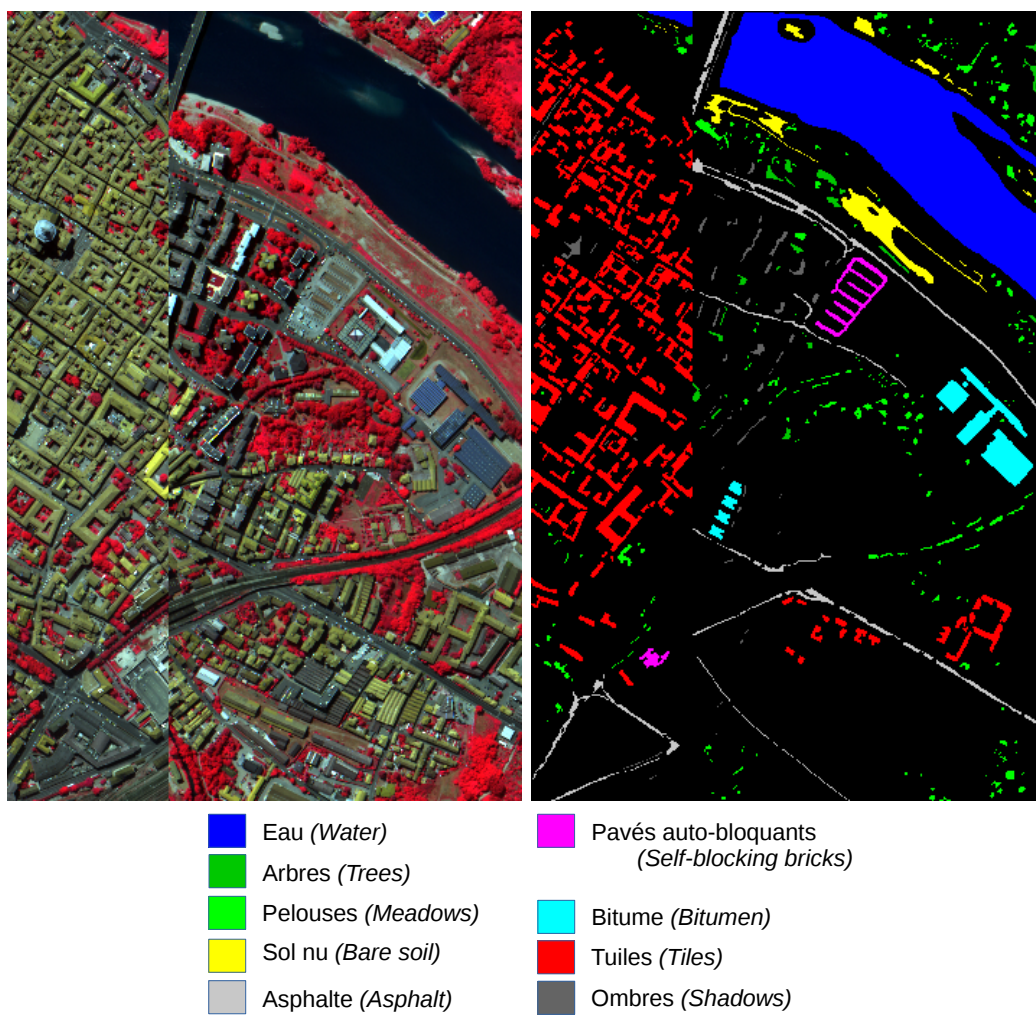


FIGURE 5.1 – Jeu de données “Pavie” : image (à gauche) et carte de vérité terrain (à droite)

## 5.2 Scène “Indian Pines”

Cette scène aérienne (fig. 5.2) a été acquise à une résolution spatiale de 20m par le capteur AVIRIS au dessus de la zone d’Indian Pines dans le Nord-Ouest de l’Indiana (USA).

Il s’agit d’une image hyperspectrale en luminance qui couvre à la fois les domaines du VNIR et du SWIR : elle est constituée de 220 bandes spectrales allant de 400 à 2500 nm.

La vérité terrain qui lui est associée est composée de classes agricoles (différents types de culture à différents niveaux de développement) et de quelques autres classes concernant la végétation plus pérenne (forêt, herbe). Ce jeu de données est considéré comme un cas de figure de classification difficile. Certaines des classes concernent en effet des cultures (en particulier pour le maïs et soja) encore dans leur premiers stades de développement, et ne couvrent qu’environ 5% du sol [Camps-Valls *et al.* 2007], avec pour conséquence des classes de mélange sol/végétation. Dans de telles conditions auxquelles s’ajoute la faible résolution spatiale des images, la discrimination entre ces différents types de culture s’avère difficile.

Au cours de nos expériences, seules 9 classes (listées dans le tableau 5.2) ont été conservées. Les classes auxquelles étaient associés moins de 400 pixels ont été rejetées, considérant que cela représentait un nombre insuffisant d’échantillons pour nos tests.

Ce jeu de données est mis à disposition par l’Université de Purdue à l’adresse suivante <https://engineering.purdue.edu/~biehl/MultiSpec/hyperspectral.html>.

TABLE 5.2 – Classes et nombres de pixels associés pour le jeu de données “Indian Pines”

Classes	Nombre de pixels associés
<i>Corn-notill</i>	1428
<i>Corn-mintill</i>	830
<i>Grass-pasture</i>	483
<i>Grass-trees</i>	730
<i>Hay-windrowed</i>	478
<i>Soybean-notill</i>	972
<i>Soybean-mintill</i>	2455
<i>Soybean-clean</i>	593
<i>Woods</i>	1265

## 5.3 Scène “Salinas”

Cette scène aérienne (fig. ??) a été acquise par le capteur AVIRIS au dessus de la Vallée de Salinas en Californie (USA). Sa résolution spatiale est de 3,7 m.

Il s’agit d’une image hyperspectrale en luminance qui couvre à la fois les domaines du VNIR et du SWIR : elle est constituée de 224 bandes spectrales allant d’environ 400 à 2500 nm.

Il s’agit d’une scène rurale et la vérité terrain qui lui est associée (voir tableau 5.3) comporte exclusivement des classes de cultures, et précisément différents types de cultures à différents stades de développement.

Ce jeu de donnée est disponible à l’adresse suivante [http://www.ehu.eus/ccwintco/index.php?title=Hyperspectral\\_Remote\\_Sensing\\_Scenes](http://www.ehu.eus/ccwintco/index.php?title=Hyperspectral_Remote_Sensing_Scenes).



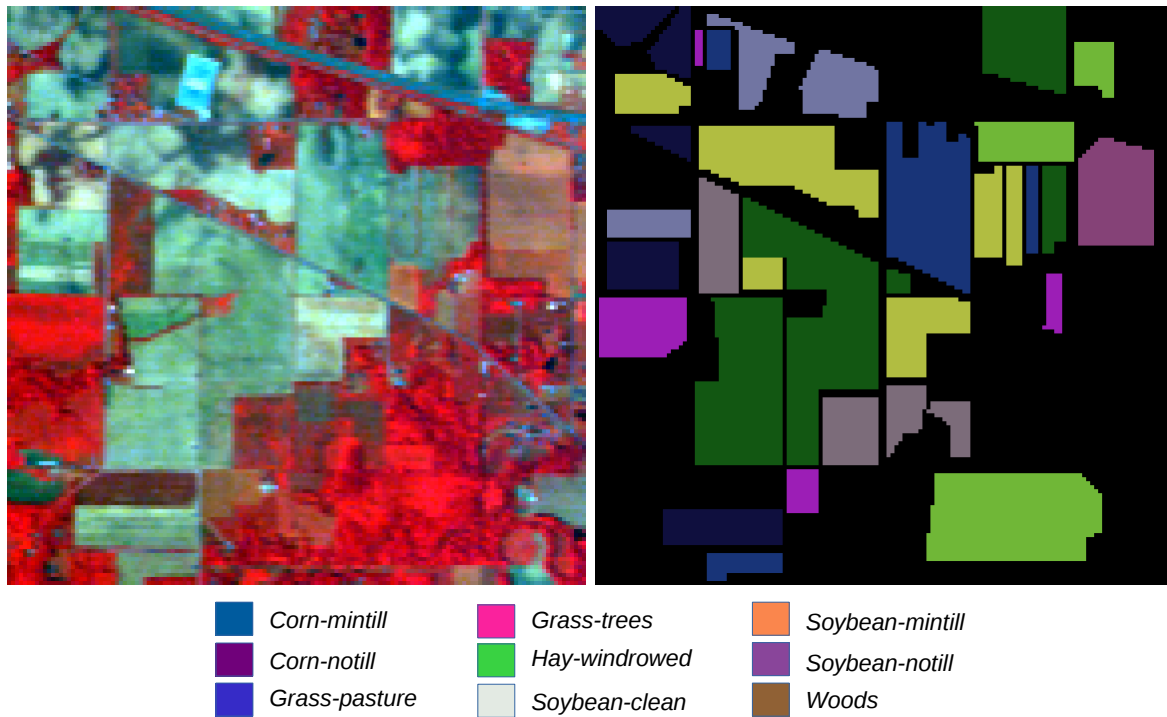


FIGURE 5.2 – Jeu de données “Indian Pines” : image (à gauche) et carte de vérité terrain (à droite)

TABLE 5.3 – Classes et nombres de pixels associés pour le jeu de données “Salinas”

Classes	Nombre de pixels associés
<i>Broccoli_green_weeds_1</i>	2009
<i>Broccoli_green_weeds_2</i>	3726
<i>Fallow</i>	1976
<i>Fallow_rough_plow</i>	1394
<i>Fallow_smooth</i>	2678
<i>Stubble</i>	3959
<i>Celery</i>	3579
<i>Grapes_untrained</i>	11271
<i>Soil_vineyard_developed</i>	6203
<i>Corn_senesced_green_weeds</i>	3278
<i>Lettuce_romaine_4_weeks</i>	1068
<i>Lettuce_romaine_5_weeks</i>	1927
<i>Lettuce_romaine_6_weeks</i>	916
<i>Lettuce_romaine_7_weeks</i>	1070
<i>Vineyard_untrained</i>	7268
<i>Vineyard_vertical_trellis</i>	1807




FIGURE 5.3 – Jeu de données “Salinas” : image (à gauche) et carte de vérité terrain (à droite)



## Troisième partie

# Optimisation de bandes spectrales : mise en place d'une méthode



## Chapitre 6

# Mise en place d'une stratégie de sélection de bandes

### 6.1 Introduction : approche proposée

Comme cela a été expliqué au chapitre 4, les méthodes de sélection automatique d'attributs sont parfaitement adaptées à la définition d'un jeu de bandes optimal pour un problème de classification donné. Ce chapitre présente la mise en place de notre stratégie de sélection de bandes, et explique les choix qui ont été faits. Ainsi qu'il a été précisé, la sélection d'attributs peut être formulée comme un problème d'optimisation. Une méthode de sélection d'attributs est donc composée d'un critère que l'on cherche à optimiser et d'une méthode d'optimisation, qu'il convient donc de définir.

Dans la littérature, les méthodes de sélection d'attributs interviennent le plus souvent comme un pré-traitement dans une chaîne de classification, en amont ou durant l'apprentissage : il s'agit alors de sélectionner rapidement les meilleurs attributs avant de passer à l'étape de classification proprement dite. Des critères importants de qualité de la méthode de sélection d'attributs utilisée sont alors sa rapidité et sa capacité à fournir de bons attributs pour le classifieur utilisé. Notre positionnement est différent. Nous cherchons à identifier le meilleur jeu de bandes spectrales dans l'optique de concevoir un capteur dédié à une problématique de classification d'occupation du sol donnée. Aussi, nous n'avons pas de contrainte concernant la rapidité de la méthode de sélection d'attributs à mettre en œuvre, du moment qu'elle demeure raisonnable. En revanche, le jeu de bandes qui sera sélectionné devra être le plus efficace possible **pour la plupart des classifieurs et non simplement au sens du critère de sélection d'attributs utilisé** (qui pourra être lié à un classifieur dans le cas d'un critère de type *wrapper*). Cette solution devra également être la plus stable possible, et comportant des bandes dont la sélection est explicable d'après la forme des spectres.

Le choix est fait d'utiliser des méthodes d'optimisation génériques. Même s'ils sont moins efficaces en terme de temps de calcul, ces algorithmes peuvent en effet être utilisés pour optimiser différents critères de sélection et aisément intégrer des contraintes complémentaires ou des informations permettant de guider la recherche de la solution [Estévez *et al.* 2009], contrairement à certaines méthodes imbriquées (*embedded*) pour lesquelles la méthode d'optimisation et le score à optimiser sont indissociables.

En pratique, on utilisera deux heuristique d'optimisation, l'une incrémentale avec l'algorithme SFFS (Sequential Forward Floating Search) décrit en 6.3.1, et l'autre stochastique avec un algorithme génétique (AG) décrit en 6.3.2.

Le choix d'une méthode incrémentale s'est porté sur SFFS, car cette méthode est à la fois "ascendante" et "flottante". Dans le cas de notre problématique de conception d'un capteur, on souhaite finalement être parcimonieux et sélectionner un nombre de bandes très limité par rapport à la donnée

initiale, et il semble donc plus pertinent d'utiliser une approche ascendante qui ajoute progressivement des attributs à la sélection, plutôt qu'une approche descendante qui part de l'intégralité des attributs et les élimine progressivement. Par ailleurs, une approche "flottante" comme SFSS rend possible la remise en question les sélections obtenues aux étapes précédentes, et évite donc de figer d'emblée à chaque niveau les attributs déjà sélectionnés, alors que l'ajout de nouveaux attributs peut parfaitement avoir pour conséquence d'obtenir une configuration encore meilleure en changeant certains attributs sélectionnés précédemment.

Pour leur part, les algorithmes génétiques sont une méthode stochastique qui donne généralement de bons résultats. Leur principe même de fonctionnement présente aussi l'avantage de conduire à la création de populations de solutions intermédiaires mais déjà assez bonnes, et susceptibles de nous intéresser dans la suite pour caractériser la stabilité des solutions proposées (voir section 6.3.2).

Il s'agit maintenant d'identifier le critère de sélection d'attributs, c'est-à-dire le score que l'on va chercher à optimiser. La suite de ce chapitre se focalise sur la sélection de ce critère. Différents scores (appartenant aux différentes familles *wrapper*, filtre et *embedded*) vont ainsi être testés et comparés. Les critères testés doivent être compatibles avec les heuristiques d'optimisation générique choisies. Ceci permet de prendre en compte des critères variés mais exclut tout de même de ce parangonnage les importances d'attributs individuels (comme ReliefF [Kira et Rendell 1992, Kononenko *et al.* 1997]) et les critères indissociables d'une méthode d'optimisation comme par exemple celui de SVM-RFE [Guyon *et al.* 2002].

Les différents critères testés vont donc être optimisés selon les mêmes heuristiques, et les résultats seront comparés pour un même nombre de bandes. Les critères qui seront considérés pour évaluer la pertinence d'un critère de sélection d'attributs seront :

- leur aptitude à fournir des jeux de bandes les plus discriminants possibles pour la plupart des classifieurs et non simplement au sens du critère de sélection d'attributs utilisé : on a donc ici un double critère : **discriminant** et **indépendant**.
- leur **parcimonie** : dans le cadre de l'optimisation spectrale pour la conception d'un capteur superspectral, on ne doit sélectionner qu'un nombre très limité de bandes (entre 15 et 20 dans notre cas)
- la **stabilité** des solutions qu'ils fournissent. L'objectif est en effet non seulement de rechercher un jeu de bandes proche de la solution optimale, mais également une solution la plus stable possible.

La suite de ce chapitre est organisée comme suit. Les différents scores testés sont présentés dans la section 6.2. La stratégie mise en œuvre pour les optimiser et les comparer est décrite dans la section 6.3. Enfin, les résultats obtenus sont présentés dans la section 6.4.

## 6.2 Scores testés

Les différents scores testés sont récapitulés dans le tableau 6.1. Notre but final étant de faire de la classification, on s'est limité à des critères de sélection d'attributs supervisés, c'est-à-dire prenant en compte des **classes prédéfinies**.

### 6.2.1 Scores de type filtre

#### Mesures de séparabilité de Bhattacharyya et de Jeffries-Matusita

En statistiques, la mesure de **Bhattacharyya** permet de quantifier la similarité de deux distributions de probabilités discrètes. Pour des distributions gaussiennes multivariées  $N(\mu_i, \Sigma_i)$  et  $N(\mu_j, \Sigma_j)$ ,

cela donne :

$$B_{i;j} = \frac{1}{8} {}^t(\mu_i - \mu_j)\Sigma^{-1}(\mu_i - \mu_j) + \frac{1}{2} \ln \left( \frac{\det \Sigma}{\sqrt{\det \Sigma_i \det \Sigma_j}} \right)$$

$\mu_k$  et  $\Sigma_k$  désignant respectivement les moyennes et les covariances de distribution, et  $\Sigma = \frac{\Sigma_i + \Sigma_j}{2}$ .

La mesure de Bhattacharrya va donc quantifier la séparabilité entre deux classes  $i$  et  $j$ . Dans un cas multi-classes, on pourra s'intéresser à la moyenne des mesures de séparabilité pour toutes les paires de classes possibles. On s'intéressera alors à :

$$Bdist_{moy} = \sum_{i=1}^{N_L-1} \sum_{j=i+1}^{N_L} B_{i;j}$$

Dans le cas multi-classes, il sera également possible de s'intéresser à la mesure de Jeffries-Matusita, définie comme suit :

$$JM = \sum_{i=1}^{N_L-1} \sum_{j=i+1}^{N_L} \sqrt{P_i \cdot P_j} \cdot (1 - e^{-B_{i;j}})$$

avec  $P_i$  la probabilité *a priori* de rencontrer la classe  $i$ . On considérera dans la suite que les classes sont équiprobables (i.e.  $P_i = cte \forall i$ ). On utilisera donc finalement la mesure suivante :

$$JM = \sum_{i=1}^{N_L-1} \sum_{j=i+1}^{N_L} (1 - e^{-B_{i;j}})$$

Par ailleurs, toujours dans un cas multi-classes, on pourra également souhaiter optimiser la séparabilité entre les classes les plus difficiles à discriminer. Une solution sera alors de s'intéresser à :

$$Bdist_{min} = \min_{1 \leq i \leq N_L-1} \min_{i+1 \leq j \leq N_L} B_{i;j}$$

## Mesure de séparabilité de Fisher

On s'intéresse ici à la mesure de séparabilité utilisée dans le cadre de l'analyse discriminante de Fisher [Fisher 1936], dans le cas de deux classes.

Soient 2 classes  $i$  et  $j$ . L'hypothèse est faite que ces classes ont une distribution normale. On modélise donc leur radiométrie par des lois gaussiennes respectivement de moyenne  $\vec{\mu}_i$ ,  $\vec{\mu}_j$  et de covariances  $\Sigma_i$  et  $\Sigma_j$ .

Fisher définit la séparation entre deux distributions comme le rapport entre la variance inter-classes et la variance intra-classes. L'analyse linéaire discriminante de Fisher consiste à reprojeter les bandes originales sur un vecteur  $\vec{w}$  optimisant ce critère. En effet, si l'on reprojette les bandes originales sur un vecteur  $w$ , la combinaison linéaire des bandes s'écrit  ${}^t w \cdot x$  et aura pour moyenne  ${}^t w \cdot \mu_i$  et pour matrice de variance-covariance  ${}^t w \Sigma_i w$  (pour  $i = 1$  ou  $2$ ).

On recherche donc le vecteur  $w$  optimisant le critère suivant  $J$  :

$$J(w) = \frac{\sigma_{\text{inter-classes}}^2}{\sigma_{\text{intra-classes}}^2} = \frac{({}^t w \cdot \mu_2 - {}^t w \cdot \mu_1)^2}{{}^t w \cdot \Sigma_2 \cdot w + {}^t w \cdot \Sigma_1 \cdot w} = \frac{({}^t w \cdot (\mu_2 - \mu_1))^2}{{}^t w \cdot (\Sigma_1 + \Sigma_2) \cdot w}$$

On montre que ce critère est optimal pour  $w \propto (\Sigma_1 + \Sigma_2)^{-1}(\mu_2 - \mu_1)$

## Critère basé sur l'information mutuelle

L'information mutuelle mesure la dépendance entre variables aléatoires discrètes. Dans le cas de 2 variables, elle se définit par :

$$I(X, Y) = \sum_{y \in Y} \sum_{x \in X} p_{XY}(x, y) \cdot \log \left( \frac{p_{XY}(x, y)}{p_X(x) \cdot p_Y(y)} \right)$$



avec  $X$  et  $Y$  désignant deux variables aléatoires discrètes,  $p_{XY}$  la fonction de distribution de probabilité conjointe de  $X$  et  $Y$ .  $p_X$  et  $p_Y$  respectivement les fonctions de distribution de probabilité de  $X$  et  $Y$ .

Il est donc possible d'utiliser l'information mutuelle pour mesurer la dépendance (la "corrélation") entre bandes spectrales. Elle peut également être appliquée à la mesure de la dépendance entre une bande  $b$  et une classification  $C$  [Battiti 1994].

Dans le cadre de la sélection d'attributs, il est intéressant de sélectionner un ensemble d'attributs les plus "corrélés" possible à la vérité terrain, tout en restant les plus différents les uns des autres. Ainsi, [Estévez *et al.* 2009] propose d'utiliser le critère suivant pour guider un processus de sélection d'attributs. Il consiste pour un attribut à calculer sa dépendance à la vérité terrain et son indépendance par rapport aux autres bandes sélectionnées. Ainsi, pour un attribut  $i$ , ce critère s'écrit

$$S(i) = I(C, i) - \frac{1}{\#\mathcal{S}} \sum_{s \in \mathcal{S}; i \neq s} \frac{I(s, i)}{H(s) \cdot H(i)}$$

$I(C, i)$  correspond à l'information mutuelle entre l'attribut  $i$  et la vérité terrain ( $C$ ).  $I(s, i)$  et  $H(i)$  désignent respectivement l'information mutuelle entre les attributs  $i$  et  $s$ , et l'entropie de l'attribut  $i$ .  $\mathcal{S}$  désigne le jeu de bandes sélectionnées et  $\#\mathcal{S}$  le nombre de bandes sélectionnées.

Dans le cas présent, ce critère a été adapté de manière à mesurer ce compromis pour un ensemble d'attributs sélectionnés.

$$S = \sum_i I(C, i) - \frac{1}{\#\mathcal{S}} \sum_{i \in \mathcal{S}} \sum_{s \in \mathcal{S}; i \neq s} \frac{I(s, i)}{H(s) \cdot H(i)}$$

### 6.2.2 Scores de type *wrapper*

Deux types de scores de la famille des *wrappers* vont être utilisés. Les premiers sont des taux classiques de bonne classification. Les seconds sont une proposition de critère d'évaluation de la qualité d'une classification tenant non seulement compte de la bonne classification des échantillons, mais prennent aussi en compte la confiance avec laquelle le classifieur les labellise.

#### Taux de bonne classification pour différents algorithmes de classification supervisée

Le premier score de type *wrapper* qui a été testé est simplement une mesure de qualité de la classification obtenue pour un classifieur donné en utilisant un jeu de bandes donné. Dans le cas présent, la mesure de qualité de la classification utilisée est le coefficient Kappa ( $\kappa$ ).

Les différents classifieurs pour lesquels ce score a été calculé sont les suivants :

- Arbres de décision
- Forêts Aléatoires
- Séparateurs à Vaste Marge ou *Support Vector Machine* (SVM) : un SVM linéaire un-contre-un a été utilisé. Cela évitait d'une part de devoir optimiser le paramétrage d'un noyau, et favorisait d'autre part les bandes permettant une séparation linéaire entre les classes.
- Classifieur par **maximum de vraisemblance** avec modélisation de distribution de la radiométrie des classes par un modèle gaussien
- Classifieur SAM
- Classifieur SID
- Classifieur SIDSAM

**Différents classifieurs** On travaillera donc avec des classifieurs dont le fonctionnement est différent.

Certains, comme le classifieur par maximum de vraisemblance, le SAM ou le SID modélisent la distribution radiométrique des classes tandis que d'autres comme les arbres de décisions, les forêts aléatoires ou les SVM modélisent les frontières entre classes.

Certains classifieurs introduisent une contrainte sur leur modèle, comme le classifieur par maximum de vraisemblance qui suppose une modélisation des classes par des gaussiennes ou le SVM linéaire qui suppose que les classes sont linéairement séparables. D'autres comme les forêts aléatoires (ou les SVM avec noyau gaussien et optimisation de paramétrage) sont capables de modéliser des frontières bien plus complexes.

### Scores prenant en compte la confiance du classifieur

La plupart des classifieurs ne se limitent pas à produire une simple labellisation, mais vont également fournir des mesures d'appartenance aux différentes classes. Ainsi, pour chaque échantillon à classer, on obtient une mesure d'appartenance à chaque classe, la classe finalement attribuée à l'échantillon étant celle pour laquelle cette mesure d'appartenance est maximale. Même si dans la suite, on se limite aux classifieurs SVM et RF, de telles mesures sont fournies par tous les classifieurs listés précédemment, à l'exception des arbres de décision.

Nous proposons donc d'intégrer cette information qui traduit la confiance avec laquelle le classifieur labellise les échantillons dans un score mesurant la qualité de la classification [Le Bris *et al.* 2015].

Pour un échantillon de descripteur  $\mathbf{x}$  donné, on obtient donc une **mesure**  $m(\mathbf{x}, c)$  **d'appartenance** à chacune des classes  $c$  du modèle.

On en déduit une **mesure de confiance** de la classification :

Soit  $y_1 = \operatorname{argmax}_{y \in C} m(\mathbf{x}, y)$  et  $y_2 = \operatorname{argmax}_{y \in C \text{ et } y \neq y_1} m(\mathbf{x}, y)$ .

On en déduit, en reprenant la formule de la "marge non supervisée" proposée par [Breiman 2001] pour les Random Forests et déjà présentée dans la section 3.1.6, la confiance de la labellisation de l'échantillon  $\mathbf{x}$  par la classe  $y_1$  par la formule suivante :

$$\operatorname{conf}(\mathbf{x}, y_1) = m(\mathbf{x}, y_1) - m(\mathbf{x}, y_2)$$

Dans une démarche de sélection d'attributs, il peut donc être intéressant de tenir également compte de ce type d'information qui traduit la notion sous-jacente de séparabilité. En effet, il va alors non seulement s'agir d'identifier les bandes qui optimisent la qualité d'une classification, mais également de s'assurer que les échantillons qui seront bien classés le seront avec une forte certitude, et que ceux qui seront mal classés le seront avec une grande incertitude.

Soit un jeu de données de validation  $\mathcal{X} = \{(\mathbf{x}_i, y_i)\}_{1 \leq i \leq n}$ . On définit les deux critères suivants de mesure de la qualité d'une classification pour la sélection d'un jeu d'attributs :

$$\mathcal{R}_{\text{appart}}(\mathcal{X}) = \sum_{i=1}^n \delta(y_i, l(\mathbf{x}_i)) \cdot m(\mathbf{x}_i, l(\mathbf{x}_i))$$

et

$$\mathcal{R}_{\text{conf}}(\mathcal{X}) = \sum_{i=1}^n \delta(y_i, l(\mathbf{x}_i)) \cdot \operatorname{conf}(\mathbf{x}_i, l(\mathbf{x}_i))$$

avec  $\delta(i, j) = \{-1 \text{ si } i \neq j \text{ et } 1 \text{ sinon}\}$ , et  $l(\mathbf{x})$  le label attribué à  $\mathbf{x}$  par le classifieur.

Plus les échantillons seront bien classés, plus ces scores augmenteront. Pour des échantillons bien classés, plus le classifieur sera confiant dans sa décision, plus ces scores augmenteront. Pour des échantillons mal classés, plus le classifieur sera confiant dans sa décision, plus ces scores diminueront.

### 6.2.3 Scores de type *embedded*

Les deux scores suivants ont également été testés. Ils sont de type *embedded*, car liés à un classifieur sans être une mesure du taux de bonne classification obtenu.

- **Marge d'un classifieur SVM** Lors de l'apprentissage d'un classifieur SVM binaire, on cherche la meilleure frontière entre les classes (c'est-à-dire le meilleur hyperplan directement dans l'espace des attributs dans le cas d'un noyau linéaire, où dans un autre espace dans lequel le problème devient linéairement séparable dans le cas d'un noyau non linéaire). On cherche la meilleure frontière entre les classes dans le sens de celles qui maximise la marge, cette dernière étant définie comme la distance entre la frontière de séparation et les échantillons les plus proches, appelés vecteurs supports.  
Dans le cas présent où l'on se trouve face à un problème multi-classes, on a utilisé un classifieur SVM linéaire 1 contre 1, et on s'est intéressé à la marge la plus faible parmi les différentes paires de classes.
- **Erreur OOB d'un classifieur RF** Dans le cas d'un classifieur RF, l'erreur sur la classification des échantillons OOB (voir section 3.1.6) donne une estimation de l'erreur de généralisation du classifieur. Le taux de bonne classification des échantillons OOB d'un classifieur RF peut donc aussi être considéré comme un critère mesurant l'aptitude du modèle calculé par le classifieur à bien discriminer les différentes classes [Breiman 2001].

## 6.3 Stratégie de comparaison de scores de sélection d'attributs

Ainsi qu'il a été dit plus haut, un bon critère de sélection d'attribut doit vérifier les conditions suivantes :

1. leur aptitude à fournir des jeux de bandes les plus **discriminants** possible et ceci le plus **indépendamment** possible des classifieurs utilisés
2. leur **parcimonie** : sélectionner le moins de bandes possibles, mais les bandes les plus efficaces
3. la **stabilité** des solutions qu'ils fournissent. L'objectif est en effet non seulement de rechercher un jeu de bandes proche de la solution optimale, mais également une solution la plus stable possible.

Ces différentes conditions vont donc être prises en compte dans notre processus de comparaison de critères de sélection d'attributs. Ce processus est décrit figure 6.1 : les différents critères de sélection d'attribut seront tous optimisés par les mêmes heuristiques, et, pour un jeu test donné, pour le même nombre de bandes.

La première étape consiste donc pour chacun des jeux de données à déterminer, à l'aide de l'heuristique d'optimisation séquentielle *Sequential Forward Floating Search* (SFFS), le nombre de bandes utiles à sélectionner.

On utilise ensuite un algorithme génétique (AG) pour optimiser les différents critères de sélection d'attributs. Cet algorithme sera ici utilisé pour optimiser des jeux de bandes de taille fixe (i.e. celle déterminée à l'étape précédente) et identique pour tous les critères, afin de garantir la condition de parcimonie.

La sélection de bandes par l'algorithme génétique sera d'ailleurs lancée à plusieurs reprises, afin de bénéficier du caractère stochastique de cet algorithme pour explorer davantage de configurations spectrales et obtenir plusieurs solutions possibles. Il faut bien garder à l'esprit qu'en matière de sélection d'attributs, il n'y a pas pour un critère donné une bonne solution unique, mais un ensemble de bonnes solutions conduisant à des résultats à peu près équivalents. Ces solutions proposées par l'algorithme génétique seront ensuite évaluées quantitativement d'après différents classifieurs. Ainsi, on mesurera

TABLE 6.1 – Liste des scores testés pour la sélection d’attributs

<b>Scores de type “wrapper”</b>	
<i>svm.lin.K</i>	Kappa d’un SVM linéaire 1-contre-1
<i>dt.K</i>	Kappa d’un arbre de décision
<i>rf.K</i>	Kappa d’un classifieur Random Forests (RF)
<i>ml.K</i>	Kappa d’un classifieur par maximum de vraisemblance avec modèle gaussien
<i>sam.K</i>	Kappa d’un classifieur Spectral Angle Mapper (SAM)
<i>sid.K</i>	Kappa d’un classifieur Spectral Information Divergence (SID)
<i>sidsam.K</i>	Kappa d’un classifieur SIDSAM
<i>svm.lin.appart</i>	score intégrant les mesures d’appartenance d’un classifieur SVM linéaire 1-contre-1
<i>svm.lin.conf</i>	score intégrant les mesures de confiance d’un classifieur SVM linéaire 1-contre-1
<i>rf.appart</i>	score intégrant les mesures d’appartenance d’un classifieur Random Forests (RF)
<i>rf.conf</i>	score intégrant les mesures de confiance d’un classifieur Random Forests (RF)
<b>Scores de type “embedded”</b>	
<i>svm.lin.marg</i>	Marge d’un SVM linéaire 1-contre-1
<i>rf.oob</i>	Erreur Out-of-Bag d’un classifieur Random Forest
<b>Scores de type “filtre”</b>	
<i>fisher.moy</i>	Séparabilité de Fisher moyenne $= \frac{1}{\text{nb paires de classes}} \sum_{i=1}^{c-1} \sum_{j=i+1}^c F_{ij}$
<i>fisher.min</i>	Séparabilité de Fisher minimale
<i>Bdist.moy</i>	Séparabilité de Bhattacharyya moyenne [Bruzzone et Serpico 2000] $= \frac{1}{\text{nb paires de classes}} \sum_{i=1}^{c-1} \sum_{j=i+1}^c B_{ij}$
<i>Bdist.min</i>	Séparabilité de Bhattacharyya minimale
<i>jm</i>	Séparabilité de Jeffries-Matusita [Bruzzone et Serpico 2000] $JM = \sum_{i=1}^{c-1} \sum_{j=i+1}^c (1 - e^{-B_{ij}})$
<i>mi</i>	Critère basé sur l’information mutuelle [Estévez <i>et al.</i> 2009]

le pouvoir discriminant des solutions proposées, tout en vérifiant leur indépendance par rapport aux classifieurs.

Par ailleurs, une analyse qualitative sera également menée à partir de ces résultats. Pour ce faire, nous proposons d'utiliser des mesures d'importance des bandes que nous dériverons à partir de résultats intermédiaires de l'algorithme génétique. Ces importances des bandes individuelles permettront de distinguer visuellement les parties du spectre considérées comme importantes par les différents critères de sélection d'attributs, et de considérer qualitativement la stabilité des jeux de bandes sélectionnés, ce qui nous est apparu être rarement fait dans la littérature.

En pratique, pour chaque critère testé, le processus de sélection de bandes par algorithme génétique sera lancé 5 fois sur 5 ensembles d'échantillons (comprenant pour chaque classe 100 échantillons d'apprentissage et 500 (300 pour Indian Pines) échantillons de test) sélectionnés aléatoirement avec remise au sein des jeux de données. Pour résumer, ce sont donc 25 solutions de jeux de bandes "optimaux" qui sont finalement obtenus pour chaque critère et évaluées quantitativement (fig .6.2).




FIGURE 6.1 – Processus d'évaluation des scores de sélections d'attribut

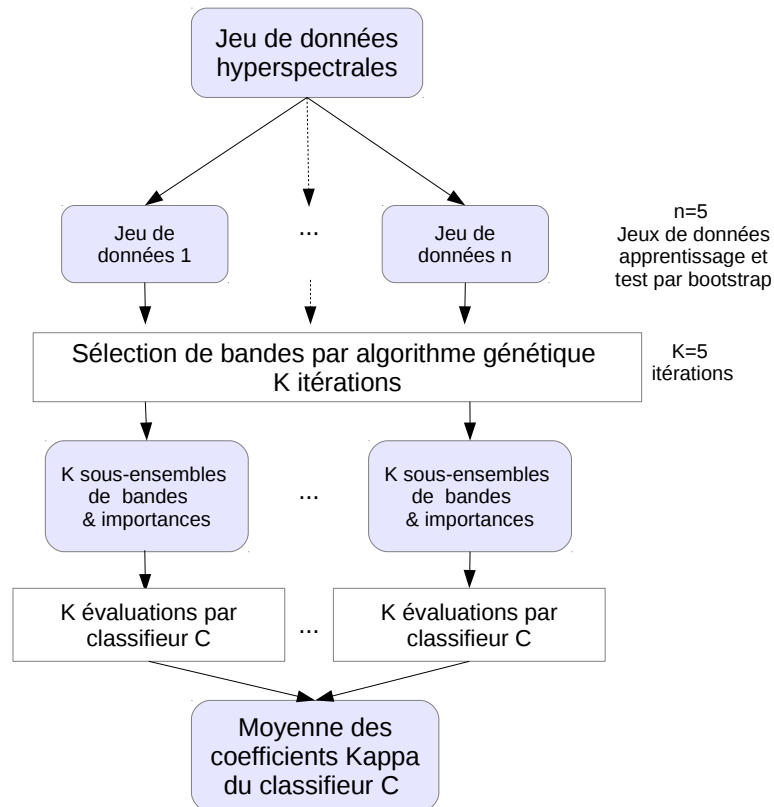


FIGURE 6.2 – Evaluation des critères de sélection utilisés à partir des différents jeux de bandes sélectionnés à l’issue d’une optimisation par algorithme génétique

### 6.3.1 Sélection du nombre optimal de bandes avec l’algorithme Sequential Forward Floating Search (SFFS)

Les résultats intermédiaires d’un algorithme de sélection d’attributs incrémental vont être utilisés pour déterminer combien de bandes sont réellement utiles et doivent être sélectionnées. Dans notre cas, on utilise l’algorithme Sequential Forward Floating Search (SFFS) [Pudil *et al.* 1994]. Son principe est décrit ci-dessous dans un cas où l’on souhaite sélectionner  $p$  canaux, en maximisant un critère  $J$ .

#### Notations

Dans la suite, on adopte les notations suivantes :

- $\mathcal{B}$  le jeu original de bandes spectrales, de cardinal  $N_B$ .
- $\mathcal{S}$  un jeu de bandes (ou d’attributs) sélectionnées.
- $J(\mathcal{S})$  le score de pertinence du jeu de bandes  $\mathcal{S}$ ;  $J(\cdot)$  est donc le score de sélection d’attributs que l’on cherche à maximiser.

---

**Initialisation :** Recherche de la bande  $b$  de  $\mathcal{B}$  maximisant le score de sélection d'attributs, i.e.

$$b = \operatorname{argmax}_{z \in \mathcal{B}} J(\{z\})$$

$$\mathcal{S} \leftarrow \{b\}$$

$$n \leftarrow 1$$

$$J_1 \leftarrow J(\mathcal{S})$$

**tantque**  $\#\mathcal{S} < p$  **faire**

Recherche de la bande  $b \in \mathcal{B} \setminus \mathcal{S}$  telle que l'association de bandes  $\mathcal{S} \cup \{b\}$  obtienne le meilleur score, i.e.  $b = \operatorname{argmax}_{z \in \mathcal{B} \setminus \mathcal{S}} J(\mathcal{S} \cup \{z\})$

$$\mathcal{S} \leftarrow \mathcal{S} \cup \{b\}$$

On va alors remettre en question le contenu de  $\mathcal{S}$  : on recherche la bande  $s$  de  $\mathcal{S}$  telle que l'association de bandes  $\mathcal{S} \setminus \{s\}$  obtienne le meilleur score, i.e.  $s = \operatorname{argmax}_{z \in \mathcal{S}} J(\mathcal{S} \setminus \{z\})$ . Cela signifie que parmi les bandes de  $\mathcal{S}$ , c'est celle-ci qui a le moins d'influence sur le score, puisque son retrait dégrade le moins le score.

**si**  $s = b$  **alors**

on peut continuer

$$J_n \leftarrow J(\mathcal{S})$$

$$n \leftarrow n + 1$$

**sinon**

$$\mathcal{S} \leftarrow \mathcal{S} \setminus \{s\}$$

**tantque**  $J(\mathcal{S}) > J_{n-1}$  **faire**

$$n \leftarrow n - 1$$

$$J_n \leftarrow J(\mathcal{S})$$

On va alors remettre en question le contenu de  $\mathcal{S}$  : on recherche la bande  $s$  de  $\mathcal{S}$  telle que l'association de bandes  $\mathcal{S} \setminus \{s\}$  obtienne le meilleur score, i.e.  $s = \operatorname{argmax}_{z \in \mathcal{S}} J(\mathcal{S} \setminus \{z\})$ .

**fin tantque**

**finsi**

**fin tantque**

---

Après quelques expériences, il est apparu que l'on ne commençait généralement à entrer dans la boucle de remise en cause de solutions déjà obtenues seulement à partir du moment où le score n'évoluait quasiment plus. Autrement dit, l'algorithme SFFS se comportait généralement comme un algorithme d'optimisation (1,1) et ne commençait à vraiment revenir en arrière qu'à partir du moment où le score à optimiser était à peu près stabilisé.

**Utilisation de résultats intermédiaires :** Ces algorithmes d'optimisation fournissent des résultats intermédiaires utiles.

- Il va estimer tous les meilleurs jeux de bandes de dimension allant de 1 à  $p$ . Cela rend possible de voir l'évolution de la position des bandes en fonction du nombre de bandes que l'on sélectionne.
- Il va également nous fournir l'évolution du score que l'on cherche à optimiser en fonction du nombre de bandes sélectionnées, ainsi que l'évolution du taux de bonne classification obtenu en utilisant les bandes sélectionnées. Cela va donc servir à déterminer le nombre de bandes utiles. (Remarque : il aurait également été possible d'accéder à ce type d'information à l'aide d'autres méthodes incrémentales comme les SVM-RFE, mais contrairement à SFFS ou (1,1), SVM-RFE ne remet jamais en cause le jeu de bandes sélectionnées, et ne permet pas de tester différents scores.)

### 6.3.2 Obtention d'une population de solutions avec un algorithme génétique

Les algorithmes génétiques sont une famille d'algorithmes d'optimisation s'inspirant des mécanismes de l'évolution d'une population d'individus. Pour chaque individu, est calculé un score reflétant son aptitude à survivre. Dans le cas présent, un individu sera un jeu de bandes sélectionnées et le score qui lui sera associé sera le score mesurant sa pertinence pour la sélection d'attributs.

---

On souhaite sélectionner  $p$  bandes.

**Initialisation :** ( $t \leftarrow 0$ ) On génère aléatoirement une population  $G(0)$  de  $N$  individus, i.e.  $N$  jeux de  $p$  bandes

**tantque**  $t < t_{max}$  **faire**

*//Boucle des générations*

$t \leftarrow t + 1$

On calcule le score de chaque individu de la population courante.

On ne conserve alors que les  $n$  ( $n < N$ ) individus présentant les meilleurs scores. Soit  $R(t)$  cette population de survivants.

On crée alors une nouvelle génération à partir de ces survivants  $R(t)$ , c'est-à-dire une nouvelle population  $G(t)$  de  $N$  individus :

**pour tout** nouvel individu **faire**

on tire au sort 2 parents parmi les survivants  $R(t)$  de la génération précédente.

Le nouvel individu est obtenu par croisement aléatoire de ses parents.

Des mutations se produisent également de manière aléatoire (selon une certaine probabilité).

Cela évite de rester bloquer au voisinage d'un minimum local.

**fin pour**

**fin tantque** *//Fin boucle des générations (La boucle cesse après un certain nombre de générations.)*

---

### Utilisation de résultats intermédiaires des algorithmes génétiques pour le calcul d'une mesure d'importance des bandes

L'algorithme génétique va nous fournir plusieurs résultats. Il va bien entendu fournir le meilleur individu parmi toutes les populations générées, c'est-à-dire la **solution finale**. Cet algorithme permet en effet d'accéder à une solution finale proche de la "vraie" solution optimale. Néanmoins, avant



d’y parvenir, il visite un certain nombre de solutions intermédiaires quasiment aussi bonnes que la solution finale, parmi lesquelles les solutions des populations intermédiaires de survivants  $R(t)$ . Il est donc intéressant d’utiliser ces solutions intermédiaires pour déterminer quelles sont les bandes les plus fréquemment sélectionnées (voir figure 6.3), et donc quelles sont les parties du spectre les plus utiles, ainsi qu’on peut le voir sur la figure 6.3.

L’objectif est en effet non seulement de rechercher un jeu de bandes proche de la solution optimale, mais également une solution la plus stable possible. On va donc associer à chaque bande  $b$  un score d’importance  $I(b)$ . Ce score est défini comme l’occurrence à laquelle cette bande figure parmi les jeux de bandes figurant parmi les bonnes solutions intermédiaires. On a donc :  $I(b) = \sum_t \sum_{S(t)} \delta(b, S)$  avec  $\delta(b, S) = 1$  si  $b \in S$ , 0 sinon.

Afin d’être plus robuste, l’algorithme génétique sera lancé plusieurs fois (i.e. pour bénéficier de différentes initialisations/mutations) et sur plusieurs “sous-”jeux de données extrait du jeu de données complet.

Le score d’importance des différentes bandes est donc finalement calculé comme la moyenne du score  $I(b)$  pour ces différents lancements de l’algorithme génétique.




FIGURE 6.3 – Utilisation de résultats intermédiaires des algorithmes génétiques pour le calcul d’une mesure d’importance des bandes. Chaque ligne représente un jeu de bandes sélectionnées faisant partie des bonnes solutions explorées par l’algorithme génétique, et chaque point noir représente une bande sélectionnée. L’histogramme bleu représente quant à lui le profil d’importance des bandes, i.e. la fréquence avec laquelle elles ont été sélectionnées.

### 6.3.3 Evaluation quantitative

Dans le cas présent où l’on se place dans l’optique d’une optimisation spectrale pour la conception d’un capteur, le but final est de sélectionner les meilleures bandes pour pouvoir réaliser des classifica-

tions de l'occupation du sol, sans savoir à ce niveau quel classifieur sera alors utilisé. Aussi la qualité du jeu de bandes sélectionnées sera évaluée en mesurant la qualité de la classification qu'il permet d'obtenir en utilisant plusieurs classifieurs :

- ML : Classifieur par maximum de vraisemblance modélisant les classes par des distributions gaussiennes
- RF : Forêt aléatoire
- SVM\_RBF : SVM 1-contre-1 avec noyau gaussien (avec optimisation du paramétrage)

Dans le cas présent, la qualité des classifications obtenues sera mesurée par le coefficient Kappa.

**Remarque :** Le classifieur SVM avec noyau gaussien sera le seul classifieur qui n'aura pas été également utilisé comme critère de sélection de bandes.

**Remarque :** Les approches de sélection d'attributs de type *wrapper* passent pour être celles qui obtiennent les meilleurs résultats pour un classifieur donné, mais aussi pour parfois être trop dépendante de ce classifieur utilisé dans le critère de sélection. Il est donc intéressant de voir quelle qualité de classification il est possible d'obtenir lorsque l'on utilise avec d'autres classifieurs un jeu de bandes sélectionnées comme étant le meilleur pour un classifieur.

On souhaite également que le critère de sélection garantisse une certaine stabilité de la performance du jeu de bandes sélectionnées. Pour cela, ainsi qu'il a été dit plus haut, on va lancer la procédure de sélection de bandes par algorithme génétique à plusieurs reprises, et sur des ensembles d'échantillons d'apprentissage/test différents. En pratique, pour chacun des 3 jeux de données initiaux, on identifiera donc 25 jeux de bandes proches de la solution optimale.

La qualité de ces différentes solutions pour la classification est alors évaluée. Pour un jeu de bandes donné, l'évaluation est effectuée de la manière suivante : l'apprentissage est effectué à partir de 50 échantillons par classe sélectionnés aléatoirement (on se place donc dans une situation relativement difficile avec un jeu de données d'apprentissage assez peu conséquent) et l'évaluation est ensuite effectuée sur le reste des échantillons du jeu de données. Ce processus est appliqué 5 fois sur chacun des 25 jeux de bandes sélectionnés.

Pour un critère de sélection de bandes donné et un indicateur de qualité de la classification, on s'intéresse donc finalement à la moyenne des différentes valeurs atteintes par celui-ci lors de ces différentes évaluations.

### 6.3.4 Analyse qualitative de la stabilité des bandes sélectionnées

Une autre condition que doit vérifier un critère de sélection d'attributs pour notre problème d'optimisation spectrale concerne la stabilité des jeux de bandes sélectionnées.

Ainsi qu'il a été décrit en 6.3.2, des profils d'importance des bandes (fig.6.3) peuvent être calculés à partir de résultats intermédiaires de l'optimisation par algorithme génétique.

En hyperspectral, comme les bandes voisines sont généralement très corrélées, ces profils d'importance des bandes doivent être plutôt réguliers (ou du moins pas trop bruités). La régularité de ces profils est donc liée à la stabilité des solutions fournies d'après un critère de sélection d'attributs. Cette analyse de régularité des profils d'importance est restée qualitative.

Par ailleurs, l'étude de ces profils d'importance permet aussi de distinguer visuellement les parties du spectre considérées comme importantes par les différents critères de sélection d'attributs.

## 6.4 Résultats

### 6.4.1 Détermination du nombre optimal de bandes avec SFFS

Comme on l'a expliqué dans la section 6.3.1, l'algorithme incrémental SFFS a été utilisé pour déterminer un nombre optimal de bandes à sélectionner. Cet algorithme optimise en effet des jeux de bandes "optimaux" de taille croissante, en partant d'une seule bande et en ajoutant progressivement d'autres jusqu'à un nombre maximal de bandes. Dans les expériences qui suivent, ce nombre de bandes maximal a été limité à 20, afin de rester cohérent avec l'application visée d'identification d'un nombre restreint de bandes dans l'objectif de la conception d'un capteur superspectral.

En pratique, on a déterminé le nombre de bandes à sélectionner en considérant à la fois l'influence du nombre de bandes sélectionnées sur :

- le score utilisé pour la sélection,
- la qualité de la classification obtenue par un classifieur SVM avec noyau gaussien en utilisant le jeu de bandes sélectionnées (la qualité de la classification est alors quantifiée en considérant le coefficient Kappa ainsi que le F-score de la classe la plus mal classée).

Le nombre optimal de bandes a été déterminé comme celui à partir duquel ces deux scores n'augmentent pratiquement plus. Ce choix a été fait en considérant l'évolution de ces indicateurs pour différents critères de sélection d'attributs. (Rappelons en effet que dans la suite, ces scores seront tous optimisés pour le même nombre de bandes.) Au final, le nombre de bandes à sélectionner est donc choisi comme un compromis entre les différents scores de sélection d'attributs.

Pour le jeu de données Pavie, la figure 6.4 montre l'influence du nombre de bandes sélectionnées sur le score de sélection d'attributs et sur la qualité (mesurée par le coefficient Kappa et le F-score le plus faible) de classification obtenue par un classifieur SVM avec noyau gaussien en utilisant les jeux de bandes sélectionnées. Ces différents indicateurs n'évoluent plus guère à partir de 5 bandes, excepté le F-score minimal qui augmente faiblement jusqu'à 7 bandes. Des résultats analogues ont été obtenus pour différents critères de sélection d'attributs, même si quelques différences existent. Ainsi, on peut constater sur la figure 6.4 que les indicateurs de qualité augmentent plus lentement pour le critère *jm* que pour le *rf.appart*. Pour cette raison, dans les expériences qui suivent, on sélectionnera 7 bandes pour le jeu de données Pavie.

Des résultats assez semblables ont été obtenus pour le jeu de données Salinas, aussi on sélectionnera également 7 bandes pour ce jeu de données.

Pour le jeu de données Indian Pines, les résultats sont quelque peu différents. Le score utilisé pour la sélection d'attributs augmente rapidement jusqu'à 7 bandes. Il reste ensuite presque constant dans le cas de *rf.appart*, mais continue à croître très faiblement pour *jm*. Le même phénomène est observé lorsque l'on considère les indicateurs de bonne classification atteints en utilisant les jeux de bandes sélectionnés pour un classifieur SVM à noyau gaussien.

Dans le cas du critère de sélection *rf.appart*, un maximum est atteint autour de 10-11 bandes, tandis que pour *jm*, on reste à peu près constant avant de connaître une nouvelle augmentation assez faible. Il convient toutefois de conserver à l'esprit que ce jeu de données est plus difficile que les deux précédents. Il présente en effet d'une part moins d'échantillons d'apprentissage et de test (et donc un risque accru de surapprentissage). D'autre part, les classes  $y$  sont plus difficiles à distinguer et les résultats bruts de classification (c'est-à-dire sans aucun post-traitement de régularisation) restent bruités. En effet, des expériences complémentaires ont été menées dans ce sens, et ont permis d'observer que le fait d'appliquer à la classification une régularisation de type vote majoritaire réduisait cette augmentation résiduelle et ont confirmé que 10 bandes étaient un bon compromis.

Aussi, dans les expériences qui suivent, seules 10 bandes seront sélectionnées pour le jeu de don-

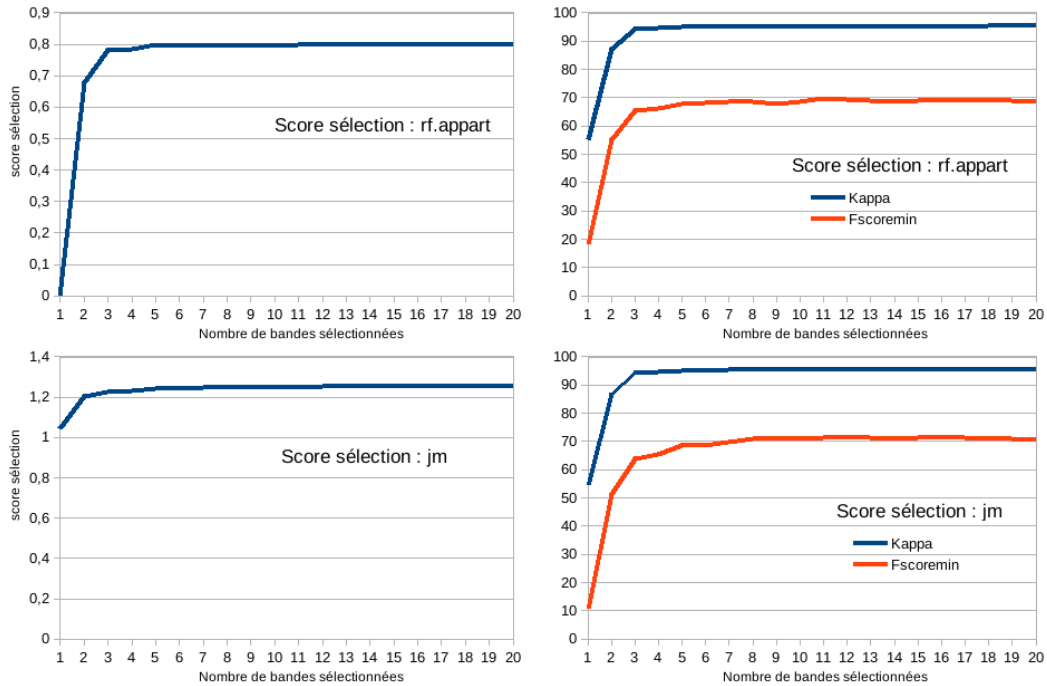


FIGURE 6.4 – Jeu de données Pavia : influence du nombre de bandes sélectionnées sur le score utilisé pour la sélection d’attributs (à gauche) et sur la qualité de la classification par un classifieur SVM gaussien en utilisant les jeux de bandes sélectionnés (à droite, avec en bleu le coefficient Kappa (en %) et en rouge le F-score (en %) le plus faible). Les 2 scores de sélection d’attributs considérés sont *rf.appart* (ligne du haut) et *jm* (ligne du bas)

nées Indian Pines. Ces bandes seront sélectionnées parmi toutes les bandes disponibles, et donc dans l’intégralité du domaine spectral VNIR + SWIR, sans restriction à un seul de ces domaines.

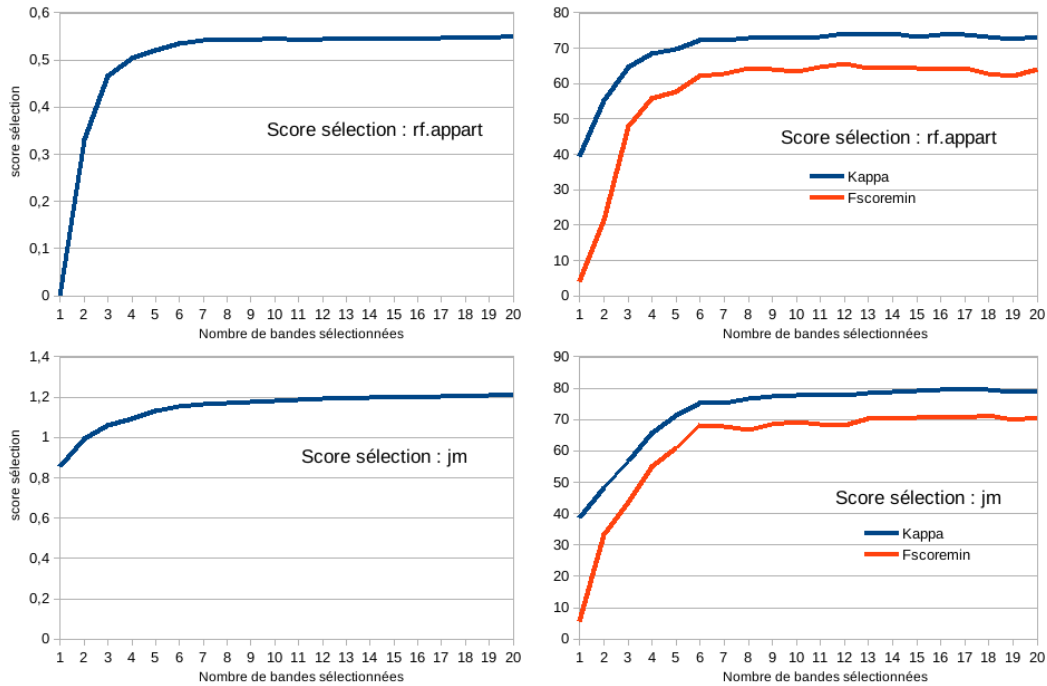


FIGURE 6.5 – Jeu de données Indian Pines : influence du nombre de bandes sélectionnées sur le score utilisé pour la sélection d’attributs (à gauche) et sur la qualité de la classification par un classifieur SVM gaussien en utilisant les jeux de bandes sélectionnées (à droite, avec en bleu le coefficient Kappa (en %) et en rouge le F-score (en %) le plus faible). Les 2 scores de sélection d’attributs considérés sont *rf.appart* (ligne du haut) et *jm* (ligne du bas)

#### 6.4.2 Comparaison des différents critères de sélection

L’optimisation de bandes à l’aide des algorithmes génétiques a donc été lancée pour sélectionner 7 bandes pour Pavie, 10 pour Indian Pines et 7 pour Salinas. Pour chacun des scores de sélection d’attributs testés, plusieurs solutions ont été proposées par les algorithmes génétiques. La qualité (mesurée par le coefficient Kappa) des classifications qu’elles permettent d’obtenir a été mesurée pour différents classifieurs. A un score de sélection d’attribut donné, on associe donc les Kappa obtenus moyennés sur l’ensemble des solutions. Ces Kappa moyens sont présentés sur la figure 6.6. A première vue, on constate que la plupart du temps, les coefficients Kappa obtenus pour les jeux de bandes sélectionnées selon les différents scores testés évoluent de manière assez semblable quel que soit le classifieur (RBF SVM, RF ou ML) utilisé pour l’évaluation. Autrement dit, un score de sélection d’attributs qui conduit à un bon résultat pour un classifieur donnera aussi généralement de bons résultats pour les autres classifieurs. Aussi, les performances du score apparaissent plutôt indépendantes du classifieur utilisé lors de l’étape de validation.

On peut aussi remarquer d’après la figure 6.6 que les meilleurs critères de sélection d’attributs conduisent à des classifications de qualité assez similaire. Ce résultat est clairement visible pour le jeu Pavie, et dans une moindre mesure pour Salinas. A l’inverse, les résultats sont plus contrastés pour Indian Pines. Ceci pourrait être dû au fait qu’Indian Pines est un jeu de données plus difficile, avec une forte variabilité intra-classe et des similarités entre classes différentes plus fortes (voir section 6.4.3), alors que Pavie est un jeu de données très simple avec peu de classes se distinguant bien les unes des autres.

Ces résultats vont maintenant être analysés par famille de critères de sélection. Les profils d’importance de bandes seront également pris en compte.




FIGURE 6.6 – Coefficients Kappa (en %) moyens obtenus par les classifieurs RBF SVM (bleu), RF (rouge) et ML (jaune) en utilisant les jeux de bandes sélectionnés d'après les différents critères de sélection d'attributs testés. De haut en bas : résultats obtenus pour Pavia, Indian Pines et Salinas.

### Comparaison de critères de type *wrapper* classiques

On peut constater sur la figure 6.6 que les scores *sam.K*, *sid.K* et *sidsam.K* sont moins bons que les autres scores de type *wrapper*. Ce phénomène apparaît fortement dans les cas d'Indian Pines et de Salinas et s'observe comme une tendance légère dans le cas de Pavie. Le fait que ce phénomène est le plus marqué pour Indian Pines est vraisemblablement lié à la forte variabilité intra-classe de ce jeu de données. N'oublions pas que pour ces classifieurs, on utilise comme modèle pour chaque classe un seul spectre de référence, à savoir le spectre moyen calculé à partir de ces échantillons d'apprentissage. Les autres scores de type *wrapper* reposant sur le Kappa comme mesure de qualité de classification conduisent à des résultats quantitatifs sensiblement équivalents. Néanmoins, on peut faire quelques commentaires complémentaires si l'on regarde les profils d'importance des bandes qui leur sont associés (figure 6.7 et 6.8). Ainsi, dans le cas de Pavie (figure 6.7), on peut voir que le critère *svm.lin.K* a tendance à sélectionner les premières bandes (autour de la bande 5) du spectre, alors qu'il apparaît que ces bandes sont assez bruitées. Le critère *ml.K* donne d'excellents résultats si l'on ne considère que l'évaluation quantitative, mais a tendance à être très sensible à un probable artefact de correction atmosphérique : ce critère accorde ainsi beaucoup d'importance à la portion du spectre comprise entre les bandes 80 et 85, et particulièrement à la bande 82. Or cette portion du spectre correspond en fait à un artefact de correction atmosphérique (qui se trouve peut-être être ici discriminant par accident), et non à un véritable comportement caractéristique permettant de bien discriminer les différentes classes. Cette tendance à sélectionner ces quelques bandes correspondant à cet artefact est par ailleurs observée avec plus ou moins de force pour d'autres critères de sélection d'attributs.

### Comparaison de critères de type *wrapper* : comparaison entre critères classiques et critères prenant en compte la confiance

Le fait d'utiliser des scores prenant en compte la confiance du classifieur au lieu de scores classiques mesurant (à l'image du coefficient Kappa) le taux de bonne classification a tendance à améliorer les résultats. Cette tendance est observée sur la figure 6.6, à la fois dans le cas des classifieurs RF et SVM : l'utilisation des scores *rf.appart* ou *rf.conf* au lieu de *rf.K*, ou celle de *svm.lin.appart* ou *svm.lin.conf* au lieu de *svm.lin.K* ont une légère tendance à améliorer la qualité des classifications obtenues. Si l'on observe les importances de bandes obtenues pour Pavie (figure 6.9), on constate que l'utilisation de *rf.appart* au lieu de *rf.K* évite de sélectionner les bandes bruitées situées autour de la bande 5. Les profils d'importance de bandes obtenus en utilisant *rf.appart* semblent aussi sensiblement plus réguliers que lorsque l'on utilise *rf.K*, à la fois pour Pavie (fig. 6.9) et Indian Pines (fig. 6.10). Ce phénomène est encore plus marqué dans le cas du critère *rf.conf*. Ainsi, le fait d'utiliser un critère de sélection d'attributs intégrant la confiance du classifieur a tendance à régulariser les importances de bandes et à stabiliser la sélection d'attributs.

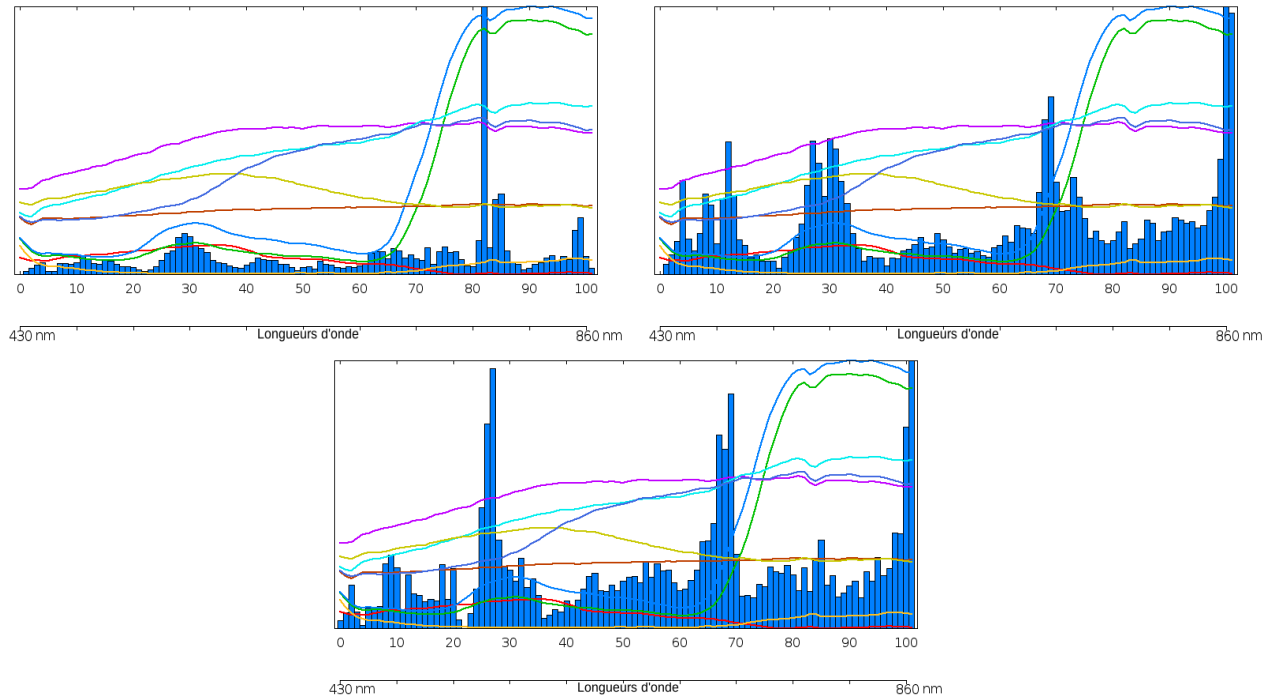


FIGURE 6.7 – Pavie : profils d'importance de bandes obtenus pour différents critères de sélection d'attributs :  $ml.K$  (en haut à gauche),  $svm.lin.K$  (en haut à droite),  $rf.K$  (en bas)

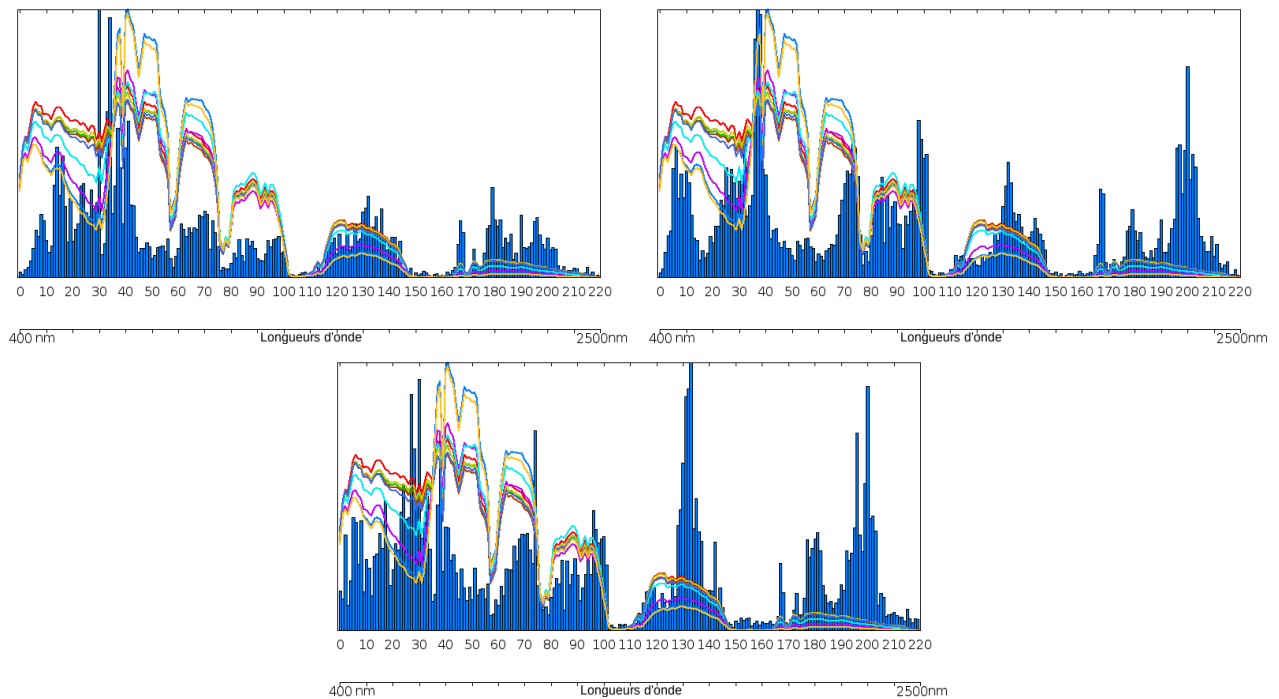


FIGURE 6.8 – Indian Pines : profils d'importance de bandes obtenus pour différents critères de sélection d'attributs :  $ml.K$  (en haut à gauche),  $svm.lin.K$  (en haut à droite),  $rf.K$  (en bas)



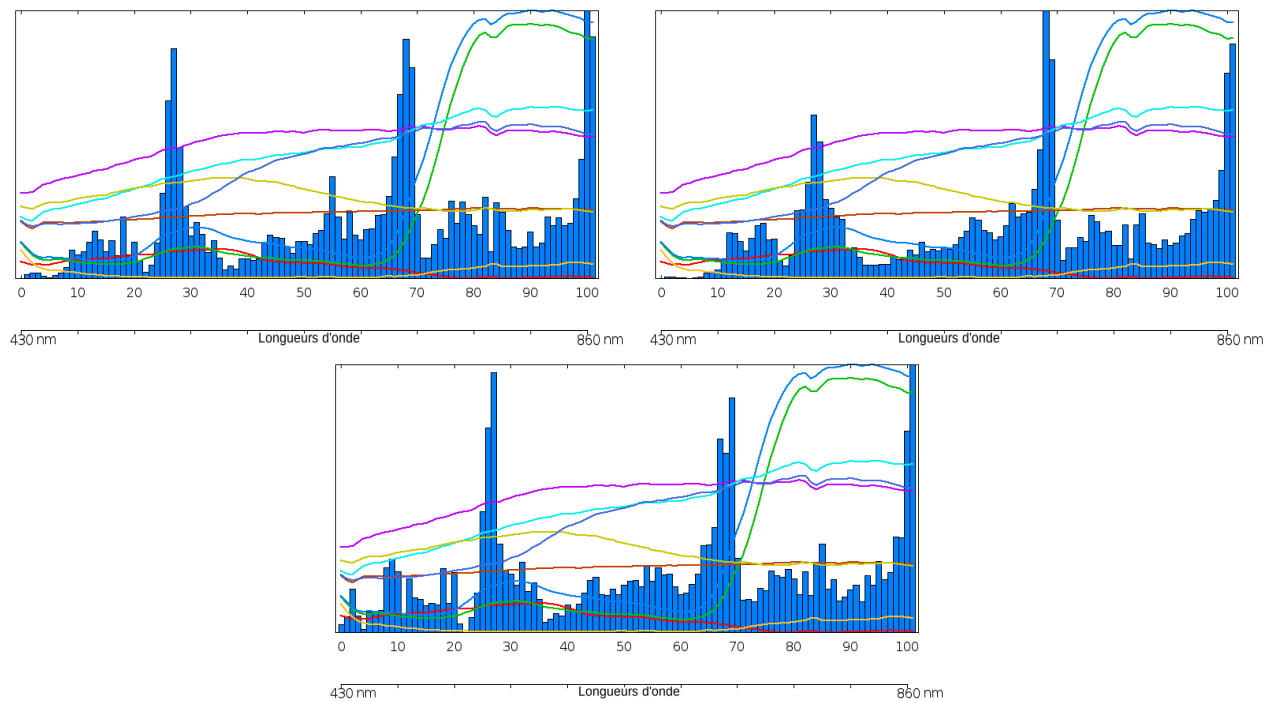


FIGURE 6.9 – Pavia : profils d'importance de bandes obtenus pour différents critères de sélection d'attributs :  $rf.appart$  (en haut à gauche),  $rf.conf$  (en haut à droite),  $rf.K$  (en bas)

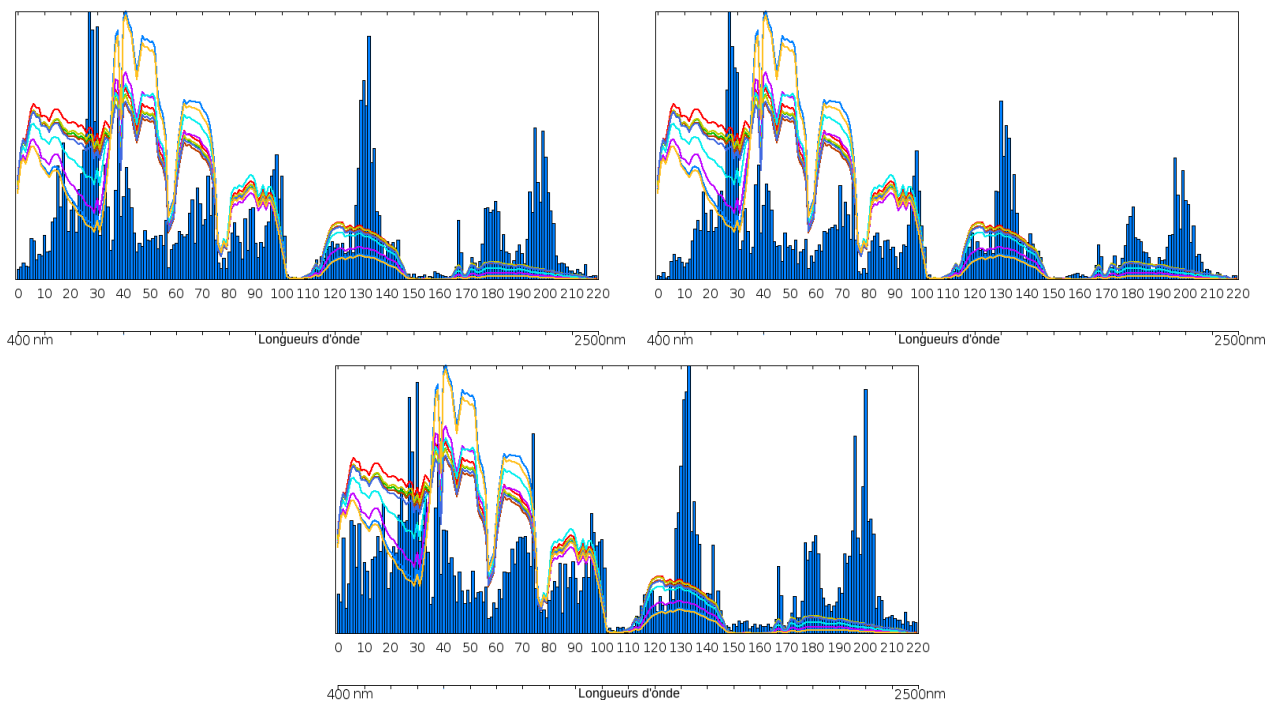


FIGURE 6.10 – Indian Pines : profils d'importance de bandes obtenus pour différents critères de sélection d'attributs :  $rf.appart$  (en haut à gauche),  $rf.conf$  (en haut à droite),  $rf.K$  (en bas)

### Comparaison entre critères *wrapper* et *embedded*

Les performances de classification atteintes en utilisant les critères *embedded* (*svm.lin.marg* et *rf.oob*) sont généralement moins bonnes que celles obtenues pour les scores *wrapper* associés à ces deux classifieurs. Ce phénomène apparaît de manière particulièrement nette dans le cas de *svm.lin.marg*, qui est le plus mauvais parmi tous les critères testés, et ceci pour tous les classifieurs utilisés lors de l'étape d'évaluation.

Même s'ils restent assez bons, les jeux de bandes sélectionnés par le critère *rf.oob* donnent ensuite généralement des résultats de classification moins bons que les autres scores de type *wrapper*, et en particulier aux autres scores *rf.K*, *rf.appart* et *rf.conf* également associés au même classifieur des Random Forests.

### Comparaison de critères *wrapper* et filtre

Du point de vue de l'évaluation quantitative (fig. 6.6), le critère basé sur l'information mutuelle (*im*) donne des résultats très variables en fonction des différents jeux de données. Ainsi, pour Pavie, les jeux de bandes sélectionnés d'après ce critère permettent des taux de bonne classification du même ordre que ceux obtenus pour les meilleurs scores de type *wrapper*, tandis qu'à l'inverse, les résultats qu'ils obtiennent sont parmi les plus mauvais dans le cas du jeu Indian Pines. Les profils d'importance de bandes (figures 6.11 et 6.12) obtenus selon ce critère *im* sont également très différents de ceux obtenus pour les autres critères : ils tendent en effet à négliger des portions complètes du spectre. Ce phénomène est particulièrement frappant dans le cas d'Indian Pines, pour lequel les bandes comprises entre 30 et 100 sont considérées comme absolument non importantes, contrairement aux autres scores testés. Ceci s'explique par le fait que ce score est construit de manière à rechercher le jeu de bandes les plus corrélées avec la vérité terrain et les moins corrélées entre elles. Dans le cas d'Indian Pines, on se trouve face à des groupes de bandes tellement corrélées à la vérité terrain que le fait qu'elles soient également assez corrélées entre elles est moins bien pris en compte par le critère. Le fait de modifier la pondération entre ces deux conditions pourrait régler ce problème, mais on introduirait alors un nouveau paramètre à régler.

Les autres scores de type filtre qui ont été testés sont des mesures de séparabilité. Ils donnent d'excellents résultats du point de vue de l'évaluation quantitative (fig. 6.6) : ils conduisent en effet à des résultats aussi bons voire meilleurs que ceux obtenus par les meilleurs scores de type *wrapper*. En particulier, la mesure de séparabilité de Jeffries-Matusita (*jm*) apparaît comme l'un des meilleurs critères.

Toutefois, si l'on s'intéresse aux profils d'importance de bandes pour Pavie (figure 6.11) d'après le critère *jm*, on constate qu'il donne beaucoup d'importance à la partie du spectre (bandes 80 à 85), correspondant à des artefacts de correction atmosphérique. Ce phénomène se produit également pour les critères *bdist.moy*, *bdist.min*, *fisher.moy* et *fisher.min*.

De surcroît, les profils d'importances de bandes obtenus en utilisant par exemple le critère *jm* semblent sensiblement moins réguliers et plus difficiles à interpréter que ceux obtenus par les meilleurs *wrapper* (*rf.appart*, *rf.conf*).

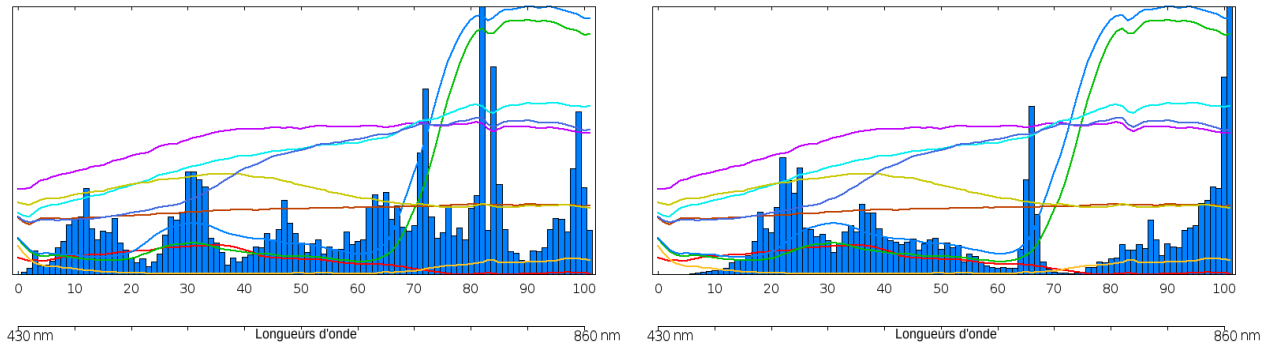


FIGURE 6.11 – Pavie : profils d'importance de bandes obtenus pour la distance de JM (à gauche) (score  $jm$ ) et l'information mutuelle (à droite) (score  $im$ )

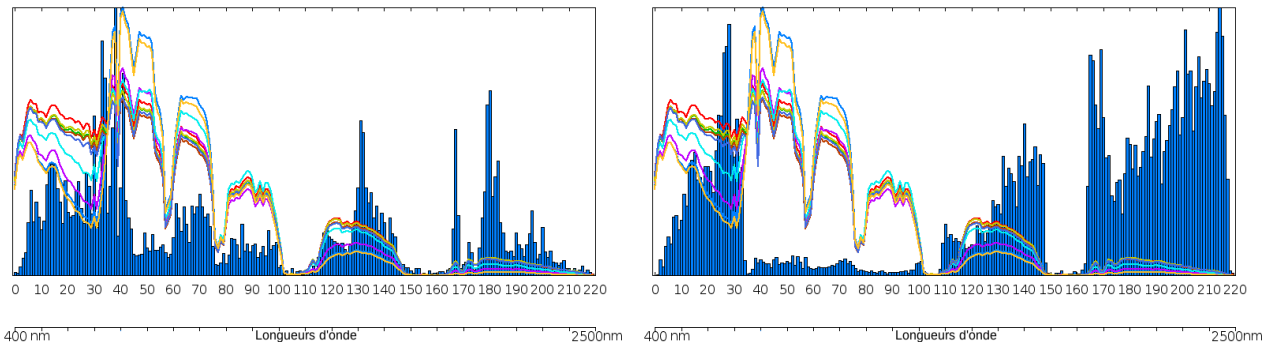


FIGURE 6.12 – Indian Pines : Profils d'importance de bandes obtenus pour la distance de JM (à gauche) (score  $jm$ ) et l'information mutuelle (à droite) (score  $im$ )

## Bilan

Différents critères de sélection d'attributs *wrapper*, *embedded* et filtre ont été testés, comparés et évalués sur plusieurs jeux de données.

- *svm.lin.marg* apparaît clairement comme le plus mauvais d'entre eux, donnant des résultats médiocres sur les différents jeux de données.
- D'autres (*sam.K*, *sid.K* and *im*) fonctionnent plutôt bien sur les jeux de données les plus simples, mais de manière médiocre sur le jeu le plus difficile (Indian Pines) où les différentes classes tendent à la fois à se ressembler et à présenter une variabilité intra-classe plus importante.
- La plupart des critères testés fonctionnent plutôt bien, permettant d'obtenir des classifications de bonne qualité. Si les meilleurs scores sont les mesures de séparabilité (filtre) et certains scores de type *wrapper*, on peut observer certaines tendances :
  - Les critères de type séparabilité ont tendance à conduire à des classifications légèrement meilleures (du point de vue de l'évaluation quantitative) que les scores de type *wrapper*. En particulier, le critère *jm* apparaît le plus souvent comme étant le meilleur score du point de vue de l'analyse quantitative. Toutefois, du point de vue qualitatif, les profils d'importance des bandes obtenus pour ce score sont un peu moins réguliers que ceux des *wrappers*, avec par conséquent des solutions peut-être un peu moins stables. Par ailleurs, dans le cas du

jeu de données Pavie, ce critère a tendance à être assez sensible à un artefact de correction atmosphérique.

- Les scores intégrant la confiance du classifieur (*rf.appart*, *rf.conf*, *svm.lin.appart.conf* ou *svm.lin.conf*) semblent mieux fonctionner que les scores *wrapper* classiques exprimés comme de simples taux de bonne classification. Cette tendance a pu être observée à la fois lors des analyses quantitative et qualitative (profils d’importance des bandes). Prendre en compte la confiance du classifieur a en effet tendance à produire des profils d’importance de bandes plus réguliers et donc à fournir des solutions plus stables.

Pour résumer, on peut considérer que les critères de sélection d’attributs les plus intéressants sont *rf.appart* et *rf.conf* pour les *wrappers* et *jm* pour les filtres, puisque ce sont eux qui permettent d’obtenir les meilleurs résultats quantitatifs. *rf.appart/rf.conf* semblent fournir des solutions plus stables que *jm*. Par ailleurs, ils semblent être aussi plus robustes à certains artefacts (comme l’artefact de correction atmosphérique dans le cas de Pavie).

Plusieurs conclusions peuvent être tirées sur les parties du spectre intéressantes d’après les profils d’importance des bandes calculés pour les différents critères.

- Les configurations spectrales optimales sont différentes d’un critère de sélection d’attributs à un autre. En effet, si certaines parties du spectre sont considérées comme importantes par la plupart des critères testés, d’autres correspondent à des désaccords entre les critères.
- Les zones considérées comme importantes sont souvent “explicables”. Elles peuvent en effet correspondre à une zone à peu près constante avant ou après une forte variation de certains spectres, ou encore à des zones où certains spectres se croisent.
- Sur les jeux de données Indian Pines et Salinas, aucune précaution n’avait été prise quant aux bandes très bruitées correspondant aux principales fenêtres d’absorption atmosphériques. Or on constate avec satisfaction que pour la plupart des critères testés (à l’exception des plus mauvais), ces zones du spectre se voient attribuées des importances très faibles. On peut y voir un critère de qualité des scores testés.
- Les profils d’importance de bandes obtenus pour le jeu de données Indian Pines sont souvent plus difficiles à analyser que pour Pavie. Néanmoins, quelques tendances communes peuvent être observées, en particulier dans le domaine du SWIR, où certains blobs le long du spectre sont visibles pour la majorité des critères testés. De manière plus générale, certaines zones du SWIR apparaissent comme importantes (au même niveau que les zones du VNIR) pour les différents scores de sélection d’attributs testés.

### 6.4.3 Exemples de classifications obtenues en utilisant les bandes sélectionnées

Afin de discuter plus en détail de la qualité et des limites des résultats obtenus en utilisant les critères *jm*, *rf.appart* et *rf.conf* de sélection d’attributs identifiés précédemment comme étant les meilleurs, cette section présente quelques exemples de classifications obtenues en utilisant les jeux de bandes sélectionnées. Tous les résultats présentés (carte de classification et matrices de confusion) ont été obtenus en utilisant un classifieur SVM avec noyau gaussien.

## Salinas

Le tableau 6.2 présente les indicateurs de bonne classification moyens obtenus pour les jeux de bandes sélectionnés à l'aide des critères *jm* ou *rf.appart*. Y sont présentés, pour chaque classe, ses précisions utilisateur (*User Acc.*) et producteur (*Prod Acc.*) ainsi que son F-score. Ces indicateurs ont en fait été moyennés sur les 25 jeux de bandes proposés comme solutions lors des différents lancements de l'algorithme génétique, pour un critère de sélection d'attributs donné. Il apparaît d'abord que les résultats obtenus en utilisant *jm* ou *rf.appart* ne sont généralement pas significativement différents. On peut toutefois remarquer, pour la plupart des classes, une tendance du F-score (i.e. une mesure alternative entre précisions producteur et utilisateur) à être très légèrement meilleur lorsque l'on utilise le critère *rf.appart* plutôt que *jm*. La seule exception concerne la classe "Lettuce\_romaine\_4wk" pour laquelle le F-score est fortement amélioré lorsque l'on utilise *rf.appart*. La plupart des classes sont très bien classées, à l'exception des classes "Grapes\_untrained" et "Vineyard\_untrained". Par ailleurs, les classes les plus mal traitées sont les mêmes pour les deux scores de sélection d'attributs, et leurs précisions sont très similaires que l'on utilise *jm* ou *rf.appart*. La figure 6.13 montre un exemple de carte de classification obtenue en utilisant le meilleur jeu de bandes (parmi toutes les solutions proposées) obtenu en utilisant *rf.appart* comme critère de sélection d'attributs. Les parcelles correspondant aux deux classes les plus mal traitées ("Grapes\_untrained" et "Vineyard\_untrained") apparaissent en rose et magenta en haut à gauche de l'image. Des confusions entre ces deux classes se produisent. Or ces deux classes semblent sémantiquement assez proches. Aussi, ces confusions risquent de ne pas être évitées même en utilisant plus de bandes, indépendamment du score de sélection d'attributs.




FIGURE 6.13 – De gauche à droite : image de Salinas, carte de vérité terrain associée et exemple de classification obtenue par un classifieur SVM avec noyau gaussien pour un jeu de bandes optimal obtenu d'après le critère *rf.appart*. La plupart des confusions concernent deux classes qui semblent sémantiquement assez proches.

TABLE 6.2 – Salinas : indicateurs de qualité de la classification (précision utilisateur, précision producteur et F-score exprimés en %) obtenue pour des jeux de bandes sélectionnées d’après les critères *jm* et *rf.appart*. Ces chiffres sont des moyennes calculées sur les 25 jeux de bandes proposés à l’issue de plusieurs lancements des algorithmes génétiques.

Classes	<i>jm</i>			<i>rf.appart</i>		
	User Acc.	Prod. Acc.	F-score	User acc.	Prod. Acc.	F-score
<i>Broccoli_green_weeds_1</i>	99,7	98,4	<b>99,1</b>	99,8	98,2	99,0
<i>Broccoli_green_weeds_2</i>	98,9	99,6	<b>99,3</b>	98,8	99,6	99,2
<i>Celery</i>	98,7	99,6	99,1	99,1	99,6	<b>99,4</b>
<i>Corn_senesced_green_weeds</i>	89,0	89,9	89,4	88,0	91,0	89,4
<i>Fallow</i>	93,0	97,4	95,1	93,5	97,6	<b>95,5</b>
<i>Fallow_rough_plow</i>	98,0	99,2	<b>98,6</b>	97,9	99,2	98,5
<i>Fallow_smooth</i>	97,5	97,2	97,3	97,6	97,7	<b>97,6</b>
<i>Grapes_untrained</i>	79,4	69,9	74,2	79,4	71,3	<b>75,0</b>
<i>Lettuce_romaine_4wk</i>	84,9	96,5	90,2	91,4	97,4	<b>94,2</b>
<i>Lettuce_romaine_5wk</i>	97,1	99,1	98,0	97,1	99,2	<b>98,1</b>
<i>Lettuce_romaine_6wk</i>	95,9	97,5	96,7	95,9	97,6	<b>96,8</b>
<i>Lettuce_romaine_7wk</i>	91,2	94,8	92,8	93,4	94,5	<b>93,9</b>
<i>Soil_vineyard_developed</i>	98,8	97,6	98,2	98,9	98,4	<b>98,7</b>
<i>Stubble</i>	99,9	99,4	99,7	99,9	99,4	<b>99,7</b>
<i>Vineyard_untrained</i>	62,9	70,9	66,5	63,8	70,3	<b>66,7</b>
<i>Vineyard_vertical_trellis</i>	96,6	97,7	97,1	97,4	98,0	<b>97,7</b>
Moyenne	92,6	94,1	93,2	93,2	94,3	<b>93,7</b>
Minimum	62,9	66,8	66,4	63,8	67,5	<b>66,7</b>
Maximum	99,9	99,8	99,8	99,9	99,8	<b>99,8</b>

### Indian Pines data set

Le tableau 6.3 présente les indicateurs de bonne classification moyens obtenus pour les jeux de bandes sélectionnées à l'aide des critères *jm* ou *rf.appart*. Y sont présentés pour chaque classe ses précisions utilisateur (*User Acc.*) et producteur (*Prod Acc.*) ainsi que son F-score. Ces indicateurs ont en fait été moyennés sur les 25 jeux de bandes proposés comme solutions lors des différents lancements de l'algorithme génétique, pour un critère de sélection d'attributs donné. Le fait d'utiliser *jm* ou *rf.appart* a peu d'impact sur le F-score (moins de 1 %) pour la plupart des classes, exceptés "Corn-notill" et "Soybean-clean", qui sont mieux discriminés lorsque l'on utilise des jeux de bandes sélectionnés d'après *jm*. Ces classes font par ailleurs partie des classes les plus mal classées.

Il faut aussi préciser que ce jeu de données est difficile, puisque certaines des classes sont très similaires et tendent donc à se confondre. Ainsi, certaines classes concernent le même type de culture à différents stades de développement. Les confusions se produisent aussi souvent entre des classes concernant des cultures différentes dans leur premier stade de développement, alors qu'elles ont encore peu poussé et que le sol nu apparaît encore majoritairement. De telles confusions sont constatées dans la matrice de confusion (tableau 6.4), comme par exemple entre les classes "Corn-notill" et "Soybean-mintill" ou "Soybean-notill". Par exemple, sur la figure 6.14, une parcelle de "Corn-notill" située en haut à gauche de l'image est majoritairement confondue avec la classe "Soybean-notill". En outre, ce phénomène est amplifié par une importante variabilité intra-classe. Ceci peut être nettement observé dans la figure 6.14 sur les parcelles les plus grandes situées au centre de l'image. Aussi, la carte de classification obtenue (figure 6.14) semble plutôt bruitée.

Remarque : Certains papiers présentent de meilleurs résultats sur ce jeu de données. Les résultats obtenus ici sont pourtant conformes à ceux obtenus dans d'autres travaux dans des conditions similaires, notamment [Roscher *et al.* 2012b] qui adoptent une stratégie d'apprentissage similaire à celle mise en œuvre ici en utilisant le même nombre d'échantillons pour chacune des classes. [Roscher *et al.* 2012b] montrent aussi qu'il est possible d'améliorer les résultats en prenant plus d'échantillons. Il faut aussi garder à l'esprit que, sur ce jeu de données, la quantité de pixels de vérité terrain disponibles pour la plupart des classes reste limitée. Par ailleurs, les classes n'y sont pas présentes de manière équilibrée, certaines d'entre elles concernant très peu d'échantillons de vérité terrain. Aussi, d'autres stratégies d'apprentissage utilisent pour chaque classe un nombre d'échantillons d'apprentissage correspondant à la même proportion de l'ensemble des échantillons de la classe, ce qui peut, dans le cas particulier de ce jeu de données, avoir un impact sur les résultats de classification (notamment avec les SVM). Toutefois, le processus d'apprentissage utilisant le même nombre d'échantillons pour chaque classe et mis en œuvre ici nous semble plus adapté : il ne fait en effet aucun *a priori* sur les classes, les considérant comme équiprobables et donnant donc la même importance à chacune d'elle.

TABLE 6.3 – Indian Pines : indicateurs de qualité de la classification (précision utilisateur, précision producteur et F-score en %) obtenus pour des jeux de bandes sélectionnées d’après les critères *jm* et *rf.appart*. Ces chiffres sont des moyennes calculées sur les 25 jeux de bandes proposés à l’issue des différents lancements des AG.

Classes	<i>jm</i>			<i>rf.appart</i>		
	User Acc.	Prod. Acc.	F-score	User acc.	Prod. Acc.	F-score
<i>Corn-mintill</i>	60,6	74,6	66,7	61,7	74,3	<b>67,2</b>
<i>Corn-notill</i>	70,1	75,9	<b>72,8</b>	67,6	72,6	69,9
<i>Grass-pasture</i>	79,7	93,3	85,8	81,1	93,6	<b>86,7</b>
<i>Grass-trees</i>	93,1	98,0	<b>95,5</b>	92,9	97,1	94,9
<i>Hay-windrowed</i>	98,7	99,8	<b>99,3</b>	98,5	99,7	99,0
<i>Soybean-clean</i>	70,9	84,4	<b>76,9</b>	67,7	81,9	73,9
<i>Soybean-mintill</i>	84,2	61,1	<b>70,8</b>	83,1	59,8	69,4
<i>Soybean-notill</i>	66,3	78,6	71,8	66,0	80,4	<b>72,4</b>
<i>Woods</i>	98,9	95,0	96,9	98,9	95,9	<b>97,4</b>
Moyenne	80,3	84,5	<b>81,8</b>	79,7	83,9	81,2
Minimum	59,7	61,1	<b>66,4</b>	59,5	59,8	66,2
Maximum	99,2	99,8	<b>99,3</b>	99,1	99,7	99,1



TABLE 6.4 – Indian Pines : matrice de confusion moyennée sur les 25 jeux de bandes proposés à l'issue des différents lancements des AG pour le score *rf.appart*.

groundtruth \ classif	<i>Corn-mintill</i>	<i>Corn-notill</i>	<i>Grass-pasture</i>	<i>Grass-trees</i>	<i>Hay-windrowed</i>	<i>Soybean-clean</i>	<i>Soybean-mintill</i>	<i>Soybean-notill</i>	<i>Woods</i>
<i>Corn-mintill</i>	74,3	7,6	0,1	0,2	0	7,6	9,3	0,9	0
<i>Corn-notill</i>	6,4	72,6	0,4	0,4	0,0	1,8	9,6	8,8	0
<i>Grass-pasture</i>	0,1	0,2	93,6	1,7	1,1	1,0	0,2	0,9	1,3
<i>Grass-trees</i>	0	0,0	1,6	97,1	0,0	0,0	0,1	0,0	1,1
<i>Hay-windrowed</i>	0	0	0,3	0,0	99,6	0,0	0	0	0
<i>Soybean-clean</i>	6,3	3,2	0,6	1,6	0	81,9	3,4	3,1	0
<i>Soybean-mintill</i>	9,6	14,3	1,0	0,5	0,0	4,9	59,8	9,8	0,0
<i>Soybean-notill</i>	1,8	6,9	1,5	0,3	0,0	1,4	7,6	80,4	0
<i>Woods</i>	0	0,0	3,0	1,0	0	0,0	0,0	0	95,9



FIGURE 6.14 – De gauche à droite : image d’Indian Pines, carte de vérité terrain associée et exemple de classification obtenue par un classifieur SVM avec noyau gaussien pour un jeu de bandes optimal obtenu d’après le critère *rf.appart*.

## 6.5 Conclusion

Le travail qui vient d’être présenté s’est particulièrement focalisé sur la comparaison de différents critères de sélection d’attributs. Tous les critères testés ont été optimisés sur des jeux de données hyperspectrales en utilisant les mêmes heuristiques d’optimisation. Le nombre de bandes à sélectionner a d’abord été déterminé pour chaque jeu de données à l’aide d’un algorithme incrémental de sélection d’attributs. Les différents critères ont ensuite été optimisés par un algorithme génétique, qui a proposé plusieurs solutions possibles. Ces différents jeux de bandes ont alors été évalués et comparés au sens d’indicateurs de qualité d’une classification. Une analyse qualitative a également été menée, en considérant une mesure d’importance des bandes calculée à partir de résultats intermédiaires de l’algorithme génétique et permettant d’identifier visuellement les parties du spectre identifiées comme étant les plus importantes d’après les différents critères de sélection d’attributs.

### Bilan de la comparaison des critères de sélection

Au final, la plupart des critères testés conduisent à de bons résultats. Peu d’entre eux donnent des résultats réellement moins bons voire médiocres : *svm.lin.marg* est apparu comme le moins bon critère, conduisant à de mauvais résultats sur les différents jeux de données, tandis que d’autres critères (*sam.K*, *sid.K* et *im*) fonctionnent assez bien sur les deux jeux de données les plus simples, et nettement moins bien sur le jeu de données le plus difficile.

A l’inverse, les autres critères ont permis de sélectionner des jeux de bandes conduisant à de bonnes classifications de qualités sensiblement équivalentes, même si certaines tendances très légères peuvent être observées. D’abord, les scores de type filtre basés sur des mesures de séparabilité conduisent à des résultats de classification sensiblement meilleurs que les meilleurs scores de type *wrapper*. En particulier, la distance de Jeffries-Matusita *jm* est souvent apparue comme le meilleur critère lors des analyses quantitatives. Toutefois, ce critère tend à donner des profils d’importance de bandes moins stables et réguliers que certains scores de type *wrapper* et, dans le cas du jeu de données Pavie, à être assez sensible à un artefact de correction atmosphérique. Enfin, des scores de type *wrappers* prenant en compte la confiance du classifieur permettent d’obtenir de meilleurs résultats que des scores *wrapper* classiques comme un simple taux de bonne classification. Ainsi, ce type de score appliqué à un classifieur Random Forest a été identifié

comme l'un des meilleurs critères de sélection d'attributs, tant d'un point de vue quantitatif que qualitatif. La prise en compte de la confiance du classifieur dans le critère de sélection d'attributs a en effet tendance à régulariser les profils d'importance des bandes et à fournir des jeux de bandes plus stables.

Par conséquent, même si les autres scores sont quasiment aussi bons, on considérera que les critères les plus intéressants sont les scores prenant en compte la confiance d'un classifieur Random Forests (*rf.appart*) et *rf.conf*) pour les *wrappers* et la distance de Jeffries-Matusita (*jm*) pour les filtres. Ces scores conduisent en effet aux meilleurs résultats quantitatifs. *rf.appart* ou *rf.conf* semble de plus fournir des résultats plus stables que *jm*, si l'on considère ses profils d'importance de bandes plus réguliers. Ces scores semblent aussi plus robustes à certains artefacts. Toutefois, même si les temps de calcul ne sont pas une contrainte majeure dans notre cas et n'ont donc pas été discutés en détail dans l'étude qui précède, on peut ajouter que les critères basés sur les méthodes de type filtre sont plus rapides que les *wrapper* comme *rf.appart* ou *rf.conf*.

### Apports proposés

Plusieurs apports ont été proposés dans ce chapitre.

- Une comparaison de différents critères de sélection d'attributs a été réalisée. Les critères testés étaient issus des trois familles d'approches “*wrapper*”, “*embedded*” ou “filtre” de sélection d'attributs. Les critères qui ont été comparés se limitaient à ceux permettant de mesurer la performance d'un jeu de bandes et utilisables dans le cadre d'approches d'optimisation génériques.
- L'approche mise en place pour les comparer est assez originale dans le sens où elle les évalue à la fois de manière quantitative (par le biais des taux de bonne classification obtenus par différents classifieurs pour les configurations spectrales optimisées au sens des différents critères), mais également qualitative en s'intéressant au comportement des sélections proposés par le biais de profils d'importance des bandes au sens des différents scores de sélection d'attributs testés.
- Une mesure d'importance des bandes calculée à partir des résultats intermédiaires d'un algorithme génétique a été proposée. On obtient alors des profils d'importance de bandes qui permettent de constater visuellement quelles parties du spectre sont importantes, au sens où elles ont souvent été sélectionnées. Ces profils ont été utilisés pour la comparaison qualitative des différents scores de sélection d'attributs.
- Des critères de type *wrapper* pour la sélection d'attributs ont été proposés : ces critères sont associés à un classifieur et prennent en compte la confiance avec laquelle ce classifieur classe les échantillons. Ils ne se limitent donc pas comme la plupart des scores *wrapper* à un simple taux de bonne classification, et nous donnent un score intermédiaire entre les séparabilités de type filtre et les scores taux de bonne classification *wrapper* classiques. Ces scores sont apparus comme étant parmi les meilleurs critères notamment lorsqu'ils sont associés à un classifieur RF.

#### 6.5.1 Stratégie de sélection de bandes mise en œuvre dans la suite

Le processus de sélection de bandes qui sera mis en œuvre dans la suite sera assez semblable à celui mis en œuvre pour comparer les différents critères de sélection d'attributs.

On commencera par utiliser l'algorithme SFFS pour fournir des indicateurs pour déterminer le nombre de bandes utiles. Le choix du nombre de bandes à sélectionner aurait alors pu être

automatisé (et aurait dû l'être dans le cas où la sélection d'attributs avait été faite comme un pré-traitement d'une chaîne de classification), mais dans le contexte de la conception d'un capteur, il est intéressant de pouvoir conserver la main sur ce paramètre.

Ensuite, on effectuera plusieurs sélections de bandes à l'aide de l'algorithme génétique. On obtiendra donc comme précédemment des profils d'importance des différentes bandes ainsi que plusieurs jeux de bandes optimisés parmi lesquels on pourra choisir la meilleure solution, comme étant celle qui respecte au choix l'un des critères suivants :

- la solution qui maximise le score de sélection d'attribut.
- le jeu de bandes qui présente les bandes les moins corrélées entre elles, autrement dit celui qui minimise la corrélation inter-bandes
- le jeu dont les bandes se trouvent le plus possible dans les zones du spectre considérées comme importantes d'après les profils d'importance de bandes

Les scores de sélection de bandes qui seront utilisés dans la suite seront les scores *rf.appart* ou *rf.conf*, ou encore *jm* dans les cas où l'on a besoin d'un critère un peu plus rapide.

## 6.6 Perspectives

### 6.6.1 Présélection de bandes utiles à l'aide de mesures de type filtre

Plusieurs méthodes de type filtre ou *embedded* consistent à calculer pour chaque attribut un score d'importance, classer les attributs en fonction de ce score puis n'en conserver que les  $n$  meilleurs. De tels scores, calculés pour chaque attribut, sont par exemple celui de l'algorithme RELIEFF [Kira et Rendell 1992, Kononenko *et al.* 1997], ou le score de Fischer. D'autres scores de ce type mesurant la corrélation (au sens de l'information mutuelle) entre chaque bande et la vérité terrain sont présentés dans [Hall et Holmes 2003]. Ces différentes mesures d'importance se calculent très rapidement.

On peut voir sur la figure 6.15 des exemples de telles mesures d'importance calculées pour les scores *CorrelationAttributeEval*, *SymmetricalUncertAttributeEval* et *ReliefFAttributeEval* du logiciel Weka<sup>1</sup>.

- Le score *CorrelationAttributeEval* correspond simplement à une mesure de la corrélation (au sens de Pearson) entre attributs et classes.
- Le score *ReliefFAttributeEval* est calculé par l'algorithme ReliefF [Kira et Rendell 1992, Kononenko *et al.* 1997].
- Le score *SymmetricalUncertAttributeEval* mesure l'incertitude symétrique d'un attribut par rapport à une classe et se calcule par la formule suivante :

$$\text{Sym}U(\text{classe}, \text{attribut}) = 2 \cdot \frac{H(\text{classe}) - H(\text{attribut}|\text{classe})}{H(\text{classe})} + H(\text{attribut})$$

avec  $H(\cdot)$  désignant l'entropie.

1. <http://www.cs.waikato.ac.nz/ml/weka/>

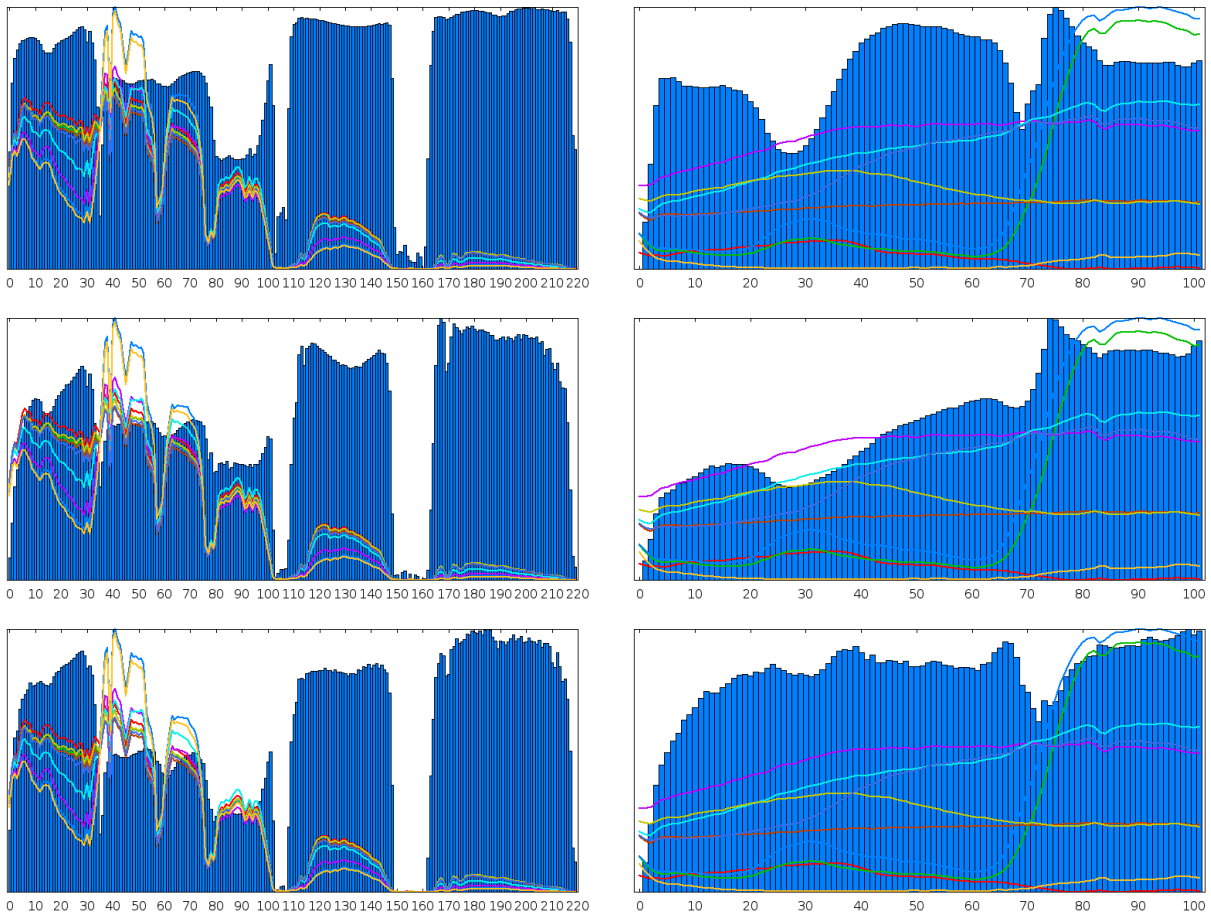


FIGURE 6.15 – Exemples pour Pavie (à gauche) et Indian Pines (à droite) d’importances de bandes données par différentes mesures de type filtre, avec de haut en bas, la corrélation entre les attributs et les classes, la mesure fournie par ReliefF et l’incertitude symétrique par rapport à une classe

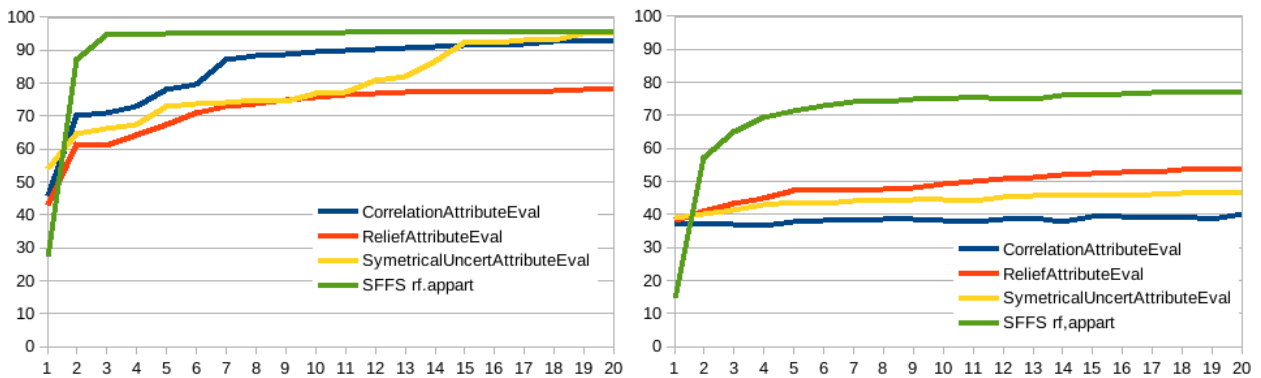


FIGURE 6.16 – Evolution (pour Pavie à gauche et Indian Pines à droite) du Kappa obtenu pour un classifieur SVM à noyau gaussien en fonction du nombre de bandes sélectionnées, pour des sélections de bandes effectuées à partir des 3 scores *CorrelationAttributeEval*, *ReliefAttributeEval* et *SymmetricalUncertAttributeEval* et par la méthode SFFS pour le score *rf.appart*

Ces mesures d'importance ne prennent pas en compte les dépendances entre bandes sélectionnées. Aussi un jeu de bandes spectrales défini à partir des  $n$  meilleures bandes d'après ces mesures ne sera pas forcément une solution optimale, ou du moins ne sera pas parcimonieuse, ainsi que l'illustre la figure 6.16 qui montre l'évolution d'un taux de bonne classification en fonction du nombre de bandes sélectionnées, pour des sélections de bandes effectuées à partir des 3 scores *CorrelationAttributeEval*, *ReliefFAttributeEval* et *SymetricalUncertAttributeEval* et par la méthode SFFS pour le score *rf.appart*. Néanmoins, si l'on s'intéresse à ces profils d'importance de bandes, on peut constater visuellement que certains groupes de bandes voisines et vraisemblablement corrélées se distinguent, formant des blobs pour lesquels les importances commencent à croître à partir d'un minimum local, puis augmentent jusqu'à un maximum local, puis redescendent. On peut donc considérer que ces maxima locaux vont correspondre à des bandes plus pertinentes que leurs voisines pour un problème de classification donné.

Aussi, on peut exploiter ces profils d'importance de bandes pour pré-sélectionner les bandes correspondant à ces maxima locaux, éventuellement après avoir lissé ces profils pour éviter d'en détecter de trop. On peut ensuite appliquer à ce jeu de bandes restreint (voir tableau 6.5) la méthode de sélection d'attributs présentée dans la section 6.5.1, mais pour une combinatoire déjà bien réduite (et donc avec un gain en terme de temps de calcul si ce critère est important).

	Pavie	Indian Pines	Salinas
Avant présélection	102	220	224
<i>CorrelationAttributeEval</i>	21	32	32
<i>ReliefFAttributeEval</i>	9	42	38
<i>SymetricalUncertAttributeEval</i>	19	53	49

TABLE 6.5 – Nombres de bandes conservées après pré-sélection suivant les différentes mesures filtres.

	Pavie	Indian Pines	Salinas
Nombre de bandes sélectionnées	7	10	7
Sans présélection	95.2	75	87.2
<i>CorrelationAttributeEval</i>	94.1	73.8	87.4
<i>ReliefFAttributeEval</i>	94.3	73.7	86.9
<i>SymetricalUncertAttributeEval</i>	94.8	74.3	87.5

TABLE 6.6 – Kappa (en %) obtenu pour les classifications utilisant des jeux de bandes sélectionnées parmi les sous-ensembles de bandes pré-sélectionnés par les mesures filtres.

On constate d'après le tableau 6.6 que les performances de classification atteintes en utilisant les jeux de bandes sélectionnées parmi ces pré-sélections de bandes importantes sont généralement très légèrement plus faibles que lorsque la sélection est faite parmi l'intégralité des bandes. Cet écart n'est toutefois pas très significatif. Aussi, dans un contexte différent de celui de l'optimisation spectrale en vue de la conception d'un capteur, si le temps de calcul devenait une contrainte, on pourrait avoir intérêt à utiliser la stratégie proposée de pré-sélection d'un sous-ensemble de bandes à partir de mesures filtres d'importance de bandes.

### 6.6.2 Utilisation d'indices calculés à partir des bandes

On obtient généralement de meilleurs résultats de classification en utilisant des indices calculés à partir des bandes. De tels indices peuvent être :

- des différences entre bandes :  $b_1 - b_2$
- des rapports entre bandes  $\frac{b_1}{b_2}$
- des différences normalisées (à la manière de l'indice NDVI) :  $\frac{b_1 - b_2}{b_1 + b_2}$

Il serait donc intéressant de prendre cet aspect en compte lors du processus d'optimisation spectrale, en optimisant le jeu de bandes spectrales, tout en définissant également les meilleurs indices à calculer à partir de ces bandes. On va donc appliquer le score de sélection d'attributs non pas directement au jeu de bandes originales sélectionnées, mais à un jeu d'indices dérivés de ce jeu de bandes originales sélectionnées. On se trouverait alors à la limite entre sélection d'attributs et extraction de caractéristiques (i.e. reformulation de la donnée originale sous la forme de nouveaux attributs). On rappellera au passage que dans le même ordre d'idée, certains processus de sélection d'attributs de la littérature en particulier basés sur des classifieurs SVM optimisent simultanément les attributs à utiliser et les paramètres du classifieur, par exemple au moyen d'un algorithme génétique comme dans le cas de [Fröhlich *et al.* 2003]. Par ailleurs, pour certaines applications de surveillance de la végétation, [Mariotto *et al.* 2013, Thenkabail *et al.* 2013, Aasen *et al.* 2014] cherchent à identifier la paire de bandes qui permettra de calculer l'indice (de type différence normalisée) qui corrélera le mieux avec le phénomène à observer.

Ce travail conjoint de sélection de bandes et de définition des indices dérivés à utiliser pour la classification peut être effectué simplement en modifiant le processus d'optimisation par les algorithmes génétiques. Précédemment les individus que l'on faisait évoluer était simplement des jeux de bandes. Leur chromosome se limitait donc à porter les numéros des bandes correspondantes.

Dans ce nouveau cas où l'on optimise également les indices dérivés, le chromosome d'un individu continue à porter les numéros des bandes qui le constitue, mais se voit également rajouter des gènes pour définir un jeu d'indices dérivés (voir figure 6.17). Pour chacun de ces indices, on a donc un code qui indique le type d'indice (bande originale (0), différence (1), rapport (2), différence normalisée (3)) ainsi que les numéros (au sein de la première partie du chromosome) des bandes originales sélectionnées impliquées dans le calcul de cet indice. Afin de rester parcimonieux, on fait le choix qu'un individu aura le même nombre d'indices dérivés que de bandes originales. On continue donc à sélectionner un jeu de bandes spectrales, mais le score de pertinence de cette sélection n'est pas directement calculé à partir de ces bandes brutes, mais de leurs indices dérivés.

Chromosome d'un individu correspondant à la sélection de 4 bandes originales

Chaque gène correspond au numéro d'une bande sélectionnée.




Chromosome d'un individu correspondant à une sélection de 4 bandes originales à partir desquelles on dérive 4 indices

Chaque gène de la partie bleue correspond au numéro d'une bande sélectionnée.

Le reste du chromosome correspond à la définition des indices dérivés.

Chacun de ces indices est défini par 3 gènes :

le type d'indice (bande originale, rapport, différence, différence normalisée) ainsi que les positions au sein de ce chromosome des 2 bandes originales à partir desquelles on dérive cet indice



Exemple :



Ce chromosome signifie que 4 bandes originales correspondant aux numéros 5, 12, 25 et 90 dans le jeu de données original sont sélectionnées, et que l'on en dérive 4 indices, dont le premier correspond à une différence (code 1) entre la première et la quatrième bandes sélectionnées, c'est-à-dire entre les bandes 5 et 90.

FIGURE 6.17 – Principe du codage des indices dérivés pour l'algorithme génétique



Les tableaux 6.8 et 6.7 présentent des résultats obtenus sur les jeux de données Pavie et Indian Pines pour les classifieurs RF et SVM avec noyau gaussien, selon que l'on utilise des jeux de bandes originales ou des jeux d'indices dérivés des bandes originales, pour une optimisation utilisant le score *rf.appart*. Dans le cas d'une classification avec le classifieur RF, une nette amélioration des résultats est observée lorsque l'on utilise les indices dérivés, plutôt que les bandes originales. En revanche, cela a très peu d'impact lorsque l'on utilise classifieur SVM. Cette différence s'explique en partie par le fait que le critère d'optimisation est basé sur la classifieur RF, mais aussi par la nature de ces classifieurs. En effet, ainsi qu'on l'a expliqué dans la section 3.1 et en particulier en 3.1.7, le classifieur SVM revient à définir automatiquement, pour chaque paire de classes, un indice calculé à partir des bandes originales et un seuil sur cet indice permettant de séparer au mieux ces classes. En revanche, le classifieur RF va modéliser les frontières entre classes de manière plus grossière, par différents seuils sur les bandes originales; aussi il aboutit à de meilleurs résultats lorsqu'on lui fournit des indices permettant de mieux distinguer les classes.

	RF		SVM	
	bandes originales	indices	bandes originales	indices
<i>Corn-mintill</i>	54,7	61,2	67,2	67,4
<i>Corn-notill</i>	57,9	68,7	69,9	70,3
<i>Grass-pasture</i>	82,2	84,4	86,7	86,6
<i>Grass-trees</i>	92,3	92,5	94,9	94,9
<i>Hay-windrowed</i>	94,9	98,2	99,0	99,5
<i>Soybean-clean</i>	49,3	63,0	74,0	73,6
<i>Soybean-mintill</i>	61,4	64,3	69,4	69,1
<i>Soybean-notill</i>	60,3	67,2	72,4	73,0
<i>Woods</i>	95,6	95,9	97,4	96,9
F-score moyennes	72,1	77,3	81,2	81,3
F-score minimum	48,8	60,3	66,2	66,0
OA	69,0	74,2	78,1	78,1
Kappa	64,2	70,2	74,6	74,6

TABLE 6.7 – Résultats obtenus pour les classifieurs RF et SVM avec noyau gaussien sur le jeu de données Indian Pines, selon que l'on utilise un jeu de 10 bandes originales ou un jeu de 10 indices. Les F-scores (en %) associés aux différentes classes sont présentés, ainsi que des indicateurs plus globaux (OA, Kappa).

	RF		SVM	
	bandes originales	indices	bandes originales	indices
<i>Asphalt</i>	86,1	91,9	91,0	92,2
<i>Bare soil</i>	82,3	89,2	91,1	90,2
<i>Bitumen</i>	84,9	89,2	87,7	89,8
<i>Meadows</i>	79,0	81,9	82,1	82,6
<i>Self-blocking bricks</i>	64,7	72,1	68,5	69,3
<i>Shadows</i>	99,2	98,3	99,9	96,7
<i>Tiles</i>	95,9	98,7	98,6	98,5
<i>Trees</i>	90,9	92,6	92,2	92,3
<i>Water</i>	99,7	99,7	99,7	99,6
F-score moyen	87,0	90,4	90,1	90,1
F-score minimum	64,7	71,9	68,4	69,2
OA	94,5	96,5	96,4	96,4
Kappa	92,2	95,1	95,0	95,0

TABLE 6.8 – Résultats obtenus pour les classifieurs RF et SVM avec noyau gaussien sur le jeu de données Pavie, selon que l'on utilise un jeu de 7 bandes originales ou un jeu de 7 indices. Les F-scores (en %) associés aux différentes classes sont présentés, ainsi que des indicateurs plus globaux (OA, Kappa).

Il est dans ce cas également possible de dériver de ce processus d'optimisation des profils d'importance des bandes originales. On constate (voir figure 6.18) que ces profils peuvent être différents de ceux obtenus lorsque l'on appliquait directement le score de sélection au jeu de bandes originales. Ils ont aussi avoir tendance à être un peu plus bruités que ceux obtenus lorsque l'on utilisait directement les bandes originales. Cela peut s'expliquer par le fait que pour un jeu de bandes sélectionnées, toutes ne vont pas être forcément prises en compte dans le même nombre d'indices dérivés. Aussi, certaines bandes un peu moins importantes pourront avoir été sélectionnées dans certaines configurations où elles ont en fait très peu d'influence sur la qualité du résultat. Il faudrait ajouter des contraintes dans ce sens. Il convient donc de nuancer les résultats obtenus, qui ne sont que des résultats préliminaires à une approche qui mériterait d'être creusée davantage.




FIGURE 6.18 – Jeu de données Pavie : profil d'importance de bandes obtenus en appliquant le score *rf.appart* directement à des jeux de 7 bandes originales (à gauche) ou à des jeux de 7 indices dérivés des 7 bandes sélectionnées (à droite)



## Chapitre 7

# Sélection de bandes fusionnées

### 7.1 Regroupement de bandes et fusion de bandes

Dans le cas de la donnée hyperspectrale, les bandes adjacentes sont le plus souvent fortement corrélées. De ce fait, l'optimisation d'un jeu de bandes spectrales peut aller plus loin qu'une simple sélection des bandes originales du jeu de données hyperspectrales et consister en sélection de bandes fusionnées, c'est-à-dire en la définition d'un jeu optimal de bandes spectrales dont à la fois la position le long du spectre et la largeur ont été optimisées. On se trouve alors à la frontière entre sélection de bandes et extraction de caractéristiques. On parlera donc de sélection ou d'extraction de bandes fusionnées.

L'intérêt de disposer de bandes larges est que celles-ci permettent de réduire le bruit.

Par rapport à la sélection de bandes individuelles, la fusion de bandes spectrales est un problème qui semble avoir été moins abordé dans la littérature, alors qu'il est directement lié à la conception de capteurs multispectraux. Le problème de sélection de bandes fusionnées rejoint aussi celui de la clusterisation, du regroupement des bandes corrélées d'un jeu de données hyperspectrales.

#### 7.1.1 Regroupement et clusterisation de bandes

La clusterisation ou le regroupement de bandes est parfois mis en œuvre conjointement avec une méthode de sélection de bandes individuelles. (Dans la littérature, on parle plutôt de regroupement pour les approches visant à obtenir des groupes de bandes adjacentes, et de clusterisation lorsque l'on s'efforce de rassembler des bandes ayant un même comportement sans tenir compte de leur position le long du spectre.) Par exemple, [Li *et al.* 2011] regroupent d'abord les bandes adjacentes corrélées au sens de leur information mutuelle conditionnelle. La sélection de bandes est ensuite effectuée, avec la contrainte qu'une seule bande soit sélectionnée par cluster. [Martínez-Usó *et al.* 2007, Jia *et al.* 2012] commencent par rassembler les attributs "corrélés" puis sélectionnent l'attribut le plus représentatif (au sens de l'information mutuelle pour [Martínez-Usó *et al.* 2007]) de chaque cluster. [Chang *et al.* 2011] effectuent une clusterisation des bandes spectrales sur la base d'un critère plus global basé sur la corrélation entre bandes et prenant expressément en compte l'existence de plusieurs classes. On optimise alors au moyen d'un algorithme de recuit simulé une fonction de coût définie comme la somme sur tous les clusters et sur toutes les classes de la somme des coefficients de corrélations entre bandes appartenant à un même cluster.

[Su *et al.* 2011] effectue une clusterisation des différentes bandes en appliquant l'algorithme des k-moyennes (k-means) à la matrice de corrélation des bandes. Ensuite, les clusters les moins homogènes et les bandes trop différentes de la bande représentante du cluster auxquelles elles appartiennent sont progressivement éliminées.

[Bigdeli *et al.* 2013, Prasad et Bruce 2008] effectuent également une clusterisation des différentes

bandes, mais, à l'inverse des méthodes précédentes, l'utilise ensuite au sein d'un classifieur SVM multiple : un classifieur SVM est entraîné pour chaque cluster (c'est-à-dire sur les différentes bandes appartenant à ce cluster). Les résultats fournis par ces classifieurs sont ensuite fusionnés. Dans cette optique, [Bigdeli *et al.* 2013] a comparé plusieurs méthodes de clusterisation ou de regroupement de bandes, incluant notamment les k-moyennes appliquées à la matrice de corrélation ou une approche utilisant les minima locaux de l'information mutuelle entre bandes adjacentes comme limite entre clusters.

[Prasad et Bruce 2008] a proposé une autre stratégie pour le regroupement de bandes : on part de la première bande du spectre et l'on ajoute progressivement au cluster les bandes adjacentes jusqu'à ce qu'un critère d'arrêt basé sur l'information mutuelle soit atteint.

Les différentes approches qui viennent d'être présentées ont pour point commun de s'efforcer de regrouper les bandes les plus semblables au sens du coefficient de corrélation ou de l'information mutuelle. Les approches sont généralement de deux types :

- celles qui appliquent l'algorithme des k-moyennes, ou un autre algorithme de partitionnement à la matrice de corrélation
- celles qui définissent les limites entre groupes de bandes comme les minima locaux de l'information mutuelle ou de la corrélation entre bandes adjacentes

Néanmoins, pour le premier type de méthodes, la manière dont le nombre de clusters (i.e. le paramètre  $k$  des k-moyennes) est choisi est rarement précisé, et sa détermination ne semble pas être automatique. Pour le second type de méthodes, il n'est pas précisé si un lissage est appliqué au profil de corrélation/information mutuelle avant la détermination des minima locaux, afin de limiter le bruit, et le cas échéant, pour quel paramétrage.

### 7.1.2 Fusion de bandes

Quelques approches de regroupement de bandes spécifiques à l'extraction de bandes fusionnées ont été proposées pour l'optimisation spectrale.

[De Backer *et al.* 2005] définissent les bandes spectrales par des fenêtres gaussiennes le long du spectre et proposent d'extraire les bandes de manière à optimiser un critère de séparabilité entre classes basé sur la mesure de Bhattacharyya (*Bhattacharyya error bound*) au moyen d'un algorithme de recuit simulé. [Serpico et Moser 2007] proposent une adaptation de l'algorithme Steepest Ascent pour le problème de sélection de bandes fusionnées. Le critère optimisé est alors la mesure de séparabilité de Jeffries-Matusita. [Minet *et al.* 2010] met en œuvre un algorithme génétique (avec des individus correspondant à des bandes larges) pour définir les bandes spectrales les plus appropriées à la détection de cibles.

Ces méthodes sont intéressantes dans le sens où elles visent directement à extraire des jeux de bandes optimaux au sens d'un critère de sélection d'attributs. Par ailleurs, elles ne prennent en compte que ce critère, et ne tiennent donc pas compte des similarités/corrélations entre bandes. De ce fait, la combinatoire de ces méthodes est importante et il est dommage de ne pas intégrer ce type d'information afin de guider la recherche de la solution en excluant les plus irréalistes (i.e. celles qui fusionneraient des bandes très différentes). Dans ce sens, un critère prenant en compte la corrélation entre les bandes et la mesure de séparabilité de Fisher est proposé par [Kumar *et al.* 2001].

A l'inverse, [Cariou *et al.* 2011] fusionnent les bandes de manière non supervisée selon un critère basé sur l'information mutuelle, afin d'obtenir la configuration optimale au sens de ce critère. Un processus de regroupement de bandes peut également se servir de la méthode de [Jensen et Solberg 2007] pour décomposer les spectres de références de différentes classes en fonctions

constantes par morceaux. [Jensen et Solberg 2007] fusionnent en effet les bandes adjacentes de manière à décomposer des spectres de référence de différentes classes en fonctions constantes par morceaux ; le critère d'arrêt est un seuil sur l'erreur de reconstruction des spectres originaux. [Wiersma et Landgrebe 1980] s'intéressent aussi à l'erreur de reconstruction mais dans le but de définir des jeux de bandes optimaux selon un modèle analytique prenant en compte les erreurs de reconstruction du spectre ; il s'agit donc cette fois à nouveau d'un problème de sélection de bandes fusionnées, mais pour un critère non supervisé. En revanche, les deux premières approches, à savoir celles de [Cariou *et al.* 2011] et [Jensen et Solberg 2007], visent à partitionner le spectre en un ensemble de bandes larges, fournissant ainsi des configurations spectrales couvrant l'intégralité du spectre et composées de bandes de largeur variable. Par contre, aucune sélection d'un jeu optimal de bandes pour la classification n'est faite parmi les bandes de cette configuration.

Enfin, certaines études s'intéressent aussi à l'impact de la résolution spectrale sur les résultats d'une classification, sans forcément optimiser de bandes [Adeline *et al.* 2014], ou comme pour définir une résolution spectrale adaptée avant un processus de sélection de bandes [Tavin 2008, Minghelli-Roman 2010]. La limite de ces approches est que l'information n'est pas nécessairement répartie de manière uniforme le long du spectre. (A titre d'exemple, le spectre d'un matériau peut rester constant sur un domaine spectral assez étendu, mais présenter à un autre endroit un comportement beaucoup plus localisé, correspondant par exemple à des bandes d'absorption. Une résolution spectrale grossière risquera de faire disparaître ce comportement caractéristique, tandis qu'une résolution fine ne permettra pas de fusionner les bandes adjacentes présentant un même comportement alors que le fait de toutes les conserver n'apporte pas d'information utile.)

### 7.1.3 Approche proposée

Il apparaît donc intéressant pour un processus d'extraction d'un jeu de bandes larges optimal pour un problème de classification de prendre en compte le critère de sélection de bandes que l'on souhaite optimiser, mais aussi de tenir compte des similarités/corrélation entre bandes adjacentes, afin de garantir que les bandes fusionnées obtenues conservent un sens de ce point de vue. Une solution serait donc de commencer par partitionner le spectre en un ensemble de bandes larges, c'est-à-dire d'obtenir une configuration spectrale couvrant l'intégralité du spectre et composée de bandes de largeur variable, puis de lui appliquer le processus de sélection d'attributs. Toutefois, la plupart des approches de partitionnement du spectre ou de regroupement de bandes rencontrées nécessitent de fixer certains paramètres (seuil, nombre de groupes de bandes, erreur de reconstruction, ...).

L'approche proposée ici consiste à générer une hiérarchie de groupes de bandes adjacentes, qui sont alors fusionnées. Au sein de cette hiérarchie, les bandes sont progressivement rassemblées selon un critère de fusion en groupes de largeur croissante. Chaque niveau de cette hiérarchie correspond donc à une configuration spectrale couvrant l'intégralité du spectre et composée de bandes de largeur variable. Une sélection de bandes fusionnées est ensuite appliquée à chacun des niveaux de cette hiérarchie, permettant ainsi d'explorer différentes configurations spectrales possibles. Deux approches sont proposées pour effectuer cette sélection de bandes, en prenant en compte la hiérarchie.

Ainsi, on propose d'utiliser cette hiérarchie de bandes fusionnées comme une contrainte pour l'extraction de bandes (on les force à avoir une signification au sens du critère de fusion utilisé) et une manière de limiter la combinatoire, à la différence de certaines approches existantes comme [Serpico et Moser 2007] qui extrait un jeu de bandes optimal au sens d'une distance de JM à l'aide d'un algorithme d'optimisation adapté ou de [Minet *et al.* 2010] qui utilise directement un algorithme génétique pour optimiser un score de type *wrapper*.

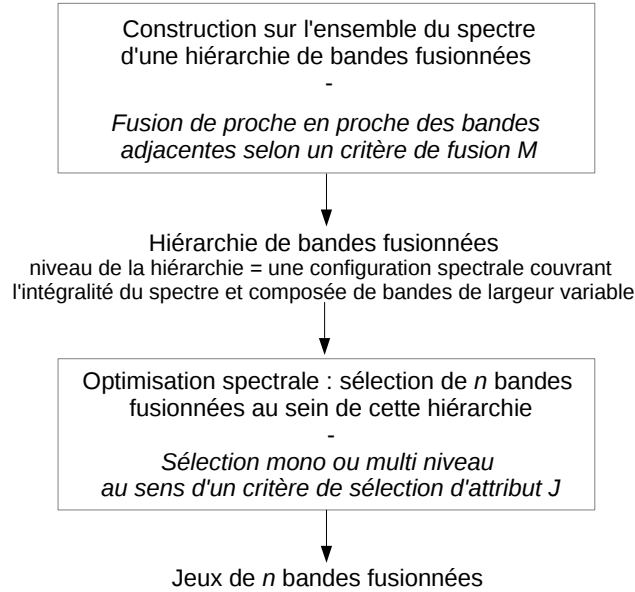


FIGURE 7.1 – Méthode mise en œuvre pour la sélection de bandes fusionnées.

## 7.2 Fusion hiérarchique de bandes

La première étape de l'approche proposée consiste à construire une hiérarchie de groupes de bandes adjacentes, qui sont alors fusionnées. Même s'il s'agit ici de l'utiliser à des fins de sélection/extraction d'un nombre limité de bandes, une telle hiérarchie de bandes fusionnées est aussi une manière d'explorer des configurations spectrales couvrant l'intégralité du spectre et composées de bandes contiguës et de largeurs variables le long du spectre.

### 7.2.1 Algorithme de fusion hiérarchique de bandes

**Notations** Soit  $B = \{\lambda_i\}_{0 \leq i \leq nb\_bandes}$  le jeu original (ordonné) de bandes. Soit  $H = \{H^{(i)}\}_{0 \leq i < nlevels}$  la hiérarchie de bandes fusionnées.  $H^{(i)} = \{H_j^{(i)}\}_{1 \leq j \leq n_i}$  est le  $i$ ème niveau de cette hiérarchie de bandes fusionnées. Il est composé de  $n_i$  bandes fusionnées, c'est-à-dire de  $n_i$  groupes ordonnés de bandes adjacentes de  $B$ . Ainsi, chaque  $H_j^{(i)}$  est défini comme un domaine spectral :  $H_j^{(i)} = [H_j^{(i)}.\lambda_{min}; H_j^{(i)}.\lambda_{max}]$ .

Aussi, la fusion de deux bandes fusionnées adjacentes  $B_1$  et  $B_2$  de ce type donne une nouvelle bande fusionnée  $B_1 \oplus B_2 = [B_1.\lambda_{min}; B_2.\lambda_{max}]$  avec  $B_1.\lambda_{max} = B_2.\lambda_{min}$

Soit  $M()$  le score que l'on va optimiser au cours du processus de construction de la hiérarchie de bandes fusionnées.

L'algorithme proposé pour la fusion hiérarchique de bandes est une approche ascendante ou *bottom-up*. (Remarque : Une approche descendante a aussi été testée, et donne des résultats similaires.) Il est décrit ci-dessous :

**Initialisation** :  $H^{(0)} = B$  (c'est-à-dire que les bandes "fusionnées" du premier niveau de la hiérarchie ne contiennent en réalité qu'une seule bande individuelle originale).

**Fusion de bandes : création du niveau  $l+1$  à partir du niveau  $l$  :**

Trouver la paire de bandes adjacentes au niveau  $l$  qui va optimiser le score  $M$  dans le cas de leur fusion : trouver  $\hat{k} = \operatorname{argmin}_k M(T(H^{(l)}, k))$

$$\text{avec } T(H^{(l)}, k) = [H_0^{(l)}; \dots; H_{k-1}^{(l)}; H_k^{(l)} \oplus H_{k+1}^{(l)}; H_{k+2}^{(l)}; \dots; H_{n_l}^{(l)}]$$

Ensuite,  $H^{(l+1)} = T(H^{(l)}, \hat{k})$

Une table  $L_l^{l+1}$  est créée afin de faire le lien entre les bandes fusionnées et les différents niveaux de la hiérarchie :

pour  $1 \leq j \leq i$ ,  $L_l^{l+1}(H_j^{(l)}) = H_j^{(l+1)}$

$L_l^{l+1}(H_i^{(l)}) = H_i^{(l+1)}$

$L_l^{l+1}(H_i^{(l)} + 1) = H_i^{(l+1)}$

pour  $i + 2 \leq j \leq n_l$ ,  $L_l^{l+1}(H_j^{(l)}) = H_{j-1}^{(l+1)}$

## 7.2.2 Critères pour la fusion de bandes

Plusieurs critères d'optimisation  $M$  pour la fusion hiérarchique des bandes ont été considérés. (Dans l'algorithme précédent, on considère que ce score doit être minimisé.) Ces critères sont supervisés ou non, selon que la notion de classes a été prise en compte ou pas.

### Corrélation entre bandes

**Un critère possible va être de considérer que des bandes adjacentes sont à fusionner si elles sont fortement corrélées.**

La "corrélacion" entre bandes (mesurée soit par le coefficient de corrélacion normalisé classique, soit par l'information mutuelle) (voir figure 7.2) mesure la degré de dépendance entre des bandes. Par conséquent, un premier critère de fusion peut viser à fusionner des bandes adjacentes en considérant le degré auquel elles sont corrélées. Ainsi, un tel critère s'efforce d'obtenir des groupes cohérents de bandes adjacentes "fortement" corrélées.

Une telle mesure inspirée de [Chang *et al.* 2011] est définie par la fonction suivante (que l'on cherchera à minimiser) :

$$M(H^{(l)}) = \sum_{i=1}^{n_l} \sum_{b_1=H_i^{(l)}. \lambda_{min}}^{H_i^{(l)}. \lambda_{max}} \sum_{b_2=H_i^{(l)}. \lambda_{min}}^{H_i^{(l)}. \lambda_{max}} (1 - c(b_1, b_2))$$

avec  $c(b_1, b_2)$  désignant le score de corrélacion entre les bandes  $b_1$  et  $b_2$ .



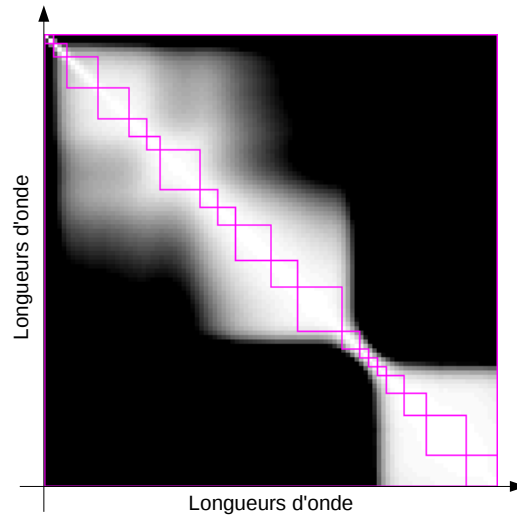


FIGURE 7.2 – Exemples de groupes de bandes en surimpression d’une matrice de corrélation entre bandes (pour le jeu de données Pavie). (Plus l’image est claire et plus les bandes sont corrélées.)

### Erreur d’approximation du spectre

**On va souhaiter fusionner progressivement les bandes de manière à conserver au mieux la forme des spectres.**

La fusion des bandes se fait alors sur la base de la méthode proposée par [Jensen et Solberg 2007] pour décomposer des spectres de références des différentes classes en fonctions constantes par morceaux (fig. 7.3).

Les bandes adjacentes sont alors fusionnées de manière à minimiser l’erreur entre le spectre original et le spectre reconstruit par cette fonction constante par morceaux.

Une telle mesure est définie par la fonction suivante pour un ensemble  $\{s_j\}_{1 \leq j \leq n_s}$  de  $n_s$  spectres :

$$M(H^{(l)}) = \sum_{j=1}^{n_s} \sum_{i=1}^{n_l} \sum_{b=H_i^{(l)}. \lambda_{min}}^{H_i^{(l)}. \lambda_{max}} |s_j(b) - moy(s_j, H_i^{(l)})|$$

où  $moy(s_j, H_i^{(l)})$  représente la valeur moyenne du spectre  $s_j$  sur un intervalle spectral  $H_i^{(l)}$




FIGURE 7.3 – Illustration du principe du critère de fusion de bandes basé sur l’erreur d’approximation du spectre. A gauche, exemples de bandes fusionnées en surimpression des spectres originaux : les lignes noires verticales sont les limites entre bandes fusionnées. A droite, reconstruction des spectres par des fonctions constantes par morceaux pour ce jeu de bandes fusionnées (jeu test Pavie)

### Séparabilité

Un autre critère de fusion de bandes adjacentes est leur **contribution à la séparabilité entre les classes**. Des mesures de séparabilité possibles sont la distance de Bhattacharrya ou celle de Jeffries-Matusita  $JM$  [Bruzzone et Serpico 2000, Serpico et Moser 2007], qui ont déjà été définies plus haut.

A un niveau de la hiérarchie, les 2 bandes adjacentes à fusionner seront donc celles dont la fusion permet d’obtenir le jeu de bandes fusionnées qui maximise la séparabilité entre classes. Si l’on utilise la distance de Jeffries-Matusita comme mesure de séparabilité, le critère  $M$  (à minimiser) de fusion de bandes est donc défini par

$$M(H^{(l)}) = -JM(H^{(l)})$$

### 7.2.3 Résultats

La figure 7.4 présente des exemples de hiérarchies de bandes fusionnées obtenues pour le jeu test Pavie pour les 3 critères de fusion décrits précédemment. Le critère basé sur la séparabilité a tendance à fournir un résultat sensiblement différent de ceux obtenus pour les deux autres critères. On peut constater que les différents critères ne considèrent pas les mêmes parties du spectre comme devant être conservées à des résolutions fines. Ainsi, les critères “corrélacion” ou “erreur de reconstruction du spectre” ont tendance à facilement fusionner les bandes dont les numéros vont de 30 à 32, tandis que le critère “séparabilité” tend au contraire à les conserver à une résolution fine. A l’inverse, ce critère regroupe facilement certaines bandes du domaine red-edge, tandis que les autres critères conservent une résolution fine dans cette partie du spectre. Ceci peut s’expliquer en considérant le fonctionnement de ces critères. En effet, les résultats obtenus pour les critères “corrélacion” ou “erreur de reconstruction du spectre” s’expliquent pour le premier par le fait que les bandes adjacentes sont peu corrélées entre elles dans ce domaine spectral, et pour le second par le fait que la pente des spectres des classes de végétation

est importante. À l'inverse, l'information intéressante du point de vue de la classification (et donc de la séparabilité) ne se trouve pas dans la description précise de ce domaine spectral, mais dans le fait qu'il y ait une pente à ce niveau, et donc plutôt dans la connaissance des valeurs des bandes situées de part et d'autre de ce domaine.

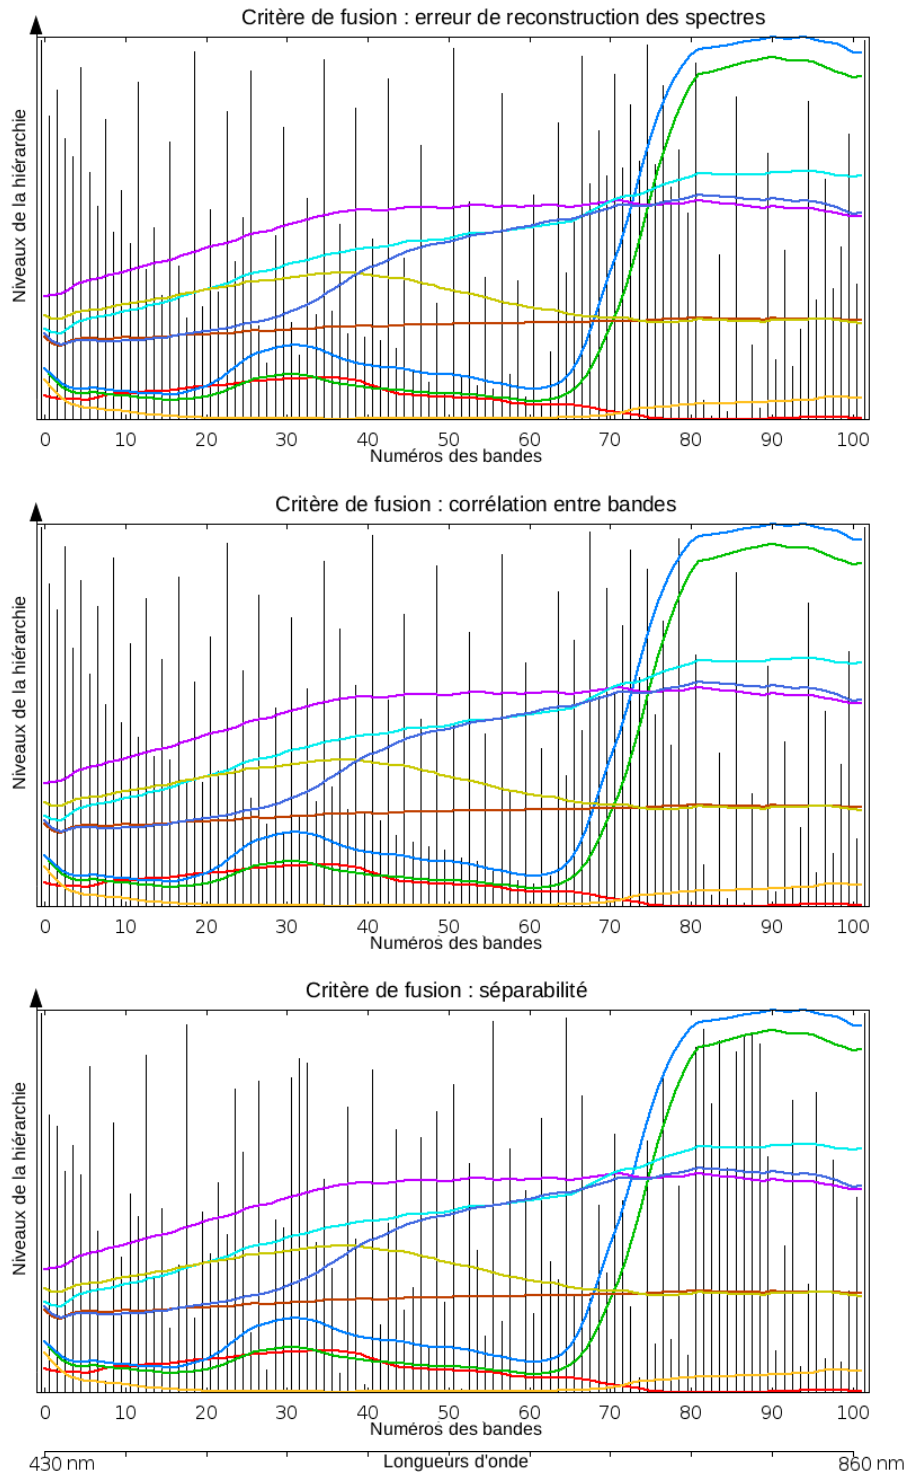


FIGURE 7.4 – Hiérarchies de bandes fusionnées obtenues pour différents critères sur le jeu de données Pavie : “erreur de reconstruction du spectre” (en haut), “corrélation entre bandes” (au milieu), “séparabilité” (en bas). L’abscisse correspond aux numéros/longueur d’onde des bandes. L’axe des ordonnées correspond aux niveaux dans la hiérarchie de bandes fusionnées (en bas : niveau le plus fin avec les bandes originales, en haut : une bande fusionnée unique). Les lignes noires verticales sont les limites entre bandes fusionnées : plus on monte dans la hiérarchie, plus le nombre de bandes fusionnées diminue. Les spectres médians des classes en présence sont affichés en couleur.

Les hiérarchies de bandes fusionnées sont aussi un moyen de visiter des partitions du spectre en différentes configurations spectrales de bandes contiguës de largeur variable. Ces configurations spectrales correspondant aux différents niveaux de la hiérarchie ont donc été évaluées au sens d'un taux de bonne classification. Ainsi, pour chaque niveau de la hiérarchie, on a calculé une classification par un classifieur SVM 1-contre-1 avec noyau gaussien optimisé. Cette classification a été évaluée : sa qualité a été quantifiée par le coefficient Kappa.

La figure 7.5 présente les résultats de ces évaluations pour les différents critères de fusion et les différents jeux de données. On peut voir que certaines configurations spectrales permettent d'obtenir de meilleurs résultats qu'à la résolution spectrale originale. Les configurations spectrales obtenues en utilisant le coefficient de corrélation sont généralement moins bonnes que celles obtenues pour les 2 autres critères. Excepté pour Pavie, le critère "erreur de reconstruction du spectre" a tendance à donner les meilleurs résultats. Néanmoins, pour Pavie, les valeurs atteintes par le coefficient Kappa restent très similaires pour les différents critères de fusion proposés.

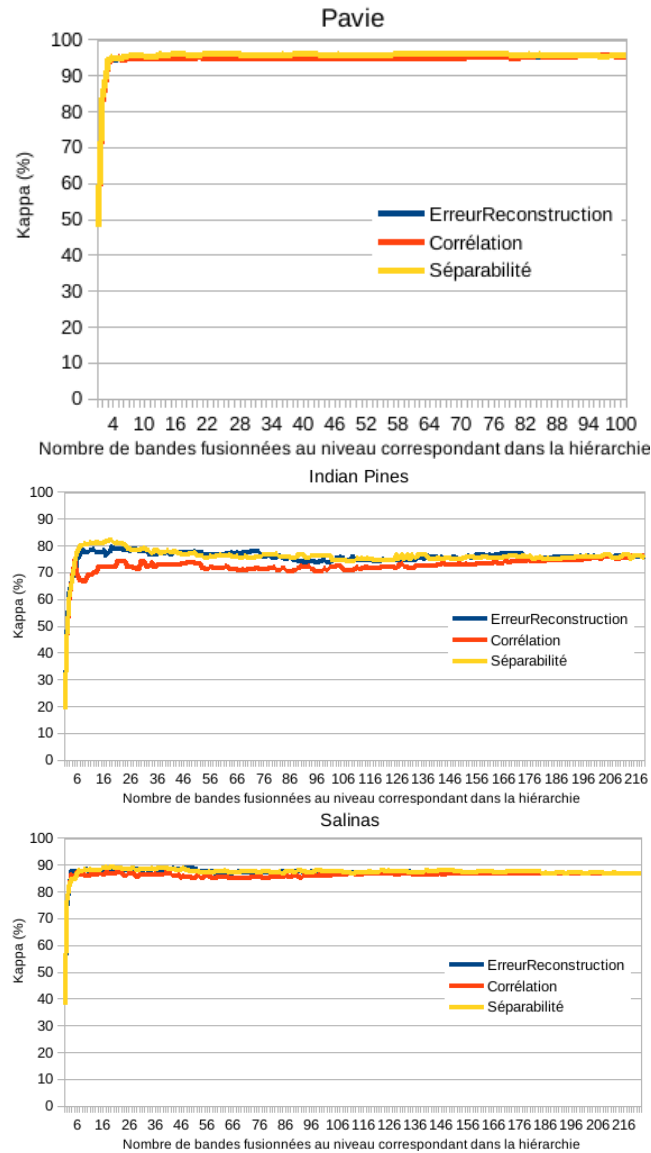


FIGURE 7.5 – Kappa obtenus par un classifieur SVM gaussien pour les différentes configurations spectrales de la hiérarchie de bandes fusionnées (abscisse = nombre de bandes fusionnées dans la configuration spectrale), pour Pavie (haut), Indian Pines (milieu) et Salinas (bas).

### 7.3 Sélection mono-niveau de bandes par une méthode gloutonne

Une approche gloutonne a d’abord été mise en œuvre afin de réaliser l’optimisation spectrale en sélectionnant un nombre limité de bandes : cela a consisté à effectuer une sélection d’un jeu de bandes (fusionnées) à chacun des différents niveaux de la hiérarchie de bandes fusionnées, sans tenir compte des résultats obtenus aux niveaux précédents et suivants. Ainsi, on a extrait un jeu optimal de  $p$  bandes à chaque niveau de la hiérarchie, ce nombre de bandes  $p$  étant le même à tous les niveaux de la hiérarchie.

Dans les expériences qui suivent, cette sélection de bandes a été effectuée en optimisant la mesure de séparabilité de Jeffries-Matusita à chaque niveau de la hiérarchie à l’aide de l’algorithme d’optimisation Sequential Forward Floating Search (SFFS) [Pudil *et al.* 1994] décrit plus haut.

### 7.3.1 Résultats

La figure 7.6 montre les résultats obtenus sur le jeu de données Pavie : 5 bandes fusionnées ont été sélectionnées à chaque niveau des différentes hiérarchies de bandes fusionnées. On peut voir que les positions des bandes fusionnées sélectionnées varient peu au fur et à mesure que l'on se déplace dans la hiérarchie, excepté lorsque l'on atteint les résolutions spectrales les plus grossières. On peut aussi remarquer qu'il arrive qu'à certains niveaux de la hiérarchie, la position d'une bande sélectionnée se déplace le long du spectre puis revienne à sa position originale lorsque l'on se déplace dans la hiérarchie. Aussi, il est possible d'utiliser le jeu de bandes sélectionnées à un niveau  $l$  de la hiérarchie pour initialiser l'algorithme au niveau suivant  $l + 1$ . Cet algorithme modifié va être présenté et mis en œuvre dans la section 7.5.

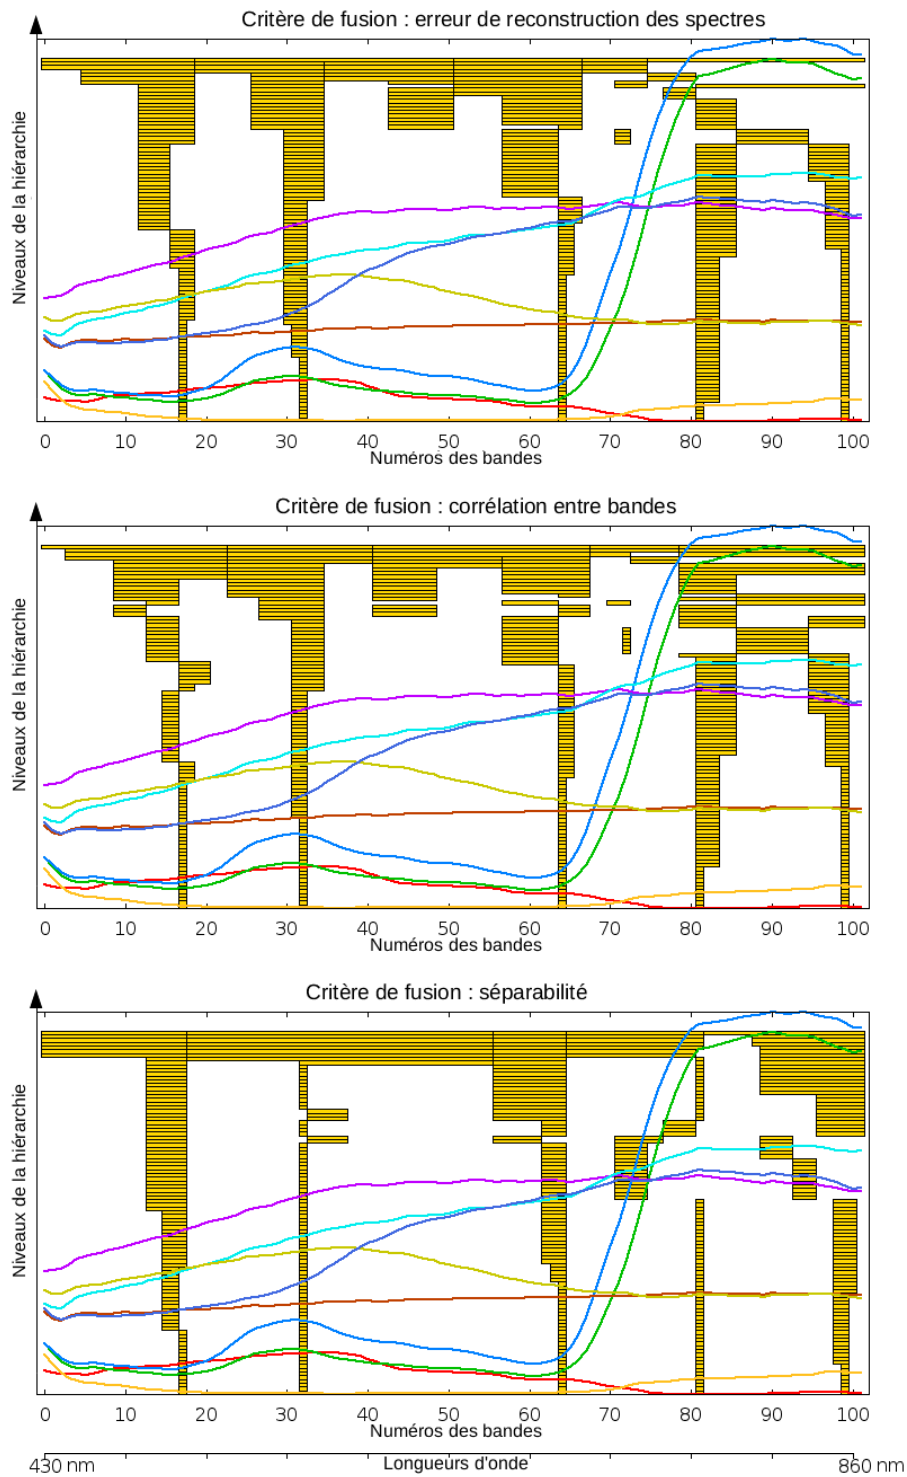


FIGURE 7.6 – Jeu de données Pavie : bandes sélectionnées aux différents niveaux de la hiérarchie en utilisant l’approche SFFS gloutonne, pour des hiérarchies de bandes fusionnées calculées pour différents critères de fusion : “erreur de reconstruction du spectre” (en haut), “corrélation entre bandes” (au milieu), “séparabilité” (en bas). L’abscisse correspond aux numéros/longueur d’onde des bandes. L’axe des ordonnées correspond aux niveaux dans la hiérarchie de bandes fusionnées (en bas : niveau le plus fin avec les bandes originales, en haut : une bande fusionnée unique)



Les jeux de bandes fusionnées sélectionnées aux différents niveaux de la hiérarchie ont été évalués par le biais d'un taux de bonne classification. Tout comme dans la section précédente, le coefficient Kappa obtenu par un classifieur SVM à noyau gaussien utilisant les bandes sélectionnées a été calculé. La figure 7.7 présente ces résultats obtenus pour le jeu de données Pavia. On peut constater que ces valeurs de Kappa restent très proches quel que soit le critère de fusion de bandes utilisé. Aucun critère de fusion n'a réellement tendance à être meilleur que les autres à ce niveau.

Les résultats obtenus lorsque l'on utilise des bandes fusionnées sont généralement meilleurs qu'en utilisant les bandes originales. Cette tendance s'observe en effet sur les deux courbes de la figure 7.7, et de manière un peu prononcée dans le cas d'Indian Pines. La performance de classification tend à augmenter au fur et à mesure que l'on s'élève dans la hiérarchie de bandes fusionnées et donc que l'on utilise des bandes plus larges, ce qui plaide en faveur d'un capteur superspectral et peut aussi s'expliquer par le fait que travailler avec des bandes un peu plus larges que les bandes originales permet de réduire le bruit. La performance de classification diminue ensuite assez rapidement dès l'on atteint des niveaux où les bandes sont devenues vraiment trop larges, "effaçant" les comportements du spectre les plus utiles pour la classification.




FIGURE 7.7 – Valeurs de Kappa obtenues par un classifieur SVM gaussien pour les jeux de bandes sélectionnés aux différents niveaux de la hiérarchie pour le jeu de données Pavia, en utilisant l'approche SFSS gloutonne (abscisse = nombre de bandes fusionnées initiales)

## 7.4 Sélection mono-niveau de bandes prenant en compte la hiérarchie de bandes fusionnées

### 7.4.1 Algorithme

On souhaite toujours sélectionner un jeu de  $p$  bandes à chaque niveau de la hiérarchie, ce nombre de bandes  $p$  étant le même à tous les niveaux de la hiérarchie. La méthode de sélection de bandes mise en œuvre dans la section précédente est gloutonne et très coûteuse en temps de calcul. Aussi, une adaptation de l’heuristique d’optimisation SFFS a été proposée de manière à prendre en compte la hiérarchie de bandes fusionnées directement dans le processus d’optimisation, et non plus à effectuer l’optimisation à chacun de ses niveaux indépendamment les uns des autres. Tout comme pour l’algorithme de construction de la hiérarchie de bandes fusionnées, une approche ascendante a été adoptée. Contrairement à l’approche gloutonne précédente, cet algorithme utilise le jeu de bandes sélectionnées au niveau précédent de la hiérarchie au moment de réaliser la sélection à un nouveau niveau.

Cet algorithme est décrit ci-dessous :

Soit  $S^{(l)} = \{S_i^{(l)}\}_{1 \leq i \leq p}$  le jeu de bandes fusionnées sélectionnées au niveau  $l$  de la hiérarchie. Le même nombre  $p$  de bandes est bien entendu sélectionné à chaque niveau de la hiérarchie.

**Initialisation :** l’algorithme standard SFFS de sélection de bandes est appliqué au niveau  $H^{(0)}$  de base de la hiérarchie

**Itérations sur les niveaux de la hiérarchie :**

Générer  $S^{(l+1)}$  à partir  $S^{(l)}$  :

$$S^{(l+1)} \leftarrow \{L_l^{l+1}(S_i^{(l)})\}_{1 \leq i \leq p}$$

Supprimer les doublons possibles de  $S^{(l+1)}$

**si**  $\#S^{(l+1)} < p$ ,

trouver  $s = \operatorname{argmax}_{b \in H^{(l+1)} \setminus S^{(l+1)}} J(S^{(l+1)} \cup b)$

$$S^{(l+1)} \leftarrow \{S^{(l+1)}; s\}$$

**fin**

Remettre en question  $S^{(l+1)}$  : trouver la bande  $s \in S^{(l+1)}$  telle que  $S^{(l+1)} \setminus \{s\}$  maximise le score de sélection d’attributs (ici la distance JM), i.e.  $s = \operatorname{argmax}_{z \in S^{(l+1)}} JM(S^{(l+1)} \setminus \{z\})$ .

$$S^{(l+1)} \leftarrow S^{(l+1)} \setminus s$$

Appliquer ensuite l’algorithme SFFS standard tant que  $\#S^{(l+1)} = p$ .

### 7.4.2 Résultats

Les résultats obtenus pour le jeu de données Pavia pour le critère de fusion “erreur de reconstruction du spectre” sont présentés sur la figure 7.8 : 5 bandes fusionnées ont été sélectionnées à chaque niveau de la hiérarchie, en partant d’une solution initiale obtenue au niveau le plus bas de la hiérarchie. Comme pour les expériences précédentes, les résultats obtenus ont été évalués quantitativement en considérant le Kappa obtenu pour des classifications réalisées par un classifieur SVM gaussien utilisant les bandes sélectionnées. Ces résultats (obtenus pour une hiérarchie de bandes fusionnées construite pour le critère de fusion “erreur de reconstruction du spectre”) sont présentés sur la figure 7.9 à la fois pour la version gloutonne et la version proposée de l’algorithme de sélection. Ces résultats restent très proches. Le tableau 7.1 illustre le fait que les deux algorithmes de sélection de bandes fusionnées conduisent à des résultats équivalents en terme de qualité de classification tandis que la version prenant directement en compte la hiérarchie est nettement plus rapide que l’approche gloutonne.

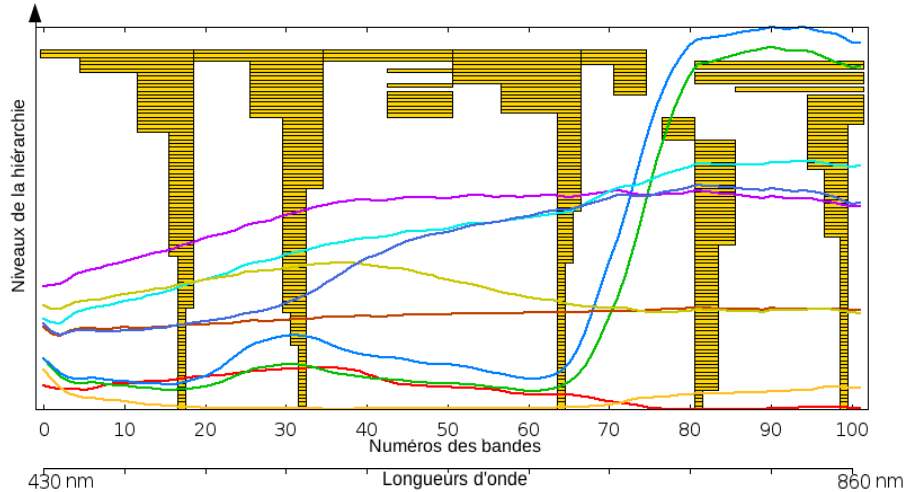


FIGURE 7.8 – Jeu de données Pavie : bandes sélectionnées aux différents niveaux d’une hiérarchie (construite selon le critère de fusion “erreur de reconstruction du spectre”) en utilisant l’approche hiérarchique proposée

	Bandes originales	Bandes fusionnées	
		SFFS glouton	SFFS adapté
Pavie (5 bandes)			
Kappa (%)	95,1	95,5	95,4
Temps de calcul	2 min	1 h 10 min	9 min
Indian Pines (10 bandes)			
Kappa (%)	77,7	81,4	81,2
Temps de calcul	4 min	7 h	40 min

TABLE 7.1 – Temps de calcul et meilleure valeur de Kappa obtenus pour Pavie (pour un jeu de 5 bandes) et Indian Pines (pour un jeu de 10 bandes) pour une hiérarchie construite selon le critère de fusion “erreur de reconstruction du spectre”

## 7.5 Sélection multi-niveaux de bandes prenant en compte la hiérarchie de bandes fusionnées

Jusqu’à présent, on a effectué une sélection de bandes fusionnées à chacun des niveaux de la hiérarchie. Il est néanmoins tentant de pouvoir sélectionner des bandes à différents niveaux de la hiérarchie. Cette recherche à différents niveaux peut s’effectuer à l’aide d’un algorithme génétique.

Lors de la sélection de jeux de bandes individuelles à l’aide d’un algorithme génétique, les individus que l’on faisait évoluer était simplement des jeux de bandes. Leur chromosome se limitait donc à porter les numéros des bandes correspondantes.

Dans ce nouveau cas où l’on optimise des bandes fusionnées situées à différents niveaux de la hiérarchie, le chromosome d’un individu continue à être composé des bandes qui le constituent, mais chacune de ces bandes y est référencée à la fois par le niveau de la hiérarchie auquel elle se trouve ainsi que son numéro (sa position) au sein de ce niveau de la hiérarchie.

Il est également possible de contraindre l’algorithme à plutôt sélectionner des bandes larges. Pour ce faire, lorsqu’une mutation doit se produire sur le niveau de la hiérarchie auquel se situe

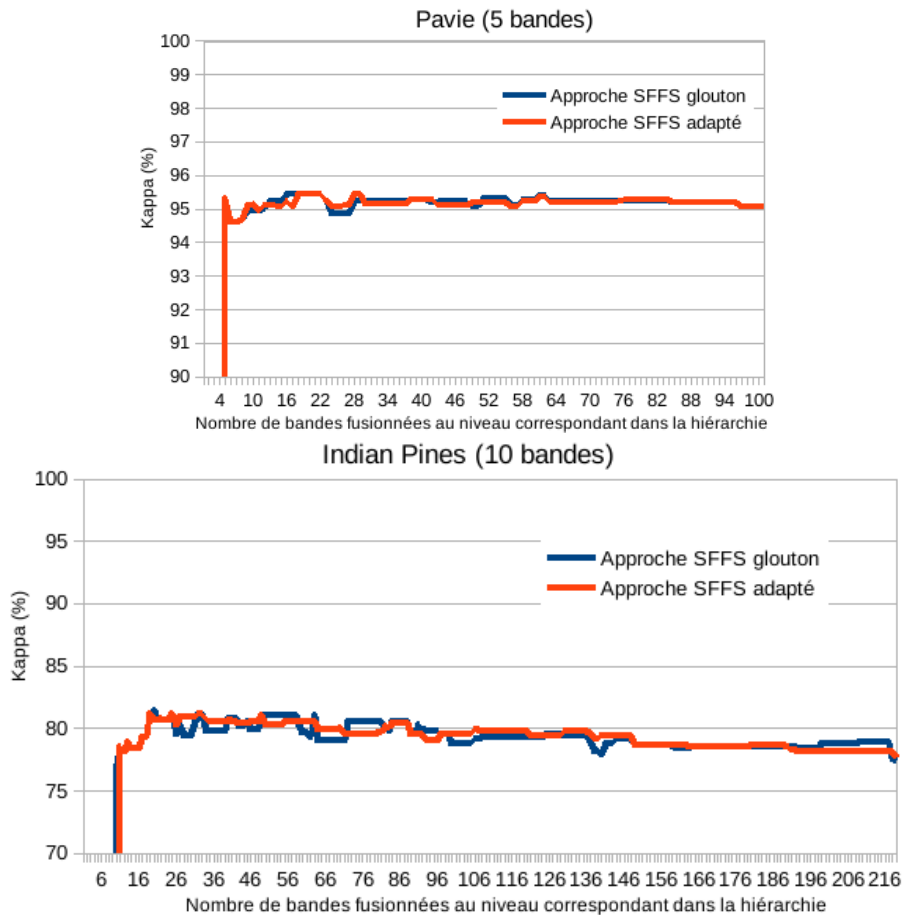


FIGURE 7.9 – Valeurs de Kappa obtenues par un classifieur SVM gaussien pour les jeux de bandes sélectionnés aux différents niveaux d’une hiérarchie (construite selon le critère de fusion “erreur de reconstruction du spectre”) pour le jeu de données Pavie, en utilisant l’approche SFFS gloutonne et l’approche hiérarchique proposée (abscisse = nombre de bandes fusionnées initiales)

une bande, on donne une probabilité plus forte pour que cette mutation se fasse vers le niveau supérieur de la hiérarchie.

Il est également possible d’introduire comme contrainte que les bandes ne se superposent pas.

Un exemple d’application de cette méthode au jeu de données Pavie est présenté sur la figure 7.10. Chaque ligne représente une solution proposée par l’algorithme génétique (pour le critère de sélection *rf.conf*) avec une recherche à différents niveaux d’une hiérarchie construite selon le critère de fusion “erreur de reconstruction du spectre”). Des indicateurs de bonne classification (Kappa et F-score de la classe la plus mal classée) obtenus par un classifieur SVM gaussien pour les différents jeux de bandes sélectionnés y sont également affichés. D’un point de vue quantitatif, les solutions proposées restent du même ordre de grandeur que celles obtenues en sélectionnant uniquement les bandes originales, et que celles obtenues par sélection mono-niveau, mais ne sont pas systématiquement meilleures. Si les bandes sont réparties de manière assez semblable le long du spectre pour ces différentes solutions, certaines d’entre elles tendent à favoriser à une position donnée des bandes plus ou moins larges.

Ce phénomène a également été observé sur le jeu de données Indian Pines.




FIGURE 7.10 – Exemple de résultats de sélection multi-niveaux de bandes prenant en compte la hiérarchie de bandes fusionnées : chaque ligne représente une solution proposée par l’algorithme génétique (pour le critère de sélection *rf.conf*) pour la sélection multi-niveaux (pour une hiérarchie construite selon le critère de fusion “erreur de reconstruction du spectre”) pour le jeu de données Pavie. Des indicateurs de bonne classification obtenus par un classifieur SVM gaussien pour les différents jeux de bandes sélectionnés sont affichés à droite.

## 7.6 Conclusion et perspectives

Les différentes stratégies d’optimisation proposées s’appuient sur une hiérarchie de bandes fusionnées, construite de manière à progressivement rassembler les bandes adjacentes similaires au sens d’un certain critère de fusion différent du critère de sélection de bandes. Différents critères pour la fusion de bandes adjacentes ont été testés pour la construction de cette hiérarchie : un premier critère visait à rassembler les bandes les plus corrélées, un second critère s’efforçait de fusionner les bandes de manière à conserver au mieux la forme des spectres de référence tandis qu’un dernier critère fusionnait les bandes adjacentes contribuant d’une même manière à la séparabilité des différentes classes. Il est apparu que les deux derniers critères donnaient des résultats légèrement meilleurs que le premier.

Plusieurs stratégies d’optimisation ont ensuite été proposées, afin d’extraire des jeux de bandes fusionnées au sein de cette hiérarchie. Deux méthodes mono-niveau où l’on explore un à un les différents niveaux de la hiérarchie, en identifiant le meilleur jeu de bandes pour chacun d’eux ont été mises en œuvre. L’une d’elles était une méthode gloutonne, tandis que l’autre tient compte des jeux de bandes précédemment sélectionnés. Au vu des expériences menées, le fait d’utiliser des bandes plus larges que les bandes originales peut permettre d’améliorer la classification, légèrement dans le cas du jeu test Pavie, de manière plus prononcée pour Indian Pines (sans doute parce que des bandes plus larges ont pour effet de réduire le bruit, plus important sur cette seconde image).

Une méthode multi-niveaux a également été mise en œuvre. Les solutions fournies par cette dernière peuvent être assez variables, et ce processus doit être lancé à plusieurs reprises pour augmenter les chances de tomber sur une solution vraiment meilleure. Cette dernière approche

---

reste parmi les perspectives et mériterait d'être testée davantage. Il serait notamment intéressant de comparer les résultats qu'elle permet d'obtenir à ceux d'une méthode où l'on ne prend en compte aucun *a priori* sur les bandes fusionnées. En effet, dans les expériences qui ont été effectuées ici, la recherche d'une solution au sein d'une hiérarchie de bandes fusionnées est une stratégie autorisant le contrôle de la croissance de la largeur des bandes (et de ne pas tout miser sur le critère de sélection d'attributs, mais aussi intégrer des informations sur la similarité entre bandes). Il serait donc intéressant de confronter ces résultats à ceux obtenus par l'extraction directe (i.e. sans passer par une hiérarchie de bandes fusionnées) d'un jeu "optimal" de bandes fusionnées par une méthode comme les algorithmes génétiques [Minet *et al.* 2010], l'algorithme de [Serpico et Moser 2007], ou encore la méthode de [Tuia *et al.* 2014b].

Une autre perspective de travail pour la sélection de bandes spectrales fusionnées optimales concerne l'utilisation des profils d'importance des bandes générés à partir des résultats de l'algorithme génétique appliqué aux bandes individuelles et présentés dans la section 6.3.2. Notre intention originale au sujet de ces profils d'importance était en effet de les exploiter pour la définition de bandes larges. Lorsque l'on observe ces profils, on constate en effet visuellement la présence de "blobs" correspondant à des groupes de bandes le long de ces profils. Il serait donc tentant de les détecter de manière automatique. Une solution possible pourrait consister à utiliser conjointement ces profils d'importance et la similarité (ou la corrélation) entre les bandes. Cette première information nous apporterait un renseignement sur les zones du spectre à sélectionner (terme d'attache à la donnée), tandis que la seconde inciterait à fusionner ou non des bandes voisines (terme de régularisation). De premiers tests dans ce sens avaient été effectués par des méthodes très simples [Najjar 2013, Chehata *et al.* 2014] à partir d'importances issues de méthodes de type filtre.



## Quatrième partie

# Application à la classification des matériaux urbains





## Préambule

Deux stratégies étaient possibles pour le travail d’optimisation spectrale pour la classification des matériaux urbains, l’une basée sur la classification d’images hyperspectrales de zones urbaines, l’autre basée sur des bibliothèques de spectres de matériaux mesurés sur le terrain ou en laboratoire. Chaque scénario a ses avantages et ses inconvénients.

Le premier présente l’avantage de travailler à partir d’images aéroportées. L’évaluation de résultats de classification sur de telles données serait donc assez réaliste, car on se place donc dans des conditions, à la fois en termes de résolution et de phénomènes perturbateurs (ombres, pixels pas toujours purs), similaires à celles que l’on rencontrerait en pratique lors de classification de données superspectrales. L’existence de ces phénomènes perturbateurs peut être gênante pour l’optimisation spectrale proprement dite, mais ne concerne pas tous les pixels. En contrepartie, ce scénario permet de couvrir une zone importante et donc de potentiellement récupérer un nombre conséquent d’échantillons d’apprentissage et de test avec des matériaux d’une même classe dans différents états d’usure. En contrepartie, il nécessite de se doter d’une vérité terrain, or des ambiguïtés peuvent exister même *in situ* pour certains matériaux (ex : métaux), ou d’accès difficile (comme dans le cas des matériaux de toiture).

Le second scénario présente l’avantage de se baser sur des mesures en principe bien identifiées (pas d’incertitude sur la classe) et “propres” (mesures directement en réflectance sur des matériaux purs). En revanche, le nombre d’échantillons d’apprentissage et de test est nettement plus faible, ce qui s’avère gênant pour la plupart des classifieurs utilisés.

La stratégie initialement envisagée était la première et consistait donc à appliquer les algorithmes présentés dans la partie précédente à des images hyperspectrales aéroportées. Dans ce but, la campagne aérienne UMBRA [Adeline *et al.* 2013b] d’acquisition d’images a eu lieu sur deux villes : Toulouse et Amiens, choisies pour représenter deux paysages urbains typiques respectivement du Sud et du Nord de la France. Ces vols couvraient également différents types de quartiers (centre urbain dense, zone résidentielle, zone industrielle, campagne péri-urbaine) afin de rencontrer la plus grande diversité possible de paysages urbains et donc de matériaux. L’idée était donc initialement d’effectuer l’optimisation spectrale à partir de spectres de matériaux extraits de ces images. Prendre des spectres dans différentes parties de ces scènes aurait vraisemblablement permis de rencontrer différents matériaux dans différents états. Par ailleurs, on aurait aussi abordé les aspects plus pratiques liés à la classification, comme par exemple s’intéresser à des traitements complémentaires comme la régularisation des classifications obtenues, ou encore à la prise en compte d’informations exogènes dans le processus de classification comme l’apport d’une information 3D (un MNS de corrélation avait été calculé) ou de données topographiques [Le Bris et Chehata 2011].

Malheureusement, plusieurs problèmes se sont posés. Sur Amiens, les conditions météorologiques n’étaient pas bonnes : le ciel s’est progressivement couvert au cours de l’acquisition, rendant l’essentiel des données inutilisables sur cette zone. Sur la zone de Toulouse, en revanche, les conditions météorologiques étaient satisfaisantes. Toutefois, les conditions ne sont pas forcément favorables à la classification du fait de la période tardive à laquelle la prise de vue a eu lieu (fin octobre), avec pour conséquence un Soleil assez bas, et donc des effets liés au relief assez importants. Ainsi, d’une part, beaucoup de fonds de rue se trouvent totalement à l’ombre, et, d’autre part, les effets directionnels peuvent être importants (des pans de toits couverts par un même matériau apparaissent très différemment sur les images selon leur orientation).

Par ailleurs, du fait de problèmes radiométriques et géométriques liés aux images acquises, les données UMBRA n’ont été disponibles que trop tardivement pour nos expériences.

Aussi avons nous dû nous orienter vers la seconde stratégie, c’est-à-dire celle consistant à travailler à partir d’une bibliothèque de spectres de référence, issus de mesures de terrain ou de mesures en laboratoire. Le travail a alors consisté à récupérer les spectres de matériaux dans différentes

bases de données spectrales disponibles, avant de les mettre dans un format commun et dans une nomenclature commune.

Dans cette partie, on définira d'abord une taxonomie des matériaux urbains à partir de laquelle sera dérivée une nomenclature pour la classification, avant de présenter la manière dont nous avons structuré la librairie de spectres. On présentera ensuite rapidement les différentes librairies de spectres que nous avons utilisées. Seront ensuite présentés la manière dont ces spectres ont été utilisés pour définir une configuration instrumentale spectrale optimale, et les résultats obtenus.

## Chapitre 8

# Création d'une base de données de spectres de matériaux

### 8.1 Taxonomie de matériaux

Plusieurs taxonomies de matériaux et de nomenclatures pour la classification des matériaux en zones urbaines ont été proposées dans la littérature. Certaines de ces nomenclatures s'efforcent d'être les plus fines et les plus générales possibles, tandis que d'autres sont plutôt des nomenclatures de travail très spécifiques à un problème de classification donné, i.e. à une image et à une zone bien précise. En effet, si une taxonomie de matériaux doit être aussi exhaustive que possible, une nomenclature de travail pour la classification peut se restreindre aux matériaux que l'on peut espérer distinguer sur les images, l'essentiel étant alors d'extraire les matériaux les plus présents, et les plus importants. On pourra notamment citer les nomenclatures de travail définies dans [Chisense 2012, Taherzadeh et Shafri 2011, Taherzadeh *et al.* 2012]. Dans le cas de [Chisense 2012], certaines classes ont d'ailleurs été identifiées depuis l'image comme étant différentes des autres sans pour autant être labellisées (matériau inconnu). Ces nomenclatures de travail incluent également souvent des classes d'ombre.

A l'inverse, certains auteurs [Herold 2004, Heiden *et al.* 2007] ont proposé des taxonomies de matériaux urbains visant l'exhaustivité, ces taxonomies permettant alors d'affecter à peu près tout matériau à une catégorie. Ces nomenclatures que l'on peut voir sur les figures 8.1, 8.2 et 8.3 sont le plus souvent hiérarchiques. Leurs premiers niveaux concernent des classes d'occupation du sol classiques (cf chapitre 1). A ces premiers niveaux, sont alors associés un niveau correspondant aux matériaux attachés à ces classes d'occupation du sol, voire un niveau supplémentaire concernant des sous-classes de matériaux.

Si dans les grandes lignes, les principales familles de matériaux sont présentes dans ces deux taxonomies, on peut toutefois noter quelques différences.

La nomenclature proposée par Herold est plus orientée classification à partir de données aéroportée et est plus opérationnelle. Ainsi, son dernier niveau (niveau 4) est composé de sous-classes de matériaux distinguées uniquement en fonction de leur couleur. Par ailleurs, certaines classes les plus fines sont davantage des classes d'occupation du sol (voire d'usage du sol). On rencontre ainsi des classes comme "piscines" ou "voies ferrées".

La taxonomie proposée par Heiden est plus théorique et plus orientée vers la nature exacte des matériaux. Ainsi, là où Herold se limite à distinguer différents types de métaux uniquement en fonction de leur couleur, Herold les distingue en fonction de leur composition. Par ailleurs, ces taxonomies s'arrêtent aux différents types de matériaux en présence, mais ne prennent pas en compte leur niveau d'usure qui a pourtant, pour certains d'entre eux, un fort impact sur leur réponse spectrale. Il conviendrait donc de prendre en compte cette information, non nécessaire-

Level 1	Level 2	Level 3	Level 4
1. Built up	1.1 Buildings/roofs	1.1.1 Composite shingle roof	1.1.1.1 Black shingle
			1.1.1.2 Blue shingle
			1.1.1.3 Brown shingle
			1.1.1.4 Green shingle
			1.1.1.5 Grey shingle
			1.1.1.6 Mixed shingle
			1.1.1.7 Orange shingle
			1.1.1.8 Red shingle
			1.1.1.9 Tan shingle
			1.1.1.10 White shingle
		1.1.2 Plastic roofs	
		1.1.3 Glass	1.1.3.1 Light Glass
		1.1.4 Gravel roof	1.1.4.1 Gray gravel
			1.1.4.2 Red gravel
		1.1.5 Metal roof	1.1.5.1 Brown metal
			1.1.5.2 Light grey metal
			1.1.5.3 Green metal
		1.1.6 Asphalt roof	1.1.6.1 Light grey asphalt
		1.1.7 Tile roof	1.1.7.1 Red tile
			1.1.7.2 Gray tile
	1.1.8 Tar roof	1.1.8.1 Black tar	
		1.1.8.2 Brown tar	
	1.1.9 Wood shingle roof	1.1.9.1 Dark wood shingle	
	1.2 Transportation areas	1.2.1 Asphalt roads	1.2.1.1 Light asphalt (old)
			1.2.1.2 Dark asphalt (new)
			1.2.2.1 Light concrete
			1.2.3.1 Light Gravel
			1.2.4.1 Dak Parking lot
			1.2.5.1 Railroad tracks
			1.2.6.1 Light concrete
			1.2.6.1 Red brick
	1.2.7 Street paint	1.2.7.1 White street marks	
		1.2.7.2 Yellow street marks	
		1.2.7.3 Red street marks	
		1.2.7.4 Blue street marks	
		1.2.7.5 Other street marks	
	1.3 Sport infrastructure	1.3.1 Tennis courts	
		1.3.2 Red Tartan	
		1.3.3 Basketball court	
2. Vegetation	2.1 Green vegetation		
	2.2 Non-photosynthetic vegetation (NPV)		
3. Non-urban bare surfaces	3.1 Bare soil		
	3.2 Beach		
	3.3 Bare Rock		
4. Water bodies	4.1 Natural/quasi-natural water bodies		
	4.2 Swimming Pools		

FIGURE 8.1 – Taxonomie de matériaux urbains proposée par Herold (source : [Herold *et al.* 2004a])

Material	Surface color	Description
<b>I. Roof materials</b>		
<b>Mineral</b>		
- roofing tile	red	basic material: clay minerals (kaolinite, montmorillonite), quartz, ferric oxides ( $\text{Fe}_2\text{O}_3$ ); colored with clay sludges (containing ferric oxides) before the firing process
- concrete	gray	basic material: water, cement ( $\text{CaO} \times \text{SiO}_2$ , $\text{CaO} \times \text{Al}_2\text{O}_3$ , $\text{CaO} \times \text{Al}_2\text{O}_3 \times \text{Fe}_2\text{O}_3$ )
	red	covered with synthetic color; also possible: clay sludges (containing ferric oxides) after the drying
- fiber cement	bright/gray	mixture of fibers of synthetics and cellulose, cement
- gravel	bright/various	different pieces of round igneous rocks (3 cm in diameter)
- slate	black	flat plates of schist, layer silicates, some sericite, chlorite
<b>Metallic</b>		
- aluminum	blank	plates of pure aluminum
	red/white	coated with synthetic colors
- zinc	blank	plates of pure zinc
- copper		plates of pure copper (without patina)
- lead		plates of pure lead
<b>Hydrocarbons</b>		
- bitumen	green/gray	long-chained hydrocarbons (residue of distillation of petroleum); strewed with crushed slate
	red	covered with red synthetic color
	gray	covered with sand
- tar paper	dark/gray	long-chained hydrocarbons (residue of desolation of hard coal tar); strewed with crushed slate
- polyvinyl chloride (PVC)	gray	$n\text{CH}_2=\text{CHCl} \longrightarrow [-\text{CH}_2-\text{CHCl-}]_n$
- polyethylene (PE)	white	$n\text{CH}_2=\text{CH}_2 \longrightarrow [-\text{CH}_2-\text{CH}_2-]_n$
- polyisobutylene (PIB)	black	$(\text{C}_4\text{H}_8)_n$
<b>II. Impervious open surfaces</b>		
<b>Mineral</b>		
- concrete	bright/gray	see roofing concrete
<b>Hydrocarbons</b>		
- asphalt	dark/gray	bitumen (mostly long-chained hydrocarbons) mixed with mineral grains (natural like sand and gravel, synthetic like from waste incineration and blast furnace slag)
<b>III. Partially impervious open surfaces</b>		
<b>Mineral</b>		
- cobblestone pavement	various	different types of igneous rocks (mainly granite), spacings between single stones are filled with sand
- pavement of concrete	bright/gray	single pieces of concrete
	red	single pieces of concrete, covered with mineral color containing iron bearing minerals ( $\text{Fe}_2\text{O}_3$ )
- loose chippings	bright	rich in calcite and clay, very fine loose material
	red	crushed tiles (flour of tiles)
<b>Hydrocarbons</b>		
- loose chippings	black	mixture from blast furnace slag, mineral grains and other dark sand

FIGURE 8.2 – Taxonomie de matériaux urbains proposée par Heiden (source : [Heiden *et al.* 2007])

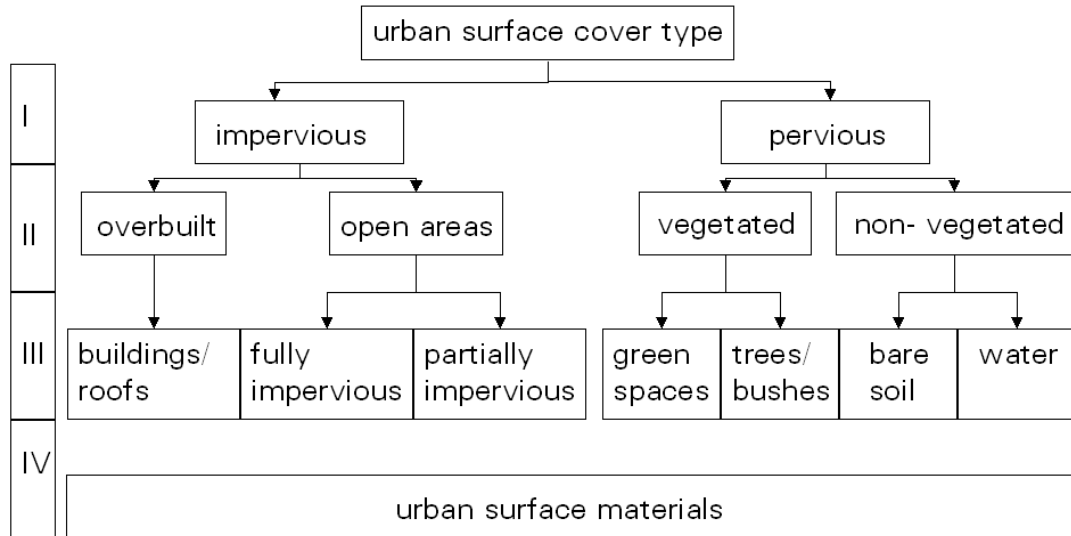


FIGURE 8.3 – Nomenclature hiérarchique utilisée par Heiden (source : [Kaufmann *et al.* 2010])

ment comme une sous-classe, mais comme un attribut complémentaire.

La nomenclature d’Heiden est dédiée aux villes allemandes, et plus généralement européennes, et diffère donc de celle d’Herold pensée pour des travaux sur la ville de Santa Monica aux USA. Certains matériaux sont donc absents de la taxonomie d’Heiden : il s’agit notamment des toitures en shingle (bardeaux bitumineux) qui occupaient une place importante dans celle d’Herold. Toutefois ce matériau semble de plus en plus utilisé dans le cadre de nouvelles constructions [Sellami-Kaaniche 2014] et il serait bon de l’intégrer dans la nomenclature également pour les villes européennes. D’autres éléments de la nomenclature d’Herold et absent de celle d’Heiden mériteraient également d’être conservés du fait de l’aspect particulier qu’ils peuvent présenter sur les images (piscines, tartans, gravier de voie ferrée), ainsi que différents types de peinture. Herold prenait en compte les peintures routières, mais elles concernent des surfaces limitées, à la différence des différents types de peintures ou de vernis recouvrant des matériaux métalliques, qui concernent des surfaces (de toiture) plus importantes. Il est en effet intéressant de distinguer les métaux en fonction de leur composition (comme le fait Heiden). Malheureusement, ils sont souvent recouverts par un vernis de couleur, et la détermination de leur nature exacte n’est de ce fait pas possible. Il est donc intéressant d’ajouter une classe de matériau “métal peint”. Il conviendrait également d’y intégrer les toitures en fibro-ciment amiante (il existe désormais des fibro-ciments sans amiante). Par ailleurs, d’autres éléments correspondant à de nouvelles pratiques sont absents de ces deux taxonomies : les panneaux photovoltaïques et les toitures végétalisées. Même si ces éléments ne concernent pas encore des surfaces très importantes, il nous semble intéressant de les intégrer à une taxonomie des matériaux afin qu’elle soit la plus exhaustive possible.

Enfin, les taxonomies proposées par Herold et Heiden sont hiérarchiques. La distinction entre différents matériaux n’intervient qu’aux niveaux les plus fins. Les premiers niveaux de la nomenclature concernent quant à eux davantage la distinction de classes d’occupation du sol, selon leur perméabilité pour Heiden, ou selon la couverture voire l’usage du sol pour Herold. Dans le cas de la nomenclature de la BD OCS GE de l’IGN (présentée sur la figure 8.4), les premiers niveaux font la distinction entre zones de végétation et de non végétation, puis selon leur perméabilité dans le second cas. Il peut alors être intéressant de conserver une catégorie semi-perméable comme dans la nomenclature d’Heiden. En revanche, la distinction du premier

Couverture du sol											
CS1. Sans végétation					CS2. Avec végétation						
CS1.1 Surfaces anthropisées		CS1.2 Surfaces naturelles			CS2.1 Végétation ligneuse			CS2.2 Végétation non ligneuse			
CS1.1.1 Zones imperméables	CS1.1.2 Zones perméables	CS1.2.1 Sols nus (sable, pierres meubles, rochers saillants...)	CS1.2.2 Surfaces d'eau (continentale et maritime)	CS1.2.3 Névés et glaciers	CS2.1.1 Formations arborées	CS2.1.2 Formations arbustives et sous-arbrisseaux (landes basses, formations arbustives, formations arbustives organisées...)	CS2.1.3 Autres formations ligneuses (vignes et autres lianes)	CS2.2.1 Formations herbacées (pelouses et prairies, terres arables, roselières...)	CS2.2.2 Autres formations non ligneuses (lichen, mousse, bananiers ...)		
		CS1.1.1.1 Zones bâties	CS1.1.1.2 Zones non bâties (routes, places, parking...)	CS1.1.2.1 Zones à matériaux minéraux (pierre-terre - voles ferrées, pistes forestières, chemins empierrés, chantiers, carrières, salines...)		CS1.1.2.2 Zones à autres matériaux composites (décharges)	CS2.1.1.1 Formations de feuillus	CS2.1.1.2 Formations de conifères	CS2.1.1.3 Formations de composition mixte		

FIGURE 8.4 – Nomenclature de la couche couverture du sol de l'OCS GE de l'IGN (source : [Touzet 2014])



niveau de la nomenclature IGN entre végétation et non végétation pose problème pour le cas des toitures végétalisées. Néanmoins, si l'on relit les spécifications de ces différentes classes [Touzet 2014], on constate que les différentes classes de végétation de cette OCS concernent en fait les zones agricoles, forestières, naturelles ou d'agrément (jardins, parcs), alors que les toitures végétalisées, bien que couvertes de végétation, se rattachent en réalité à la classe des "zones bâties" (CS1.1.1.1) "imperméables", c'est-à-dire à la famille des classes "sans végétation" (CS1). Les toitures végétalisées semblent toutefois s'inscrire plus facilement, comme un matériau de toiture, dans la nomenclature hiérarchique d'Heiden (figure 8.3), conçue pour le milieu urbain, où la notion de séparation entre végétation et non végétation n'intervient que pour les surfaces perméables. Après y avoir ajouté les classes manquantes, on aboutit donc à la taxonomie présentée figure 8.5. Les différentes classes de matériaux peuvent toutefois également s'inscrire dans la nomenclature de l'OCS IGN, aboutissant à la taxonomie présentée figure 8.6.

Par ailleurs, certains matériaux sont présents dans différentes classes d'occupation du sol. On va ainsi par exemple rencontrer des graviers ou du béton, à la fois au sol et sur les toitures. Aussi, certains matériaux ne seront pas rattachés à une seule classe du niveau hiérarchique précédent. Par conséquent, on travaillera en pratique avec, d'une part, une taxonomie hiérarchique "théorique" associant à des classes d'occupation du sol les matériaux susceptibles de s'y trouver en présence, et, d'autre part, une simple liste des différents matériaux sans autre considération concernant leur usage. Un matériau sera présent de manière unique dans cette liste, tandis qu'il pourra apparaître à plusieurs reprises dans la taxonomie hiérarchique. La taxonomie hiérarchique sera utile pour la classification en faisant le lien entre matériaux et occupation du sol de niveau supérieur, car elle pourra d'une part permettre de remonter des matériaux vers les classes d'OCS auxquelles ils appartiennent, et d'autre part, de manière inverse d'avoir des *a priori* sur les matériaux en présence si l'on dispose déjà de certaines connaissances sur l'OCS (comme une BD topographique, un MNS). La simple liste des matériaux sera quant à elle utilisée comme nomenclature de base pour catégoriser différents spectres dans une base de données, et réaliser des expériences de classification des matériaux sans considération des classes d'OCS dont ils font partie.

---

**Surfaces imperméables : toitures de bâtiments**


---

## [Minéraux]

- Tuile en terre cuite
- Tuile en ciment
- Ciment / béton
- Fibro-ciment
  - . Amiante
  - . Fibro-ciment sans amiante
- Gravier
- Ardoise

## [Métaux]

- Métaux
  - . Aluminium
  - . Zinc
  - . Cuivre
  - . Acier
  - . Plomb
  - . Alliages impliquant ces métaux
- . Métaux peints

## [Hydrocarbonés]

- Asphalte et bitume
- Papier goudronné
- Shingle / bardeaux bitumineux
- Plastique
  - . Polyvinyle chloride (PVC)
  - . Polyéthylène (PE)
  - . Polyisobutylène (PIB)

## [Autres]

- Panneaux photo-voltaïques
- Verre
- Toitures végétalisées

---

**Surfaces au sol imperméables**


---

## [Minéraux]

- Ciment / béton

## [Hydrocarbonés]

- Asphalte
- Tartan

## [Autres]

- Peintures routières
- ( - Piscine (pas un matériau en tant que tel, mais aspect caractéristique sur les images) )

---

**Surfaces au sol partiellement imperméables**


---

- Pavés en pierre
- Pavés auto bloquants en ciment
- Graviers (surtout si mélangé avec un peu de goudron)
- (- Voies ferrées (gravier+métal) (pas un matériau, mais aspect caractéristique sur les images))

---

**Surfaces au sol perméables**


---

- Graviers
- Terre
- Sable

FIGURE 8.5 – Taxonomie proposée à partir de la nomenclature d'Heiden

---

**CS 1.1.1.1 : Surfaces anthropisées → Zones imperméables → Zones bâties**


---

**[Minéraux]**

- Tuile en terre cuite
- Tuile en ciment
- Ciment / béton
- Fibro-ciment
  - . Amiante
  - . Fibro-ciment sans amiante
- Gravier
- Ardoise

**[Métaux]**

- Métaux
  - . Aluminium
  - . Zinc
  - . Cuivre
  - . Acier
  - . Plomb
  - . Alliages impliquant ces métaux
- . Métaux peints

**[Hydrocarbonés]**

- Asphalte et bitume
- Papier goudronné
- Shingle / bardeaux bitumineux
- Plastique
  - . Polyvinyle chloride (PVC)
  - . Polyéthylène (PE)
  - . Polyisobutylène (PIB)

**[Autres]**

- Panneaux photo-voltaïques
- Verre
- Toitures végétalisées

---

**CS 1.1.1.2 : Surfaces anthropisées → Zones imperméables → Zones non bâties**


---

**Imperméable :****[Minéraux]**

- Ciment / béton

**[Hydrocarbonés]**

- Asphalte
- Tartan

**[Autres]**

- Peintures routières
- ( - Piscine (pas un matériau en tant que tel, mais aspect caractéristique sur les images) )

**Partiellement perméable :****[Minéraux]**

- Pavés en pierre
- Pavés auto bloquants en ciment

---

**CS 1.1.2.1 : Surfaces anthropisées → Zones perméables → Zones à matériaux minéraux**


---

- (- Voies ferrées (gravier+métal) (pas un matériau, mais aspect caractéristique sur les images))
- Graviers
- Terre
- Sable

## 8.2 Structuration d’une librairie de spectres de matériaux

On souhaite se doter d’une librairie de spectres de matériaux qui rassemblera des mesures issues de différentes sources. Il s’agit donc de structurer cette base de données de manière à suivre la taxonomie de matériaux présentée précédemment, mais aussi à conserver d’autres informations plus détaillées associées à ces spectres de matériaux, pouvant notamment correspondre à de potentielles sous-classes. On a en effet pu voir que les nomenclatures d’Heiden et d’Herold présentent des différences au niveau des sous-classes de matériaux, dont la distinction se fait sur la base de la couleur dans le cas d’Herold. Par ailleurs, l’état et le niveau d’usure des matériaux sont aussi une information utile. Par conséquent, plutôt que de définir explicitement des sous-classes qui pourraient varier en fonction des applications, nous proposons de nous arrêter aux classes de matériaux et de leur associer des attributs concernant leur couleur, leur état (niveau d’usure, saleté), le type d’occupation du sol auquel le matériau sur laquelle cette mesure de spectre a été faite appartenait, ainsi que leur composition au cas où des sous-classes de compositions différentes seraient possibles (cas des métaux).

### Champs de la base de données

Il est donc proposé d’associer les attributs suivants à chaque spectre de la base de données :

- “Origine” “NomBaseOrigine” et “NomFichierOrigine” : des métadonnées concernant sa librairie d’origine pour garantir sa traçabilité
- “DescriptifOrigine” : descriptif associé au spectre dans sa librairie d’origine
- “Nom” : Nom attribué au spectre
- “Classe” : Classe de la taxonomie
- “ClasseDétail” : sous-classe possible du point de vue de la composition du matériau
- “FamilleOCS” : exemple voirie, sol nu ou toiture
- “Couleur”
- “Etat”
- “Longueurs d’onde” : c’est-à-dire les longueurs d’onde associées aux mesures de réflectance
- “Spectre” : les mesures de réflectance
- “Type de mesure”

Il sera donc éventuellement possible de recréer en fonction des besoins des classes plus fines en appliquant des requêtes sur ces attributs.

**Remarque concernant l’adaptation aux spectres disponibles :** Il a aussi fallu s’adapter aux spectres collectés, parfois en faible nombre ou insuffisamment documentés. Ainsi, il aurait été intéressant dans le cas des métaux d’avoir d’emblée plusieurs classes correspondant aux différents métaux en présence (aluminium, zinc, acier, cuivre, ...). Néanmoins, on disposait de peu de spectres pour chacune de ces catégories, et en outre, un certain nombre de spectres récupérés étaient simplement labellisés métal sans indication complémentaire. Aussi avons nous dû nous résoudre à stocker tous ces spectres dans une même classe métal, en précisant dans le champ “ClasseDétail” leur composition lorsque celle-ci était connue.

## 8.3 Bibliothèques spectrales de matériaux urbains

Les spectres que nous avons récupérés proviennent de différentes bibliothèques ou campagnes d'acquisition terrain. L'effectif des spectres en fonction de leur origine est donné dans le tableau 8.1.

### ASTER Spectral Library

La bibliothèque de spectres ASTER<sup>1</sup> [Baldrige *et al.* 2009] est mise à disposition par le Jet Propulsion Laboratory du Institut de Technologie de Californie. Il s'agit d'une compilation de plus de 2400 spectres de matériaux naturels et artificiels. Cette bibliothèque intègre 3 autres bibliothèques de spectres produites par l'Université Johns Hopkins (Johns Hopkins University (JHU) Spectral Library), le Jet Propulsion Laboratory (JPL) Spectral Library (Jet Propulsion Laboratory (JPL) Spectral Library) et l'USGS (the United States Geological Survey (USGS - Reston) Spectral Library).

### SLUM

La bibliothèque SLUM<sup>2</sup> (Spectral Library of impervious Urban Materials) [Kotthaus *et al.* 2014] produite et diffusée dans le cadre de LUMA (London Urban Micromet data Archive) regroupe des mesures de spectres de réflectances de 74 matériaux imperméables, prélevés sur la zone de Londres.

### MEMOIRES et autres données acquises par l'ONERA

De nombreux spectres issus de mesures terrain ou en laboratoire ont été fournis par l'ONERA. Une partie d'entre eux ont été récupérés de la bibliothèque spectrale MEMOIRES (Moyen d'Echange et de valorisation de Mesures de propriétés thermiques, Optiques et InfraRouges d'Echantillons et de Scènes)<sup>3</sup> [Martin et Rosier 2012]. D'autres proviennent de campagnes de mesures sur la ville de Toulouse non encore intégrées dans MEMOIRES.

### Santa Barbara

Un certain nombre de spectres mesurés (uniquement mesures terrain) sur la ville de Santa Barbara sont disponibles à l'adresse suivante <http://www.ncgia.ucsb.edu/ncrst/research/pavementhealth/urban/> [Herold *et al.* 2004a]. Il s'agit de spectres qui ont été mesurés dans le cadre de travaux portant respectivement sur l'optimisation spectrale pour la classification urbaine [Herold 2004] et l'analyse de l'état des routes à partir de données hyperspectrales [Herold *et al.* 2004b]. On distinguera ces deux bibliothèques. Outre ces mesures terrain, des spectres mesurés à partir d'une image hyperspectrale étaient également disponibles mais ont pour le moment été laissés de côté, du fait de leur résolution spectrale plus faible et de la présence de certains artefacts sur les spectres.

### Ben Dor

Des spectres issus des travaux de [Ben-Dor *et al.* 2001] pour la classification urbaine ont également été récupérés.

---

1. <http://speclib.jpl.nasa.gov/>
2. <http://LondonClimate.info/LUMA/SLUM.html>
3. <http://www.onera.fr/dota/memoires>

## DESIREX

Des spectres issus de la campagne de mesure terrain DESIREX 08 (ESA) [Sobrino *et al.* 2008] sur la ville de Madrid ont également été récupérés.

TABLE 8.1 – Origine des spectres récupérés

Librairie	Nombre de spectres
ASTER	29
BenDor	33
SLUM	55
DESIREX	11
ONERA MEMOIRES	282
SantaBarbara_routes	43
SantaBarbara_matériaux	62

## 8.4 Mise en forme et rangement des spectres dans la base de données

Il a donc fallu intégrer ces différents spectres dans notre modèle de base de données en fonction des champs définis au paragraphe 8.2. Ce travail a consisté à les rattacher aux différentes catégories de la nomenclature de la base de données, et renseigner les différents attributs définis lorsque les informations étaient disponibles. Ce travail n’a pas toujours été simple du fait de la grande hétérogénéité des informations accompagnant les spectres récupérés. Par ailleurs, les descriptions de ces spectres étaient parfois ambiguës. Voici quelques exemples de problèmes rencontrés :

- le mot “pavement” peut se traduire par pavé ou trottoir...
- existe-t-il une distinction entre béton et ciment, d’autant plus qu’il existe également un béton bitumineux relevant des matériaux hydrocarbonés.
- certains spectres avaient été mesurés sur des classes de mélange, comme par exemple des mélanges entre terre, sable et gravier
- le terme “brique” désigne selon les cas des briques de construction ou des pavés autobloquants.

Des informations concernant la couleur ou l’état des matériaux étaient associées à certains spectres avec plus ou moins de précision, mais pour d’autres, on ne disposait d’aucune information.

**Domaine spectral** Seuls ont été conservés les spectres qui couvraient à la fois le VNIR et le SWIR. Pour le travail d’optimisation spectrale effectué par la suite, on a donc dû se limiter au domaine spectral commun à la totalité des spectres récupérés.

Leur résolution spectrale était généralement comprise entre 1 et 5nm, parfois 10 nm en particulier dans le SWIR.

**Effets atmosphériques et autres artefacts** Tous les spectres récupérés n’ont pas été acquis dans les mêmes conditions, soit en laboratoire, soit sur le terrain (les mesures à partir d’images hyperspectrales ayant pour le moment été laissées de côté). Il s’agit uniquement de spectres de **réflectance**. Il a donc fallu prendre en compte les bandes concernées par les fenêtres d’absorption atmosphérique, où le signal a de fortes chances d’être bruité. Dans certains cas, les valeurs

avaient déjà été mises à 0 dans ces zones, dans d'autres cas, elles étaient plus ou moins bruitées. En outre, sur certains spectres d'autres artefacts étaient visibles, par exemple d'origine instrumentale comme des transitions entre capteurs VNIR et SWIR1 d'un ASD. Dans des cas où l'on dispose de très peu de spectres pour certaines classes, ces artefacts risquent d'être identifiés comme discriminants. Aussi a-t-il également fallu exclure les bandes concernées.

## 8.5 Classes non considérées

Notre travail s'est plutôt focalisé sur les matériaux urbains artificiels. Aussi, certains thèmes comme la végétation ou l'eau ont été exclus du processus d'optimisation spectrale et n'ont donc pas non plus été intégrés dans la base de données de spectres de référence.

**Végétation** La végétation est un élément important du paysage urbain et un facteur clé pour comprendre le fonctionnement de cet écosystème. Toutefois, sa détection à partir de données multispectrales classiques (rouge - vert - bleu - proche infrarouge) ne pose généralement pas de problèmes. Il aurait été intéressant d'aller plus loin (séparation des espèces, mesure de l'état sanitaire), mais cela aurait constitué une problématique à part entière, et aurait nécessité de disposer de nombreux spectres correspondant aux différentes espèces, et acquis à différentes périodes dans le temps, la végétation pouvant présenter un aspect très variable dans le temps et selon les conditions climatiques. Il sera toutefois intéressant de mener une étude complémentaire dans ce sens, notamment afin de savoir dans quelle mesure il est possible de discriminer la végétation spécifique aux toitures végétalisées. (En effet, si, dans un processus de classification, les ambiguïtés entre végétations haute et basse peuvent être levées en utilisant une information 3D (MNS) [Iovan 2009], cela n'est plus possible pour la distinction entre végétation haute et toitures végétalisées.)

**Eau** Bien que présentes en milieu urbain, les zones d'eau n'ont pas été prises en compte. Il faudrait là-aussi disposer de davantage de spectres, car son aspect est variable selon sa profondeur, sa turbidité et son eutrophysation.

En revanche, le **sol nu naturel** (terre, sable) a bien été pris en considération, du fait de son importance pour les problématiques de perméabilité des sols et de ses potentielles confusions avec des matériaux imperméables.

**Panneaux photovoltaïques** Cette classe a finalement été laissée de côté. Nous disposions de quelques spectres pour la décrire, mais ces spectres étaient les seuls à être fournis sous forme de BRDF. Par manque de temps, plutôt que de définir la meilleure manière de les intégrer (intégration ou simulation de spectres sous différentes configurations observateur-source lumineuse réalistes), nous les avons laissés de côté. Mais il sera intéressant de les intégrer ultérieurement dans le processus.

La synthèse des spectres retenus est donnée dans le tableau 8.2 et illustré par la figure 8.7.

TABLE 8.2 – Bilan des spectres disponibles pour les principales classes de matériaux

Tuiles	29
dont tuiles en terre cuite	12
et tuiles en ciment	6
Ardoises	2
Shingle	27
Papier goudronné	3
Fibro-ciment	3
Amiante	2
Métal non peint	19
dont Acier(7) Acier_rouillé(1) Aluminium(5)	
Aluminium_et_Zinc(1) Cuivre(3) Plomb(1)	
Métal peint	8
Plastique	7
dont PVC	6
(Chacun de ces spectres est d'une couleur différente)	
Asphalte	162
Pavés en pierre	122
Ciment/béton	67
dont Pavés en ciment	10
Peintures routières	5
Terre	10
Gravier	29
Sable	1






FIGURE 8.7 – Bilan des spectres disponibles pour les principales classes de matériaux

## Chapitre 9

# Optimisation spectrale pour la discrimination des matériaux

### 9.1 Approche proposée

#### 9.1.1 Constitution de “jeux de données synthétiques”

Ainsi qu’il a été mentionné plus haut, le travail d’optimisation spectrale a dû être mené à partir de bibliothèques spectrales disponibles (et non à partir d’images hyperspectrales et de cartes de vérité terrain associées). Ce scénario présente toutefois l’avantage de se baser sur des mesures en principe bien identifiées (pas d’incertitude sur la classe) et “propres” (mesures directement en réflectance sur des matériaux purs). En revanche, le nombre d’échantillons d’apprentissage et de test est nettement plus faible, ce qui s’avère gênant à la fois lors de la phase d’apprentissage pour la plupart des classifieurs utilisés, mais également pour l’évaluation des résultats de classification puisque les échantillons de test risquent d’être les mêmes que ceux ayant servi pour l’apprentissage. La réponse à ce problème a consisté à générer d’autres spectres à partir des spectres de la base de données, en leur appliquant un facteur multiplicatif aléatoire. Cela ne permet pas de réellement simuler la totalité de la variabilité intra-classe des matériaux, comme leurs différents états (usure, couleur variable) pour lesquels le facteur multiplicatif devrait alors varier selon les différentes parties du spectres. Le facteur multiplicatif aléatoire appliqué aux spectres était ici compris entre 0,8 et 1,2, d’après l’observation des écarts types sur les classes pour lesquelles on disposait de nombres de spectres plus conséquents. Des analyses quantitatives plus fines sur la variabilité de certains matériaux sont également disponibles dans [Lacherade *et al.* 2005, Briottet *et al.* 2006], différenciant différents comportements correspondant à la variabilité intrinsèque d’un matériau, celle liée à sa rugosité, celle liée à ses différentes utilisations et enfin celle liée à ses différentes variétés.

La méthode (voir figure 9.1) mise en œuvre pour se doter d’un jeu de vérité terrain est donc la suivante :

#### **Génération d’une vérité terrain de n échantillons par classe**

**Pour** chaque classe  $c$  **faire**

$VT_c \leftarrow \emptyset$

Création d’une requête pour récupérer la liste des spectres appartenant à cette classe

Création de la liste  $L_c$  des spectres de la base de données vérifiant la requête

**Pour**  $i$  de 1 à  $n$  **faire**

Sélection aléatoire d’un spectre  $s$  de  $L_c$

Bruitage du spectre  $s$  :

Application à  $s$  d’un facteur multiplicatif aléatoire (choisi ici entre 0,8 et 1,2)

$s \leftarrow rand().s$

On ajoute ce spectre à la vérité terrain :  $VT_c \leftarrow VT_c \cup s$

## FinPour FinPour

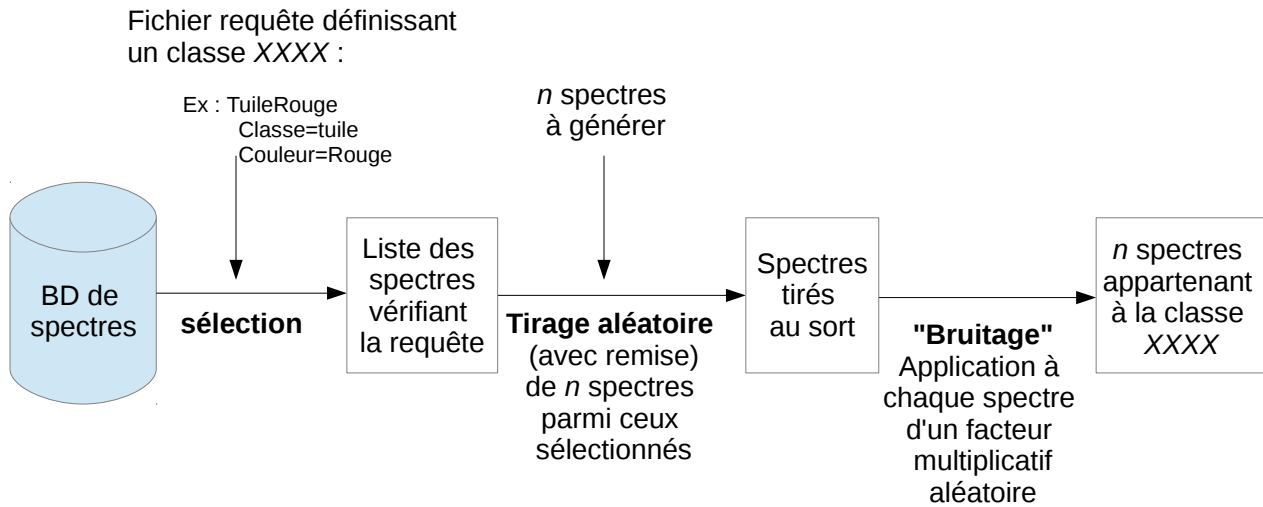


FIGURE 9.1 – Génération d’une vérité terrain synthétique à partir de la base de données

Si certaines classes sont bien représentées dans la base de données, comme les revêtements asphaltés (162 spectres), les pavés en pierre (144 spectres) et le béton (69 spectres), d’autres pourtant importantes et donc à prendre en compte ne le sont que par très peu d’échantillons (comme les ardoises et l’amiante, représentées chacune par seulement 2 spectres) qui ne pourront donc pas nécessairement bien représenter leur variabilité intra-classe. En conséquence, les résultats qui seront obtenus pour certaines classes seront à nuancer.

## 9.2 Expériences et résultats

Les expériences d’optimisation spectrale ont été menées pour deux légendes de classification différentes.

La première (“légende 1”) regroupe des classes parmi les mieux représentées dans la base de données ainsi que d’autres classes importantes (ex : ardoise) car assez communes. Ces classes seraient les classes de base d’une carte de matériaux car on est à peu près certains de les rencontrer. Cette légende est donnée ci-dessous :

- Ardoise
- Asphalte
- Ciment
- Gravier
- Métal
- Pavés en pierre
- Shingle
- Terre
- Tuile

La seconde légende (“légende 2”) reprend sensiblement les mêmes classes, mais en les divisant parfois en sous-classes, et intègre quelques autres classes qu’il pourrait être important de savoir discriminer. Elle est donnée ci-dessous :

- Amiante
- Ardoise
- Asphalte
- Ciment
- Fibrociment
- Gravier
- Métal
- Métal peint
- Pavés en pierre
- Shingle
- Terre
- Tuile en ciment
- Tuile en terre cuite

Certains éléments d’occupation du sol importants comme l’eau et la végétation que l’on pourrait s’attendre à rencontrer dans ces légendes ont été exclus de ce travail pour les raisons explicitées dans la section 8.5.

Par ailleurs, on se limite ici à distinguer les différentes familles de matériaux. On ne tient donc pas compte de leur usage (comme cela aurait pu être le cas de ceux présents à la fois au sol, ou comme matériau de toiture), cette information étant insuffisamment disponible parmi les spectres recueillis.

On n’a pas établi dans ces légendes de distinction concernant la couleur ou l’état des matériaux. En effet, on cherche ici pour le moment simplement à identifier des jeux de bandes permettant de les distinguer au mieux, et même s’ils présentent des couleurs différentes, i.e. une variabilité intra-classe dans le domaine visible, il n’est pas forcé que cela soit également le cas dans d’autres parties du spectre, où ils peuvent au contraire présenter un comportement commun, mais discriminant par rapport aux autres classes.

Par ailleurs, l’optimisation spectrale a été effectuée selon le critère *rf.conf*. Ce critère se base sur le classifieur Random Forest qui a la capacité de gérer des classes présentant des aspects variables. Aussi est-il dans une certaine mesure capable de gérer ces problèmes de variabilité intra-classe.

On étudiera toutefois dans un second temps l’impact sur la classification de la prise en compte de la couleur lors de l’apprentissage, notamment lorsque l’on se limite à des bandes dans le VNIR.

L’optimisation spectrale a été effectuée à la fois pour des spectres à une résolution de 10 nm et à celle de 1 nm, afin de voir l’impact de la résolution spectrale.

### 9.2.1 Sélection de bandes individuelles pour la légende 1 pour une résolution constante de 10 nm

#### Sélection dans le domaine VNIR+SWIR (420-2400 nm)

Les figures 9.2 et 9.3 montrent l’impact du nombre de bandes sélectionnées respectivement sur le score de sélection d’attributs *rf.conf* et sur la qualité de la classification obtenue en utilisant




FIGURE 9.2 – Légende 1 : évolution du score de sélection en fonction du nombre de bandes sélectionnées par la méthode SFFS dans le domaine VNIR+SWIR

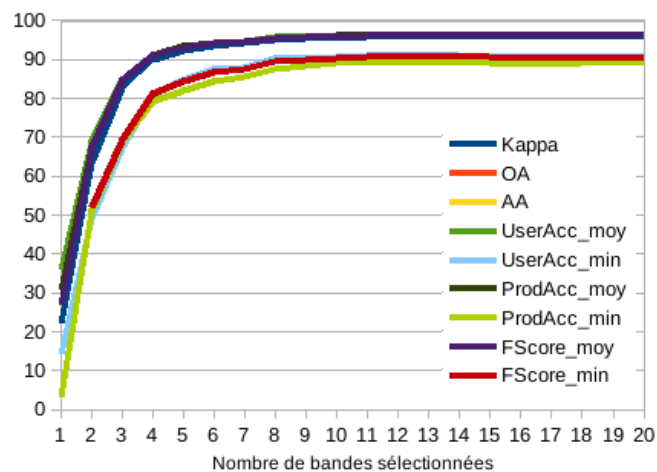


FIGURE 9.3 – Légende 1 : évolution de la qualité de la classification par un SVM à noyau gaussien en fonction du nombre de bandes sélectionnées par la méthode SFFS dans le domaine VNIR+SWIR

un classifieur SVM avec noyau gaussien. Le score *rf.conf* tend à monter rapidement puis à rester à peu près constant à partir de 7-8 bandes. La qualité de la classification obtenue en utilisant un classifieur SVM continue de s'améliorer jusqu'à 9-10 bandes, à la fois pour les indicateurs globaux et pour les indicateurs liés à la classe la plus mal classée (FScore\_min). Dans la suite, on sélectionnera 10 bandes.

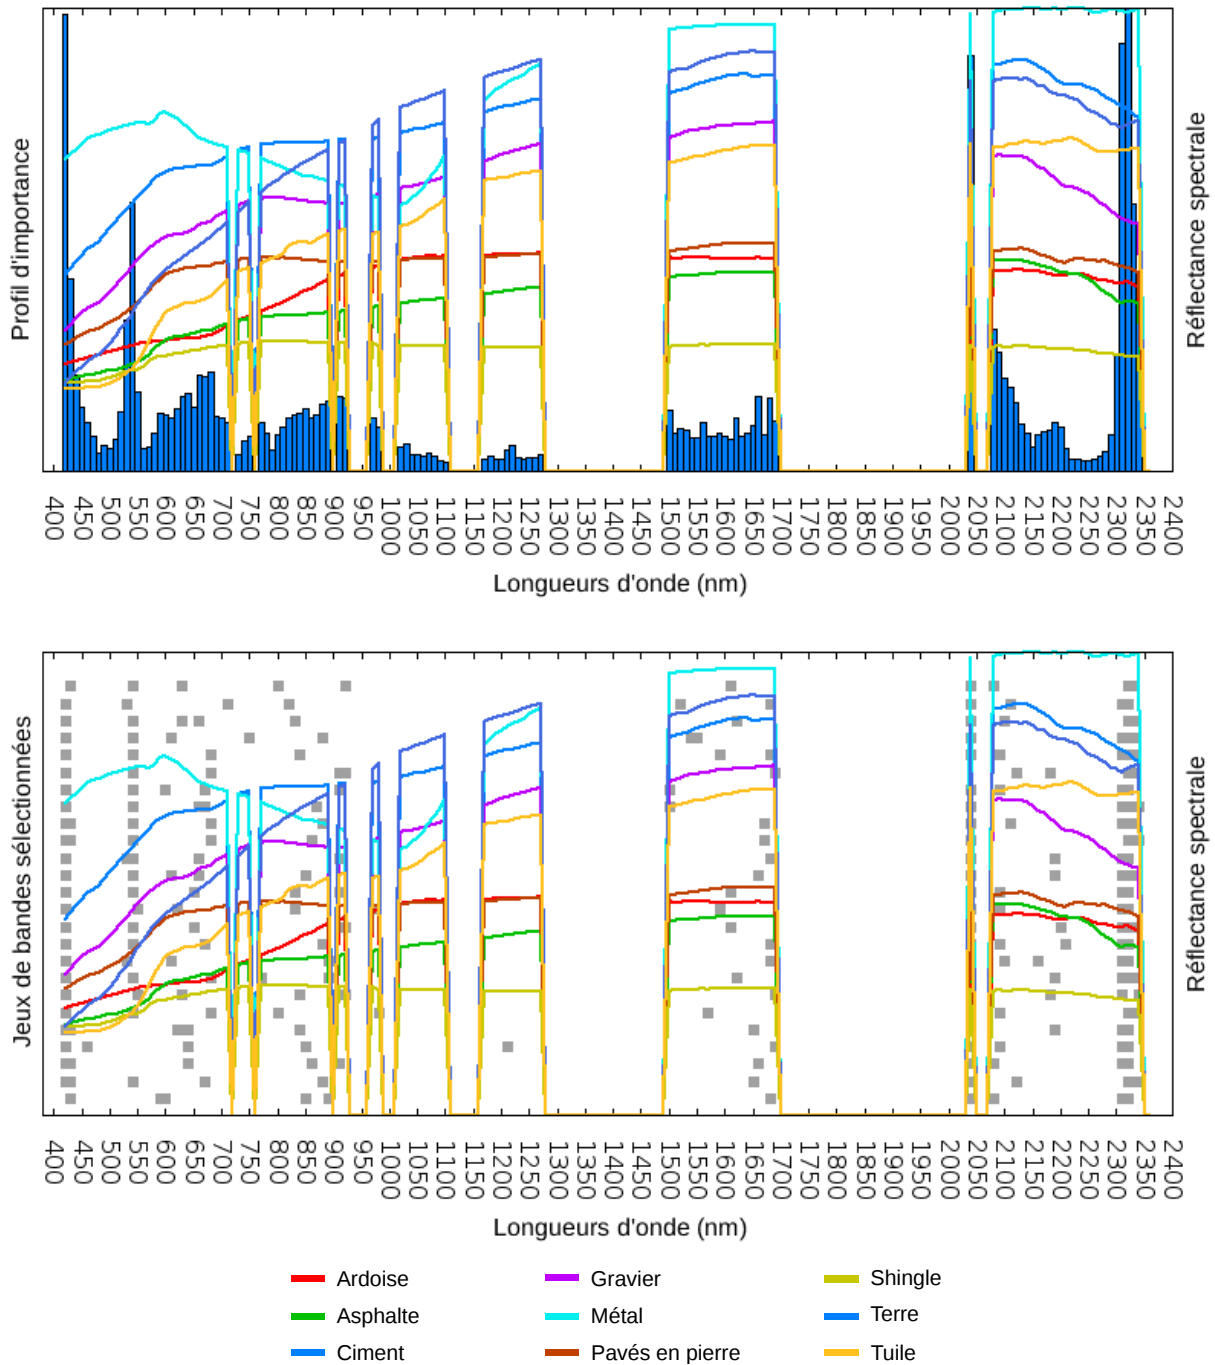


FIGURE 9.4 – Légende 1 : profil d'importance de bandes (en haut) calculé pour une sélection de 10 bandes dans le domaine VNIR+SWIR et sélections obtenues (en bas) pour différentes itérations de l'algorithme génétique

Les profils d'importance associés aux différentes bandes (par application de l'algorithme génétique pour une sélection de 10 bandes) ainsi que les jeux de bandes sélectionnées par différentes itérations de l'algorithme génétique sont visibles sur la figure 9.4. On peut constater que certaines parties du spectres notamment entre 1000 et 1500 nm (dans les fenêtres 1000-1100 nm et 1150-1350 nm) ne sont pas considérées comme intéressantes par l'algorithme : ces bandes y sont très rarement sélectionnées. Des bandes sont considérées comme importantes à la fois dans le VNIR et le SWIR.

On observe aussi qu'une bande située à 2040 nm est considérée comme importante et toujours sélectionnée. Les bandes voisines avaient été masquées afin d'éviter au maximum tout problème d'artefact dû à l'atmosphère. Cette bande se trouve donc isolée, avec un comportement spécifique perçu comme discriminant et est donc sélectionnée. Si ces voisines n'avaient pas été masquées, les sélections auraient aussi pu parfois se porter sur elles. Plus généralement, cela illustre le problème de l'influence de l'atmosphère. En principe, on a éliminé les bandes d'absorption atmosphérique, en masquant plus de bandes que nécessaire. Il apparaît toutefois que certaines bandes sélectionnées restent proches de ces bandes d'absorption, et donc de zones sensibles aux conditions atmosphériques et aux artefacts que celles-ci sont susceptibles d'avoir engendrés.

Quelques résultats quantitatifs sont présentés pour le jeu de bandes sélectionnées au sein duquel les bandes sont les moins corrélées : les tableaux 9.1, 9.2 et 9.3 présentent des matrices de confusions et bilan par classes obtenus à l'issue de classification par SVM avec noyau gaussien et RF. Ces chiffres sont des moyennes : 5 classifications ont en effet été effectuées à partir de données d'apprentissage (100 échantillons par classe) et de validation différentes (3000 échantillons par classe). Ces résultats apparaissent également sur la figure 9.5.

TABLE 9.1 – Matrice de confusion obtenue à l'issue d'une classification par SVM avec noyau gaussien pour un jeu optimal de 10 bandes issues du domaine VNIR+SWIR pour la légende 1.

prévu (BD) \ obtenu (classif.)	Ardoise	Asphalte	Ciment	Gravier	Métal	PavésPierre	Shingle	Terre	Tuile
Ardoise	100	0	0	0	0	0	0	0	0
Asphalte	0,9	91,7	1,8	0,8	1,1	0,5	0,6	2,0	0,5
Ciment	0,0	1,9	89,1	2,5	1,0	2,2	1,2	1,8	0,2
Gravier	0	0,7	0,6	98,6	0	0	0	0	0
Métal	0,2	0,3	2,2	0	96,8	0	0,3	0	0,3
PavésPierre	0	1,1	4,7	0,1	0,1	92,0	0,4	0,7	1
Shingle	0,1	1,4	0,2	0	0,0	0,3	98,0	0	0
Terre	0	1,1	0	0	0	0	0	99,0	0
Tuile	0	0	0	0	0	0	0	0,2	99,8

TABLE 9.2 – Matrice de confusion obtenue à l'issue d'une classification par RF pour un jeu optimal de 10 bandes issues du domaine VNIR+SWIR pour la légende 1.

prévu (BD) \ obtenu (classif.)	Ardoise	Asphalte	Ciment	Gravier	Métal	PavésPierre	Shingle	Terre	Tuile
Ardoise	97,2	0,4	0,1	0	0	0,5	1,8	0	0
Asphalte	3,1	75,6	2,5	2,8	1,6	6,6	7,0	0,2	0,8
Ciment	0,8	1,5	74,8	4,7	2,2	5,2	5,4	4,9	0,5
Gravier	0	1,2	5,7	87,8	0,6	2,8	0,3	1,1	0,5
Métal	0,6	1,7	2,0	0,8	88,3	0,9	4,1	0,4	1,1
PavésPierre	0,4	4,1	11,3	1,4	0,6	77,3	2,2	0,5	2,3
Shingle	3,6	6,5	1,6	0,5	1,7	6,4	78,9	0,9	0
Terre	0	0	1,6	1,1	1,1	0	0,5	93,7	2,1
Tuile	0,2	4,1	0	0,4	0,5	6,3	0,0	3,3	85,3



TABLE 9.3 – Bilan de classification pour un jeu optimal de 10 bandes issues du domaine VNIR+SWIR pour la légende 1.

	SVM noyau gaussien			RF		
	Préc. util.	Préc. prod.	F-score	Préc. util.	Préc. prod.	F-score
Ardoise	98,9	100,0	99,5	91,9	97,2	94,5
Asphalte	93,5	91,7	92,6	80,1	75,6	77,6
Ciment	90,4	89,1	89,7	75,6	74,8	75,1
Gravier	96,6	98,6	97,6	88,3	87,8	88,0
Métal	97,7	96,8	97,3	91,3	88,3	89,7
PavésPierre	96,9	92,0	94,4	73,0	77,3	75,1
Shingle	97,5	98,0	97,7	78,9	78,9	78,8
Terre	95,5	99,0	97,2	89,3	93,7	91,4
Tuile	98,1	99,8	98,9	92,5	85,3	88,7
Moyennes	96,1	96,2	96,1	84,6	84,3	84,3
Kappa			95,6			82,4

On peut constater que d’après ces résultats les différentes classes se retrouvent assez bien, en particulier lorsque l’on utilise un classifieur SVM à noyau gaussien, les résultats avec les RF restant un peu plus faibles. Il convient toutefois de garder à l’esprit que le jeu de données sur lequel se sont appuyés ces tests est pour certaines classes assez limité, et que bien que les spectres se soient vus appliqués un coefficient multiplicatif aléatoire, on se trouve dans une situation pour laquelle la variabilité intra-classe n’est vraisemblablement pas aussi importante qu’elle le serait sur un jeu de données réelles.

Ainsi, les ardoises sont généralement bien détectées mais ne sont représentées que par deux spectres dans la base de données. La classe des ciments/bétons est la plus mal traitée par les deux classifieurs. Elle a tendance à être confondue avec plusieurs autres classes, dans des proportions un peu différentes selon le classifieur utilisé. Elle est principalement confondue avec les pavés en pierre, et dans une moindre mesure, avec les graviers, les shingles et la terre. Une explication possible serait le fait que certains des matériaux de cette classes sont des pavés en ciment incluant d’autres matériaux minéraux analogues à ceux présents dans ces classes. L’asphalte est la seconde classe la moins bien traitée, avec des confusions avec les shingle (qui incluent aussi des éléments hydrocarbonés) ainsi qu’avec les pavés en pierre et dans une moindre mesure les graviers. Une explication possible serait le fait que ces matériaux sont des constituants du revêtement routier, et que leur signature apparaît plus fortement lorsque celui-ci est usé [Mohammadi 2012]. Il est d’ailleurs plus surprenant que peu de confusions interviennent entre graviers et pavés en pierre.

### Comparaison avec le jeu hyperspectral complet VNIR+SWIR

Il était intéressant de confronter les résultats obtenus pour le jeu de bandes sélectionnées avec ceux obtenus en utilisant l’intégralité du jeu hyperspectral VNIR+SWIR à la résolution de 10 nm sans sélection. Les résultats obtenus sont présentés dans le tableau 9.4 et sur la figure 9.5. Les chiffres obtenus sont assez similaires à ceux obtenus en utilisant le jeu de 10 bandes issues de l’optimisation. Dans le cas du classifieur RF, on parvient à une classification légèrement meilleure avec les 10 bandes sélectionnées.

TABLE 9.4 – Bilan de classification pour la légende 1 pour le jeu hyperspectral complet (à la résolution spectrale de 10 nm)

	SVM noyau gaussien			RF		
	Préc. util.	Préc. prod.	F-score	Préc. util.	Préc. prod.	F-score
Ardoise	99.2	100.0	99.6	88.4	96.7	92.3
Asphalte	96.3	93.1	94.6	72.7	72.4	72.3
Ciment	92.7	89.6	91.1	67.7	79.0	72.8
Gravier	94.6	99.5	96.9	88.1	80.0	83.8
Métal	98.8	97.3	98.0	94.1	87.1	90.5
PavésPierre	97.6	94.2	95.8	67.8	72.8	70.2
Shingle	97.8	99.2	98.5	77.9	74.5	76.0
Terre	95.6	98.5	97.0	88.5	90.5	89.5
Tuile	98.5	99.5	99.0	93.6	78.0	85.0
Moyennes	96.8	96.8	96.7	82.1	81.2	81.4
Kappa			96,4			78,9

### Comparaison avec la configuration spectrale de Worldview-3

Lancé en 2014, le satellite de télédétection Worldview-3 est équipé d'un capteur superspectral comportant 8 bandes dans le visible-proche infrarouge et 8 bandes dans le SWIR (fournissant des images d'une résolution spatiale de 31cm en panchromatique, 1,24 m pour les bandes visibles et proche infrarouge et 3,7 m pour les bandes du SWIR). Sa configuration est rappelée dans l'annexe B. Il était donc intéressant de confronter les résultats obtenus pour le jeu de bandes sélectionnées avec ceux obtenus en utilisant la configuration spectrale (16 bandes larges) de Worldview-3. L'évaluation d'une classification utilisant les 16 bandes du satellite Worldview-3 est également présentée dans le tableau 9.5 et sur la figure 9.5. Les chiffres obtenus sont assez similaires à ceux obtenus précédemment en utilisant le jeu de 10 bandes issues de notre optimisation. Les performances de classification obtenues dans les deux cas restent assez similaires. Ainsi, les performances atteintes pour le classifieur SVM ne sont pas significativement différentes. Dans le cas du classifieur RF, on parvient à une classification légèrement meilleure avec les 10 bandes sélectionnées.

TABLE 9.5 – Bilan de classification pour la légende 1 pour la configuration spectrale de Worldview-3

	SVM noyau gaussien			RF		
	Préc. util.	Préc. prod.	F-score	Préc. util.	Préc. prod.	F-score
Ardoise	99,1	100,0	99,6	90,3	96,7	93,4
Asphalte	93,8	92,4	93,1	75,3	74,6	74,8
Ciment	90,4	88,9	89,6	73,8	75,6	74,6
Gravier	95,1	99,3	97,1	86,2	83,5	84,8
Métal	97,4	96,6	97,0	92,9	89,3	91,0
PavésPierre	98,1	94,2	96,1	69,2	74,7	71,8
Shingle	98,0	97,8	97,9	79,5	75,7	77,4
Terre	95,9	97,7	96,7	87,9	92,5	90,1
Tuile	97,5	98,8	98,1	92,8	81,9	86,9
Moyennes	96,2	96,2	96,2	83,1	82,7	82,8
Kappa			95,7			80,6



### Sélection dans le domaine VNIR limité au domaine 420-1000 nm




FIGURE 9.6 – Légende 1 : évolution du score de sélection en fonction du nombre de bandes sélectionnées dans le domaine VNIR (420-1000 nm) par la méthode SFFS

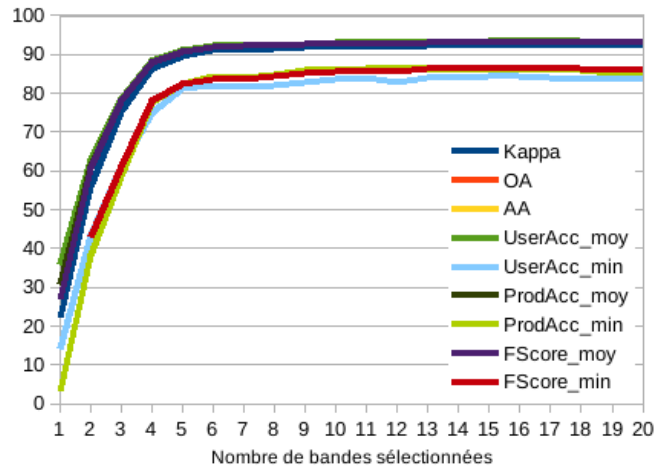


FIGURE 9.7 – Légende 1 : évolution de la qualité de la classification par un SVM à noyau gaussien en fonction du nombre de bandes sélectionnées dans le domaine VNIR (420-1000 nm) par la méthode SFFS

Les figures 9.6 et 9.7 montrent l'impact du nombre de bandes sélectionnées respectivement sur le score de sélection d'attributs *rf.conf* et sur la qualité de la classification obtenue en utilisant un classifieur SVM avec noyau gaussien. Le score *rf.conf* tend à monter rapidement puis à rester à peu près constant à partir de 4-5 bandes. La qualité de la classification obtenue en utilisant un classifieur SVM continue à s'améliorer légèrement jusqu'à 9-10 bandes, en particulier pour les indicateurs liés à la classe la plus mal classée (FScore\_min).

Dans la suite, on a sélectionné 10 bandes.

Les profils d'importance associés aux différentes bandes (par application de l'algorithme génétique pour une sélection de 10 bandes) ainsi que les jeux de bandes sélectionnés par différentes itérations de l'algorithme génétiques sont visibles sur la figure 9.8. On peut constater que 4 (voire 5) domaines se détachent du profil d'importance, à mettre en regard avec les résultats des figures 9.6 et 9.7. Si l'on regarde les jeux de bandes sélectionnés, on constate que l'algorithme a plutôt sélectionné des bandes voisines dans ces domaines, plutôt que dans les autres parties du spectre. On peut aussi remarquer que les bandes principales sélectionnées sont proches de celles

de la famille SPOT multispectral ou Pléiades.

Quelques résultats quantitatifs sont présentés pour le jeu de bandes sélectionnées au sein duquel les bandes sont les moins corrélées. Le tableau 9.8 ainsi que la figure 9.5 présentent un récapitulatif des précisions par classes obtenues à l'issue de classification par SVM avec noyau gaussien et RF. Ces résultats restent nettement plus faibles que ceux obtenus précédemment en prenant également des bandes dans le SWIR. Ceci confirme les résultats obtenus par [Oltra-Carrio *et al.* 2015] sur l'intérêt des bandes issues du domaine SWIR pour la classification en milieu urbain. Les résultats obtenus sont assez différents selon le classifieur. Dans le cas des RF, les classes les plus mal traitées sont l'asphalte et le shingle, qui se confondent mutuellement (en raison de couleur sombre ou rouge sans doute assez proches), mais aussi avec les autres classes (notamment les tuiles dans le cas de l'asphalte).

Les tableaux 9.6 et 9.7 présentent les matrices de confusions obtenues respectivement pour les SVM et les RF. Les confusions ne sont les mêmes selon le classifieur utilisé. Si l'on regarde les classes les plus mal traitées, on constate que les shingles se confondent avec la plupart des autres classes en particulier dans le cas du classifieur RF. L'asphalte tend à se confondre avec les shingles, mais également avec des classes minérales (gravier, pavés en pierre et ciment), ainsi qu'avec les tuiles. Pavés en pierre et ciment (et dans une moindre mesure graviers et ciment) tendent à se confondre en particulier dans le cas du classifieur RF.




FIGURE 9.8 – Légende 1 : profil d'importance de bandes calculé pour une sélection de 10 bandes dans le domaine VNIR (en haut) et sélections obtenues (en bas) pour différentes itérations de l'algorithme génétique

TABLE 9.6 – Matrice de confusion obtenue à l'issue d'une classification par SVM à noyau gaussien pour un jeu optimal de 10 bandes issues du domaine VNIR pour la légende 1.

prévu (BD) \ obtenu (classif.)	Ardoise	Asphalte	Ciment	Gravier	Métal	PavésPierre	Shingle	Terre	Tuile
Ardoise	100	0	0	0	0	0	0	0	0
Asphalte	0,6	87,7	1,1	5,7	1,2	0,6	1,4	0,3	1,4
Ciment	0,1	1,2	86,0	3,3	0,8	3,1	2,2	2,9	0,4
Gravier	0	2,0	3,6	93,5	0,3	0	0,1	0,4	0,0
Métal	1,6	2,1	3,6	0,3	90,0	0,4	1,6	0,1	0,2
PavésPierre	0	1,3	4,4	1,0	1,0	87,1	1,1	1,2	2,8
Shingle	0,4	0,9	2,8	0,2	3,0	0,5	92,3	0	0
Terre	0	0,1	1,3	1,6	0	0	0,2	96,9	0
Tuile	0	2,6	0,1	1	0	0,3	0,4	0,2	95,4

TABLE 9.7 – Matrice de confusion obtenue à l'issue d'une classification par RF pour un jeu optimal de 10 bandes issues du domaine VNIR pour la légende 1.

prévu (BD) \ obtenu (classif.)	Ardoise	Asphalte	Ciment	Gravier	Métal	PavésPierre	Shingle	Terre	Tuile
Ardoise	95,3	0,3	0,1	0	1,6	0,1	1,6	0,2	0,8
Asphalte	3,8	62,6	2,2	5,8	2,0	9,2	7,9	3,1	3,5
Ciment	0,3	0,9	68,5	7,3	5,1	6,2	4,5	5,7	1,5
Gravier	0	1,6	14,1	64,7	2,7	4,3	4,8	4,8	3,0
Métal	4,3	0,9	3,4	4,8	79,1	1,6	4,8	0,6	0,4
PavésPierre	0,4	8,0	9,5	1,9	1,5	70,2	4,6	1,6	2,3
Shingle	7,6	7,3	6,3	3,9	5,5	9,6	58,5	0,2	1,0
Terre	0,7	3,8	4,2	2,9	1,5	0,2	1	83,1	2,6
Tuile	1,0	8,8	0	1,8	0,0	5,2	1,2	2,6	79,4

TABLE 9.8 – Bilan de classification pour un jeu optimal de 10 bandes issues du domaine VNIR (420-1000nm) pour la légende 1.

	SVM noyau gaussien			RF		
	Préc. util.	Préc. prod.	F-score	Préc. util.	Préc. prod.	F-score
Ardoise	97,5	100,0	98,7	84,1	95,4	89,3
Asphalte	89,6	87,7	88,6	66,9	62,6	64,5
Ciment	83,7	86,0	84,8	63,5	68,5	65,8
Gravier	87,8	93,5	90,5	69,6	64,7	67,0
Métal	93,5	90,1	91,7	80,1	79,1	79,5
PavésPierre	94,7	87,2	90,7	65,9	70,2	67,9
Shingle	93,2	92,4	92,7	66,2	58,5	61,9
Terre	94,9	96,9	95,9	81,6	83,1	82,3
Tuile	95,2	95,5	95,3	84,1	79,4	81,6
Moyennes	92,2	92,1	92,1	73,5	73,5	73,3
Kappa			91,1			70,2

### Comparaison avec la configuration spectrale de Pléiades

On a également sélectionné 4 bandes pour se confronter aux bandes d'un capteur multispectral existant (en l'occurrence Pléiades). On a aussi sélectionné 4 bandes dans le domaine VNIR et SWIR, afin de vérifier l'apport du SWIR, même lorsque peu de bandes sont sélectionnées.

On peut constater d'après les résultats obtenus (présentés dans les tableaux 9.9, 9.10 et 9.11, ainsi que la figure 9.9) que les 4 bandes sélectionnées dans le VNIR obtiennent de meilleures classifications qu'avec les bandes de Pléiades. En revanche, l'utilisation de bandes sélectionnées à la fois dans le VNIR et le SWIR permet une amélioration significative de la qualité des classifications, pour toutes les classes, et en particulier pour l'asphalte, les shingles, mais aussi pour les graviers et pavés en pierre.

On peut d'ailleurs constater qu'un jeu de 4 bandes bien choisies dans le VNIR et le SWIR donne des résultats sensiblement aussi bons, voire meilleurs (notamment dans le cas du classifieur RF) qu'un ensemble de 10 bandes sélectionnées uniquement dans le VNIR.



TABLE 9.9 – Bilan de classification pour un jeu optimal de 4 bandes issues du domaine VNIR (420-1000nm) pour la légende 1.

	SVM noyau gaussien			RF		
	Préc. util.	Préc. prod.	F-score	Préc. util.	Préc. prod.	F-score
Ardoise	97,5	100,0	98,7	85,1	95,8	90,1
Asphalte	77,1	80,8	78,8	66,5	61,3	63,6
Ciment	79,5	83,6	81,5	63,1	68,3	65,4
Gravier	85,6	91,4	88,4	69,3	65,5	67,3
Métal	91,8	88,9	90,3	79,9	79,3	79,5
PavésPierre	86,5	79,8	83,0	65,9	69,7	67,6
Shingle	86,6	80,3	83,3	65,9	58,9	61,9
Terre	94,4	95,3	94,8	82,0	83,2	82,6
Tuile	95,1	91,8	93,4	85,1	79,9	82,4
Moyennes	88,2	88,0	88,0	73,6	73,5	73,4
Kappa			86,5			70,2

TABLE 9.10 – Bilan de classification pour la légende 1 pour la configuration spectrale de Pléiades.

	SVM noyau gaussien			RF		
	Préc. util.	Préc. prod.	F-score	Préc. util.	Préc. prod.	F-score
Ardoise	93,8	100,0	96,8	80,2	92,9	86,0
Asphalte	72,0	79,5	75,5	54,9	51,5	52,9
Ciment	78,6	79,7	79,0	57,7	61,8	59,6
Gravier	84,4	91,2	87,7	63,7	57,5	60,4
Métal	90,1	88,7	89,4	78,6	75,9	77,2
PavésPierre	80,8	79,0	79,9	58,9	62,3	60,5
Shingle	87,0	71,0	78,1	58,7	51,9	54,9
Terre	92,8	94,7	93,7	74,9	76,2	75,5
Tuile	92,7	85,9	89,1	72,4	70,9	71,6
Moyennes	85,8	85,5	85,5	66,7	66,8	66,5
Kappa			83,7			62,6

TABLE 9.11 – Bilan de classification pour un jeu optimal de 4 bandes issues du domaine VNIR+SWIR pour la légende 1.

	SVM noyau gaussien			RF		
	Préc. util.	Préc. prod.	F-score	Préc. util.	Préc. prod.	F-score
Ardoise	96,2	100,0	98,0	84,9	96,2	90,1
Asphalte	86,7	83,8	85,1	78,2	70,4	73,9
Ciment	83,0	80,8	81,8	72,9	74,1	73,4
Gravier	93,0	95,2	94,1	84,6	84,7	84,6
Métal	93,9	95,9	94,9	89,9	87,2	88,4
PavésPierre	86,3	81,7	83,9	71,2	73,5	72,3
Shingle	92,0	91,9	91,9	77,5	74,3	75,8
Terre	93,7	98,6	96,1	89,3	92,4	90,8
Tuile	96,3	93,0	94,6	87,9	82,4	85,0
Moyennes	91,2	91,2	91,1	81,8	81,7	81,6
Kappa			90,1			79,4

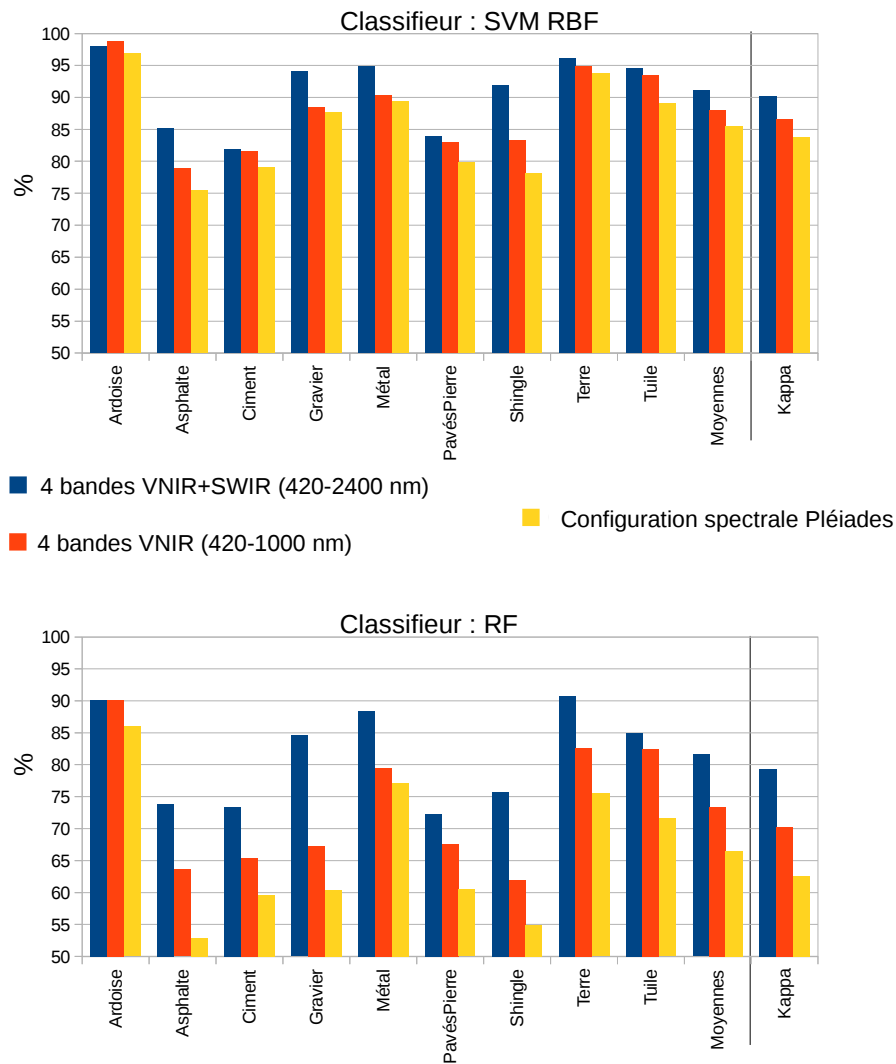


FIGURE 9.9 – Légende 1 : performances de classification pour les classifieurs SVM à noyau gaussien et RF pour différentes configurations spectrales de 4 bandes : jeu optimal de 4 bandes dans le domaine VNIR+SWIR (420-2400 nm), jeu optimal de 4 bandes dans le domaine VNIR (420-1000 nm) et configuration spectrale de Pléiades. Les F-Scores des différentes classes, ainsi que le F-Score moyen et le Kappa sont représentés.

### 9.2.2 Impact de la prise en compte ou non de la couleur des matériaux : sous-classes

On a pu voir que les classes pour lesquelles le plus de confusions se produisaient étaient l'asphalte, le ciment, les pavés en pierre et le shingle. Or ces classes sont également celles qui peuvent présenter des aspects différents notamment en terme de couleur. L'asphalte peut être rouge, gris ou noir selon sa couleur et son niveau d'usure. Les shingles sont de différentes couleurs. Le ciment va être plus ou moins clair, voire coloré.

Il était donc intéressant de voir l'impact de la prise en compte de la couleur, de l'état et de la matière sur la qualité de la classification. Pour ce faire, on a utilisé les jeux de bandes sélectionnées précédemment, et effectué les classifications en prenant cette fois en compte lors de l'apprentissage des sous-classes correspondant à différents aspects d'un matériau. On procède donc comme suit :

1. Apprentissage avec des sous classes correspondant à différentes couleurs ou aspects
2. Classification
3. Agrégation : fusion pour un même matériau des différentes sous-classes correspondant à ses différents aspects
4. Evaluation

Remarque : Il aurait aussi été possible de prendre en compte ces sous-classes pour la sélection des bandes (comme le faisait par exemple [Herold *et al.* 2003]), mais ces informations (couleur/état) ne sont pas disponibles pour tous les spectres, et l'on souhaitait exploiter pour ce travail de sélection de bandes le plus d'éléments possibles de la librairie spectrale collectée. Pour cette même raison, ces informations ne sont utilisées ici que pour l'apprentissage; elles sont en revanche absentes pour les échantillons que l'on classe, d'où l'agrégation des sous-classes en classe de matériaux à l'issue de la classification et juste avant l'évaluation.

Les différentes sous-classes définies sont les suivantes :

- Asphalte : gris ; noir ; gris très foncé ; rouge
- Ciment : gris ; clair ; rouge ; sombre
- Métal : acier ; acier rouillé ; aluminium ; cuivre
- Shingle : clair ; foncé ; rouge
- Tuile : ciment ; terre cuite

Les résultats obtenus pour une sélection de 10 bandes dans le VNIR+SWIR sont présentés dans le tableau 9.12. On assiste donc à une légère dégradation dans le cas du classifieur SVM et à une amélioration peu importante dans le cas du classifieur RF. Certaines classes comme l'asphalte ou les shingles tendent toutefois à être moins bien traitées : des shingles sont classés comme de l'asphalte. Ceci s'explique vraisemblablement par le fait que certains shingles ne font en fait pas partie des sous-classes de couleur qui ont été définies et sont alors mal classés. Le modèle de classification obtenu est dans ce cas moins générique que celui obtenu pour une seule classe.

Les résultats obtenus pour une sélection de 10 bandes dans le VNIR sont présentés dans le tableau 9.13. On observe peu d'impact sur les résultats obtenus par un classifieur SVM. En revanche, une nette amélioration globale est alors observée dans le cas du classifieur RF. Toutefois, ce résultat est à nuancer, car les précisions producteur et utilisateur tendent à être déséquilibrées pour plusieurs classes, en particulier pour l'asphalte, les shingles et le ciment. Ce déséquilibre traduit des phénomènes de sous-détection ou sur-détection sur ces classes. La prise en compte de sous-classes a donc conduit à une amélioration des résultats globaux, mais à des résultats plus nuancés pour certaines classes.

TABLE 9.12 – Bilan de classification pour un jeu optimal de 10 bandes issues du domaine VNIR+SWIR pour la légende 1, à partir d’un apprentissage utilisant des sous-classes.

	SVM noyau gaussien			RF		
	Préc. util.	Préc. prod.	F-score	Préc. util.	Préc. prod.	F-score
Ardoise	97,9	100,0	98,9	97,2	97,6	97,4
Asphalte	89,9	92,9	91,4	71,9	91,4	80,5
Ciment	89,2	86,2	87,6	72,4	76,7	74,5
Gravier	93,5	97,7	95,5	94,6	85,4	89,8
Métal	97,0	96,7	96,8	86,4	98,0	91,8
PavésPierre	92,2	87,8	89,9	75,1	74,1	74,6
Shingle	98,7	94,6	96,6	92,7	62,9	75,0
Terre	95,7	98,7	97,1	89,9	94,0	91,9
Tuile	98,0	98,9	98,4	93,5	85,6	89,3
Moyennes	94,6	94,8	94,7	85,9	85,1	85,0
Kappa			94,0			83,2

TABLE 9.13 – Bilan de classification pour un jeu optimal de 10 bandes issues du domaine VNIR pour la légende 1, à partir d’un apprentissage utilisant des sous-classes.

	SVM noyau gaussien			RF		
	Préc. util.	Préc. prod.	F-score	Préc. util.	Préc. prod.	F-score
Ardoise	97,5	100	98,7	90,0	93,3	91,6
Asphalte	85,3	89,3	87,2	62,5	80,4	70,3
Ciment	83,1	85,6	84,2	59,4	76,9	67,0
Gravier	88,8	93,1	90,9	72,1	71,6	71,8
Métal	93,7	90,6	92,0	84,2	84,1	84,1
PavésPierre	94,9	85,5	90,0	74,4	65,3	69,6
Shingle	93,2	91,3	92,2	76,1	55,8	64,4
Terre	95,7	96,6	96,1	88,2	80,1	83,9
Tuile	97,6	96,0	96,8	89,3	77,6	83,1
Moyennes	92,2	92,0	92,2	77,3	76,1	76,2
Kappa			91,2			73,2

### 9.2.3 Sélection de bandes individuelles pour la légende 1 pour une résolution constante de 1 nm

Tout comme dans les expériences précédentes, 10 bandes ont été sélectionnées. Les profils d’importance associés aux différentes bandes ainsi que les jeux de bandes sélectionnés par différentes itérations de l’algorithme génétique sont visibles sur la figure 9.10. On peut constater que ces résultats sont assez semblables à ceux obtenus précédemment pour des bandes d’une largeur de 10 nm.

Les résultats quantitatifs globaux (présentés dans le tableau 9.14) obtenus à la résolution spectrale de 1 nm sont assez proches de ceux obtenus précédemment (voire légèrement inférieurs, surtout dans le cas des SVM). Néanmoins, pour certaines classes, on observe des améliorations ou des diminutions plus significatives (mais pas nécessairement pour les deux classifieurs). Par exemple, les pavés en pierre sont nettement moins bien traités par les SVM à la résolution de 1

nm qu'à 10 nm, tandis que cette dégradation n'est pas très importante pour les RF. A l'inverse, les métaux sont nettement mieux traités par les RF à la résolution de 1 nm qu'à celle de 10 nm, alors qu'aucune amélioration, ni dégradation n'est observée pour les SVM.

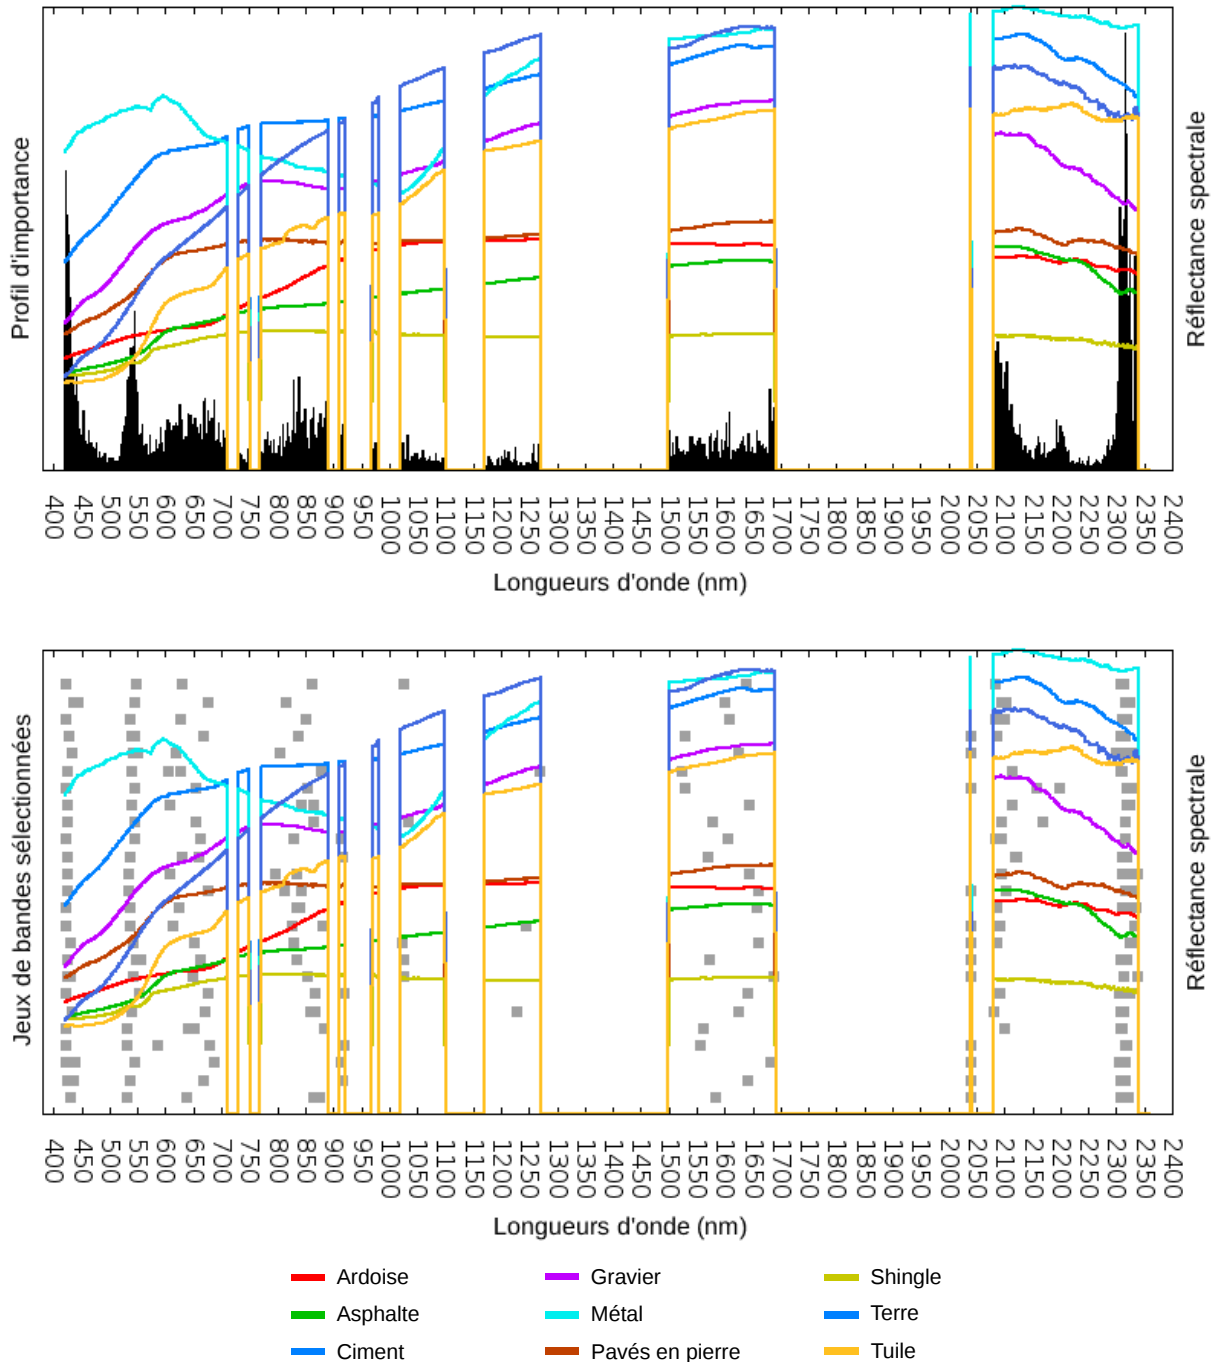


FIGURE 9.10 – Légende 1 : profil d'importance de bandes (en haut) calculé pour une sélection de 10 bandes dans le domaine VNIR+SWIR à la résolution de 1 nm et sélections obtenues (en bas) pour différentes itérations de l'algorithme génétique

TABLE 9.14 – Bilan de classification pour un jeu optimal de 10 bandes issues du domaine VNIR+SWIR à la résolution spectrale de 1 nm pour la légende 1

	SVM noyau gaussien			RF		
	Préc. util.	Préc. prod.	F-score	Préc. util.	Préc. prod.	F-score
Ardoise	96,9	100,0	98,4	91,6	97,8	94,6
Asphalte	94,2	90,2	92,1	80,1	72,3	75,9
Ciment	90,1	91,3	90,7	76,7	77,1	76,9
Gravier	94,9	98,3	96,6	85,1	88,3	86,6
Métal	98,3	96,2	97,2	94,4	90,2	92,2
PavésPierre	92,3	87,9	90,0	71,5	77,6	74,4
Shingle	96,6	97,2	96,9	79,5	77,9	78,6
Terre	96,2	98,9	97,5	90,5	94,9	92,6
Tuile	97,8	97,1	97,4	91,9	84,1	87,8
Moyennes	95,3	95,2	95,2	84,6	84,4	84,4
Kappa			94,6			82,5

#### 9.2.4 Sélection de bandes fusionnées pour la légende 1

On s'est également intéressé au fait de savoir s'il était possible d'utiliser des bandes plus larges. Les algorithmes présentés au chapitre 7 ont donc été appliqués au jeu de données de résolution spectrale 10 nm correspondant à la légende 1. Le critère utilisé pour la construction de la hiérarchie de bandes fusionnées correspondait à l'erreur de reconstruction des spectres par une fonction constante par morceaux. La hiérarchie de bandes fusionnées obtenue est présentée sur la figure 9.11. Les bandes des régions 1150-1250 nm, 1500-1700 nm et 2100-2150 nm se rassemblent assez vite en bandes plus larges. Les spectres des différentes classes sont en effet assez plats dans cette zone. A l'inverse, les régions 420-600 nm (visible) et 2250-2350 nm ont tendance à n'être fusionnées que plus tardivement.

Les configurations spectrales de bandes contiguës de largeur variable correspondant aux différents niveaux de la hiérarchie ont été évaluées, à partir des résultats d'une classification par un classifieur SVM 1-contre-1 avec noyau gaussien optimisé. Le coefficient Kappa, le F-score moyen sur l'ensemble des classes ainsi que le F-score minimal (correspondant à la classe la plus mal traitée) ont été calculés et sont présentés sur la figure 9.12. Différentes configurations spectrales permettent d'obtenir des résultats équivalents (au sens de ces 3 mesures qui apparaissent généralement corrélées) à la résolution spectrale originale : certaines de ces configurations dégradent les performances, tandis que d'autres les améliorent légèrement, mais on reste dans les mêmes ordres de grandeurs. La dégradation qui se produit lorsque l'on passe en dessous de 90 bandes fusionnées correspond à la fusion de bandes originales dans le domaine 2250-2350 nm. L'amélioration observée lorsque l'on passe en dessous de 40 bandes correspond à la fin des fusions des dernières bandes individuelles du visible. Les performances un peu moins inférieures entre ces deux événements correspondent donc vraisemblablement à une sur-représentation de bandes issues du visible dans cette série de configurations spectrales.

En revanche, les performances de classification diminuent assez fortement lorsque les configurations spectrales comportent moins de 22 bandes, c'est-à-dire lorsqu'elles commencent à n'être plus composées que de bandes trop larges causant la perte d'une information utile.




FIGURE 9.11 – Légende 1 : hiérarchie de bandes fusionnées obtenue pour le critère de fusion “erreur de reconstruction du spectre” L’abscisse correspond aux numéros/longueur d’onde des bandes. L’axe des ordonnées correspond aux niveaux dans la hiérarchie de bandes fusionnées (en bas : niveau le plus fin avec les bandes originales, en haut : une bande fusionnée unique). Les lignes noires verticales sont les limites entre bandes fusionnées : plus on monte dans la hiérarchie, plus le nombre de bandes fusionnées diminue. Les spectres médians des classes en présence sont affichés en couleur.




FIGURE 9.12 – Légende 1 : évolution de la qualité de la classification par un SVM à noyau gaussien pour les différentes configurations spectrales de la hiérarchie de bandes fusionnées de la figure 9.11 (abscisse = nombre de bandes fusionnées dans la configuration spectrale)



L'algorithme de méthode de bandes SFFS adapté à la hiérarchie (présenté dans la section 7.5) a ensuite été mis en œuvre. Un jeu de 10 bandes a donc été sélectionné au sens du score *rf.conf* à chaque niveau de la hiérarchie. Ces jeux de bandes sont présentés sur la figure 9.13. Les parties du spectre sélectionnées restent assez stables dans certains domaines (notamment dans le visible et le domaine 1500-2400nm du SWIR), mais sont plus instables dans le proche infra-rouge (750-1050 nm).

De la même manière que précédemment, ces jeux de bandes ont été évalués à partir des résultats d'une classification par un classifieur SVM 1-contre-1 avec noyau gaussien optimisé. L'évolution du coefficient Kappa, du F-score moyen et du F-score le plus faible est présenté sur la figure 9.14. Cette fois, l'apport de l'utilisation de bandes fusionnées n'est pas évident. Certaines configurations améliorent légèrement la classification, tandis que d'autres la dégradent. Les scores obtenus restent toutefois dans les mêmes ordres de grandeur (<1%). Il est donc possible de travailler avec des bandes plus larges que la résolution originales de 10 nm.

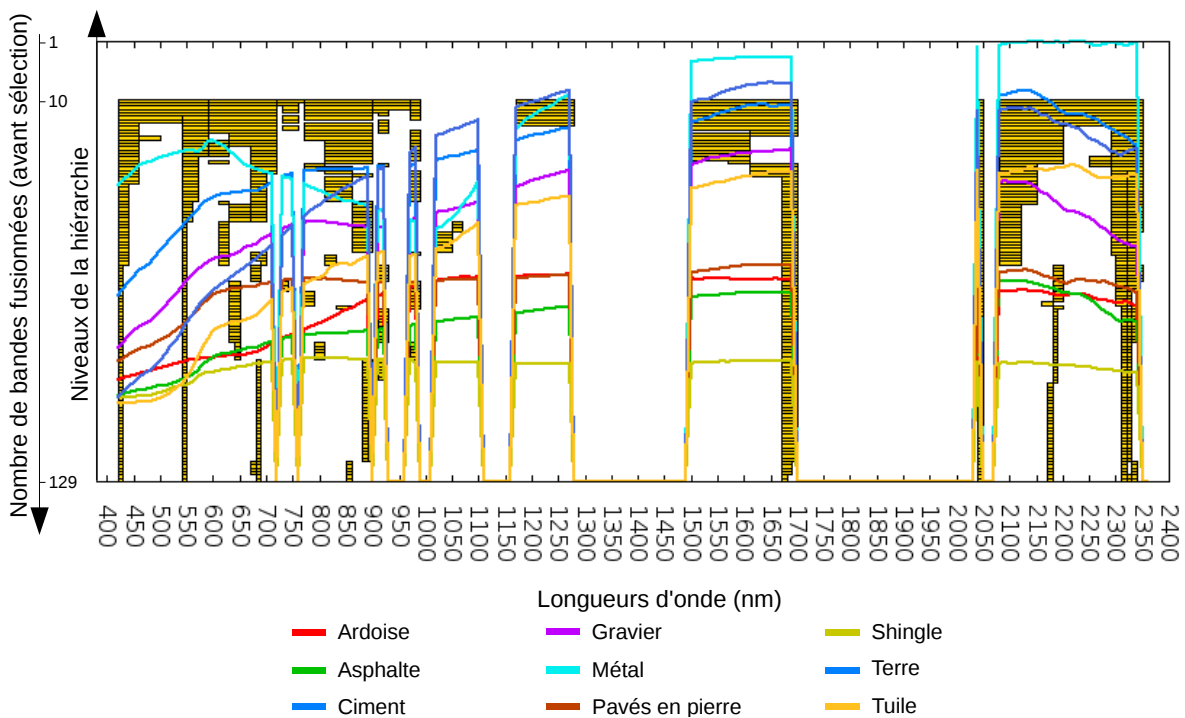


FIGURE 9.13 – Légende 1 : jeux de 10 bandes sélectionnés (en utilisant l'approche SFFS adaptée) aux différents niveaux de la hiérarchie de bandes fusionnées de la figure 9.11. Chaque ligne correspond à un niveau de la hiérarchie, les rectangles jaunes correspondant alors aux bandes sélectionnées à ce niveau. L'abscisse correspond aux numéros/longueur d'onde des bandes. L'axe des ordonnées correspond aux niveaux dans la hiérarchie de bandes fusionnées (en bas : niveau le plus fin avec les bandes originales, en haut : une bande fusionnée unique). Les spectres médians des classes en présence sont affichés en couleur.

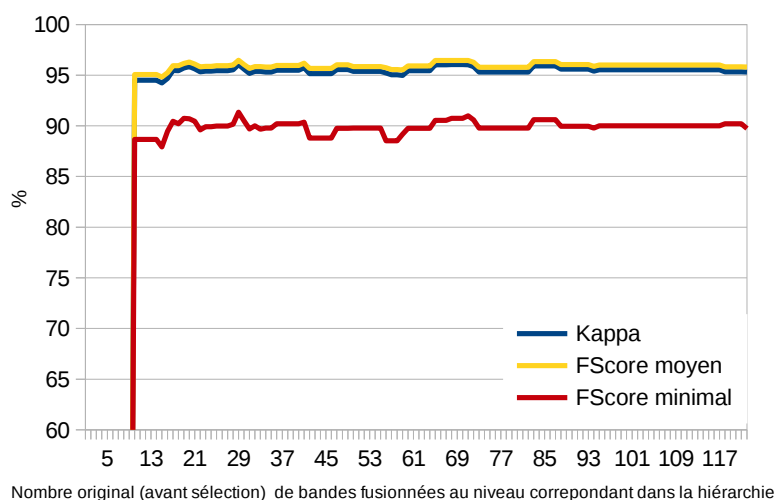


FIGURE 9.14 – Légende 1 : évolution de la qualité de la classification par un SVM à noyau gaussien pour les jeux de 10 bandes sélectionnés (en utilisant l’approche SFFS adaptée) aux différents niveaux de la hiérarchie de bandes fusionnées de la figure 9.11 (abscisse = nombre de bandes fusionnées initiales, avant sélection)

### 9.2.5 Sélection de bandes individuelles pour la légende 2 pour une résolution constante de 10 nm

L’évolution du score de sélection d’attributs *rf.conf* et de la qualité de la classification obtenue en utilisant un classifieur SVM avec noyau gaussien en fonction du nombre de bandes était sensiblement la même pour la légende 2 que pour la légende 1. Aussi on a également sélectionné 10 bandes pour cette seconde légende.

Les profils d’importance associés aux différentes bandes (par application de l’algorithme génétique pour une sélection de 10 bandes) ainsi que les jeux de bandes sélectionnés par différentes itérations de l’algorithme génétiques sont visibles sur la figure 9.15. Ces résultats sont également assez similaires à ceux obtenus pour la légende 1, à la différence que la partie du spectre comprises entre 1000 et 1100 nm est un peu plus importante tandis que celle entre 1150 et 1300 nm continue à ne pas être considérer comme intéressante par l’algorithme. La partie entre 1500 et 1700 nm est un peu plus lissée et 2 blobs tendent à s’y dessiner. Le blob situé vers 2200 nm tend aussi à mieux se détacher.

Si l’on s’intéresse aux résultats quantitatifs (tableau 9.15), certaines classes comme les tuiles et la terre sont mieux traitées que pour la légende 1, tandis que les ciments et l’asphalte sont moins bien traités, en particulier pour le classifieur RF. On remarque surtout que les classes ajoutées par rapport à la légende 1 sont généralement très bien classées, notamment l’amiante et les fibrociments (au détriment de la classe des ciments dont certains échantillons tendent à être affectés à ces classes, surtout dans le cas du classifieur RF). Or, ces classes étaient très peu représentées dans la librairie spectrale. Les résultats obtenus sont donc à nuancer : la solution proposée de générer des spectres supplémentaires par application d’un facteur multiplicatif aléatoire ne permet pas de tenir compte de la véritable variabilité des matériaux, qui n’affecte pas nécessairement de manière identique les différentes parties du spectre (cela a par exemple été montré dans le cas de revêtements routiers asphaltés par [Herold *et al.* 2004b, Mohammadi 2012]). Dans ces conditions, il peut être difficile de mesurer dans quelle mesure on ne tombe pas dans du sur-ajustement.

On a également effectué une classification pour la légende 2, mais en utilisant le jeu de bandes sélectionnées pour la légende 1. Les résultats sont présentés dans le tableau 9.16 et montrent que le jeu de bandes optimisé pour la légende 1 est également adapté au cas de la légende 2. Les différences entre cette classification et celle obtenue pour le jeu de bandes optimisé pour la légende 2 ne sont en effet pas significatives. Le seul changement notable concerne les métaux qui sont mieux traités par le classifieur RF pour le jeu de bandes optimisé pour la légende 2.

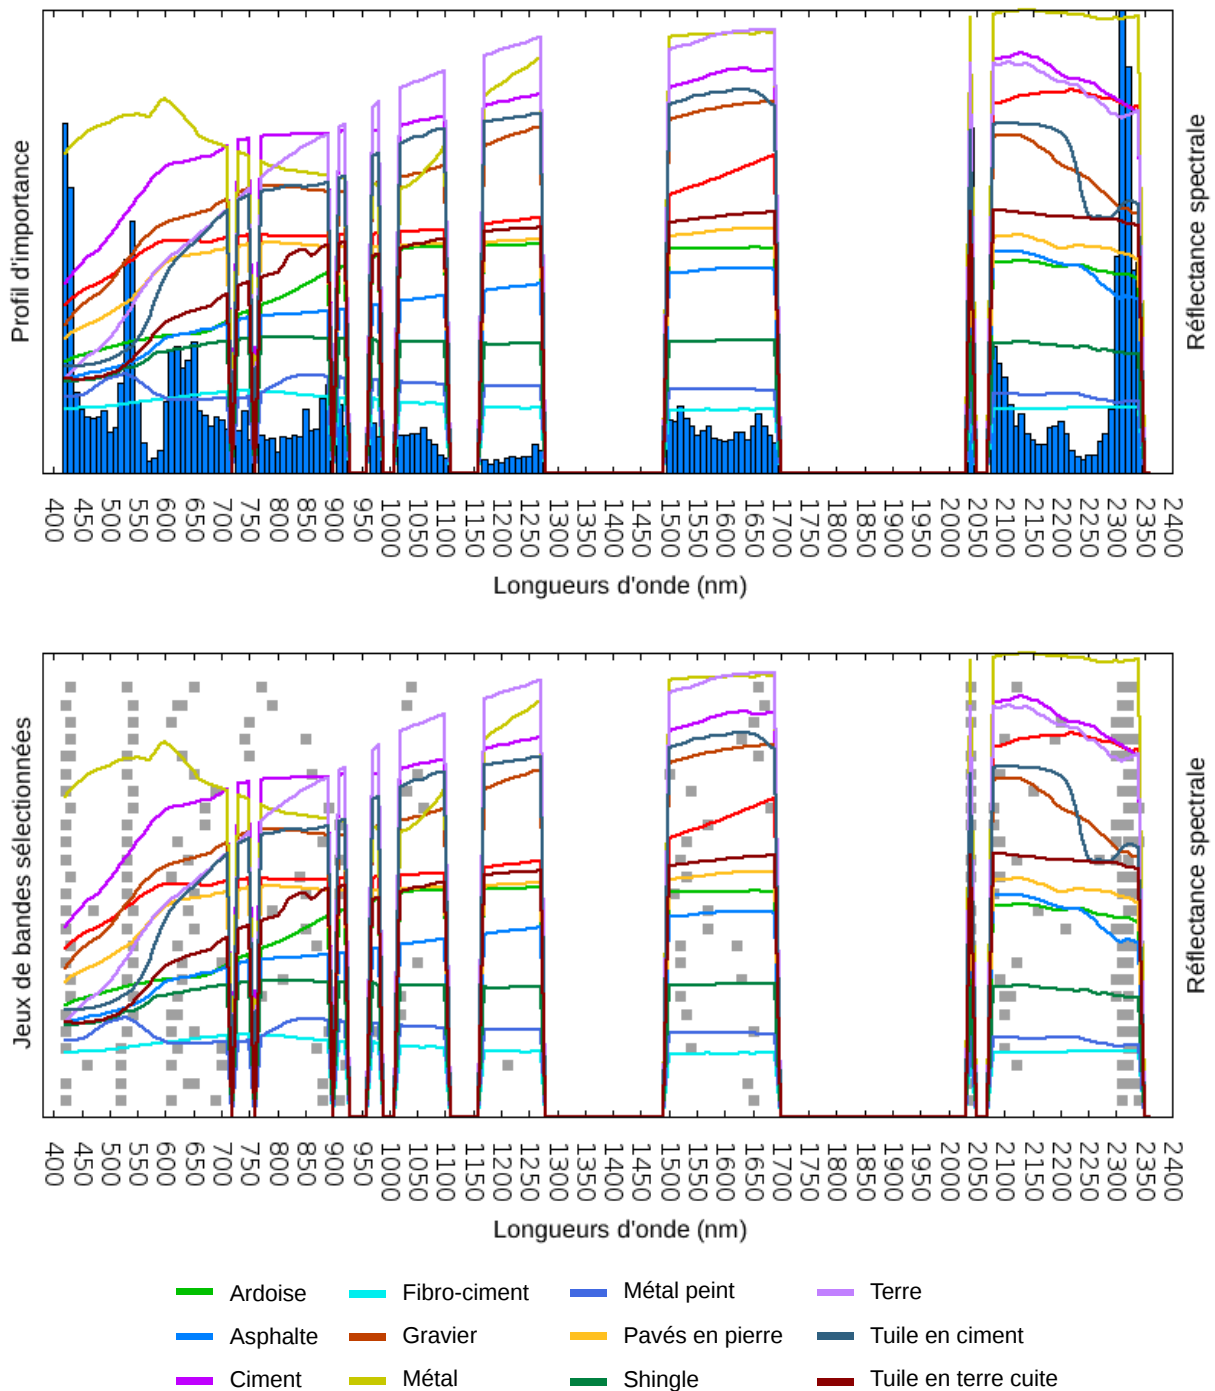


FIGURE 9.15 – Légende 2 : profil d'importance de bandes (en haut) calculé pour une sélection de 10 bandes dans le domaine VNIR+SWIR et sélections obtenues (en bas) pour différentes itérations de l'algorithme génétique

TABLE 9.15 – Bilan de la classification pour un jeu optimal de 10 bandes issues du domaine VNIR+SWIR pour la légende 2

	SVM noyau gaussien			RF		
	Préc. util.	Préc. prod.	F-score	Préc. util.	Préc. prod.	F-score
Amiante	99,1	100,0	99,6	93,4	98,3	95,8
Ardoise	97,9	100,0	98,9	92,0	96,4	94,1
Asphalte	95,0	90,7	92,8	79,0	72,0	75,3
Ciment	92,2	85,1	88,5	78,1	68,3	72,8
Fibrociment	99,2	100,0	99,6	93,5	99,5	96,4
Gravier	96,1	98,8	97,4	85,8	87,9	86,7
Métal	97,0	99,0	98,0	94,2	90,0	92,0
MétalPeint	100,0	99,9	99,9	98,3	98,9	98,6
PavésPierre	94,0	92,3	93,2	75,1	75,5	75,3
Shingle	97,8	97,5	97,6	78,6	76,3	77,4
Terre	95,4	99,6	97,5	92,1	95,1	93,5
TuileCiment	99,2	100,0	99,6	89,4	94,5	91,8
TuileTerreCuite	98,7	99,0	98,9	94,9	93,7	94,2
Moyennes	97,1	97,1	97,0	88,0	88,2	87,1
Kappa			96,8			87,2

TABLE 9.16 – Bilan de la classification pour la légende 2 en utilisant le jeu optimal de 10 bandes issues du domaine VNIR+SWIR sélectionné pour la légende 1

	SVM noyau gaussien			RF		
	Préc. util.	Préc. prod.	F-score	Préc. util.	Préc. prod.	F-score
Amiante	99,6	100	99,8	93,2	97,9	95,5
Ardoise	97,5	100	98,7	91,9	97,0	94,3
Asphalte	94,5	90,8	92,6	79,7	71,5	75,4
Ciment	91,9	85,9	88,8	77,6	69,6	73,3
Fibrociment	99,7	100,0	99,9	93,1	99,5	96,1
Gravier	95,8	98,9	97,4	87,1	87,8	87,4
Métal	96,7	98,8	97,7	93,9	88,1	90,9
MétalPeint	100,0	100,0	100,0	96,9	98,3	97,6
PavésPierre	94,5	91,3	92,8	74,8	75,6	75,2
Shingle	97,3	97,3	97,3	79,1	75,9	77,4
Terre	95,3	99,4	97,3	92,4	95,7	94,0
TuileCiment	99,1	99,9	99,5	88,2	94,6	91,2
TuileTerreCuite	99,4	99,3	99,4	95,2	93,5	94,3
Moyennes	97,0	97,0	97,0	87,9	88,1	87,9
Kappa			97,1			87,1

### 9.2.6 Bilan

Au vu des différentes expériences effectuées, on a vérifié qu'un jeu limité de bandes spectrales (environ 10) est suffisant pour la discrimination des matériaux des deux légendes testées. Utiliser davantage de bandes n'a que très peu d'influence sur la qualité des résultats obtenus.

L'apport de l'utilisation de bandes appartenant au domaine spectral du SWIR est confirmé. En effet, à nombre égal de bandes sélectionnés, les résultats obtenus en utilisant des configurations spectrales comportant des bandes appartenant à la fois au VNIR et au SWIR fournissent des classifications significativement meilleures que celles composées exclusivement de bandes issues du domaine VNIR (420-1000 nm). Ceci a été vérifié à la fois pour des jeux de 10 et de 4 bandes. On a d'ailleurs pu constater qu'un jeu de 4 bandes bien choisies dans le VNIR et le SWIR permettait d'obtenir des résultats sensiblement aussi bons, voire meilleurs (notamment dans le cas du classifieur RF) qu'un ensemble de 10 bandes sélectionnées uniquement dans le VNIR. Il a aussi été constaté que les différentes configurations spectrales composées de bandes issues exclusivement du VNIR avaient tendance à dégager 4 ou 5 groupes de bandes au sein desquels des bandes adjacentes sont sélectionnées, le reste du spectre ayant tendance à être ignoré.

La sélection de bandes individuelles a été effectuée à la fois pour des résolutions spectrales de 10 nm et de 1 nm. Les configurations spectrales proposées dans les 2 cas restent assez semblables. De même, les indicateurs de qualité des classifications obtenues dans ces 2 cas restent assez proches. Si pour certaines classes, on peut observer des améliorations ou des diminutions plus significatives selon que l'on travaille à une résolution de 10 ou 1 nm, elles ne sont pas forcément les mêmes selon le classifieur utilisé. Une résolution plus fine (1nm) serait peut-être intéressante pour diagnostiquer des phénomènes plus fins (comme par exemple, le niveau de dégradation de certains matériaux), mais n'apparaît pas comme nécessaire dans le cas présent de discrimination des différents matériaux.

On s'est également intéressé au fait de savoir s'il était possible d'utiliser des bandes plus larges.

Ces expériences de sélection de bandes ont toutes été effectuées pour le même critère basé sur la confiance d'un classifieur RF. Un tel classifieur est à même de gérer dans une certaine mesure l'existence d'une variabilité intra-classe. Par ailleurs, dans le cas où l'on sélectionnait des bandes à la fois dans le VNIR et le SWIR, il était également intéressant de ne pas s'arrêter à des distinctions de couleur de matériaux ; en effet, les couleurs étant spécifiques au domaine visible et rien n'interdisait l'existence dans le domaine infra-rouge de bandes discriminantes par rapport aux autres classes et pour lesquelles un même matériau de différentes couleurs répond de manière unique. Aussi, n'a-t-on pas pris en compte de sous-classes lors des expériences d'optimisation spectrale.

Il était toutefois intéressant de voir dans quelle mesure la prise en compte des sous-classes correspondant à différents aspects de mêmes matériaux pouvait améliorer les résultats de classification pour une configuration spectrale donnée. Il est alors apparu que la prise en compte de sous-classes lors de l'apprentissage améliorait les résultats de la classification uniquement dans le cas du classifieur RF principalement pour des bandes issues exclusivement du VNIR. Cette amélioration concernait les résultats globaux, mais pouvait conduire à des résultats plus nuancés pour certaines classes.

Une expérience de sélection de bandes a également été tentée pour une nomenclature un peu plus détaillée. Toutefois, les nouvelles classes étaient généralement décrites par très peu de spectres dans la librairie spectrale collectée. Il est ensuite apparu que ces classes étaient généralement très bien détectées lors de la classification. Les résultats obtenus sont donc à nuancer : la solution proposée de générer des spectres supplémentaires par application d'un facteur multiplicatif aléatoire ne permet pas de tenir compte de la véritable variabilité des matériaux, qui n'affecte pas nécessairement de manière identique les différentes parties du spectre. Aussi des classes décrites par peu de spectres dans la base de données sont plus faciles à retrouver pour le classifieur, car présentant une variabilité moindre dans le jeu de données test généré.

## Cinquième partie

### Conclusion



## Chapitre 10

# Bilan et perspectives

Le travail réalisé s’inscrivait dans la perspective d’enrichissement de la connaissance de l’occupation du sol. Il est en effet apparu que la modélisation fine du milieu urbain nécessitait pour certaines applications une connaissance géospatiale des matériaux en présence, autrement dit de carte de matériaux. De telles cartes pourraient dès lors constituer une couche supplémentaire, à la fois dans des bases de données sur l’occupation du sol (comme par exemple l’occupation du sol à grande échelle de l’IGN) et dans des maquettes urbaines 3D (comme par exemple celles produites par la chaîne BATI3D).

Des applications potentielles pour des cartes de matériaux ont été recensées au chapitre 1. Elles demeurent toutefois assez diverses, certaines nécessitant une connaissance des différents matériaux en présence sur une zone donnée, d’autres se focalisant sur un matériau particulier, voire sur son état. De même, certaines de ces applications nécessitent une véritable carte précise géométriquement, tandis que d’autres se contentent des proportions des différents matériaux en présence au sein de mailles plus ou moins larges. Les besoins en terme de cartes de matériaux sont donc à cette heure encore assez divers et parfois très spécialisés.

Toutefois, aucune base de données existante ne contient actuellement une telle information. Aussi, la télédétection apparaît comme la seule solution permettant de la produire. Néanmoins, du fait de la forte hétérogénéité des matériaux en présence, de leur variabilité, mais aussi des fortes ressemblances entre classes distinctes, il apparaît que les capteurs optiques multispectraux “classiques” (ne comportant que les 4 canaux rouge - vert - bleu -proche infrarouge) ne sont pas suffisants pour garantir une bonne discrimination des matériaux. Un capteur multispectral, voire superspectral, plus riche spectralement pourrait donc apporter une solution à cette limite.

Le travail mené a donc consisté à identifier la meilleure configuration spectrale, ou du moins à proposer des solutions s’en approchant, pour la classification des matériaux urbains, c’est-à-dire à mener à bien un travail d’optimisation spectrale. Pour ce faire, des méthodes de sélection automatique d’attributs ont été mises en œuvre. Un premier travail a donc consisté à définir et préciser ces méthodes, et à les valider sur des jeux de données de la littérature. La seconde partie du travail a consisté en l’application de ces algorithmes d’optimisation spectrale au cas d’étude des matériaux urbains.

### 10.1 Mise en place d’outils d’optimisation spectrale

Contrairement à nombre de cas d’applications des méthodes de sélection d’attributs utilisées comme pré-traitement d’un processus de classification, nous n’avons pas ici de véritables contraintes quant aux temps de calcul. Il a dès lors été possible d’utiliser des heuristiques d’optimisation classiques associées à des critères de type filtre ou *wrapper*. Deux heuristiques classiques ont été choisies du fait de leur généricité et de leur flexibilité, et donc de leur capacité à être utilisées avec différents critères de sélection d’attributs, voire à intégrer et à être guidées par différents



critères. Il s'agissait d'une part de l'algorithme SFFS, méthode séquentielle utilisée ici pour étudier l'impact du nombre de bandes sélectionnées sur la qualité de la classification, et d'autre part d'un algorithme génétique, méthode stochastique permettant pour un nombre de bandes à sélectionner fixe, d'explorer plusieurs solutions proches de la solution optimale.

Un travail méthodologique a alors été mené afin d'identifier le meilleur critère à utiliser pour mesurer la pertinence d'un jeu de bandes, autrement dit pour définir le score à optimiser lors du processus de sélection de bandes. Une comparaison de différents scores possibles, aussi bien filtre que *wrapper* ou *embedded*, a été effectuée. Les meilleurs scores identifiés sont, d'une part, un score de type filtre avec la mesure de Jeffries-Matusita, et, d'autre part, deux scores de type *wrapper* associés à un classifieur et prenant en compte la confiance avec laquelle le classifieur labellise les échantillons, autrement dit des scores *wrapper* ne se limitant pas à de simples taux de bonne classification.

Plusieurs critères ont été pris en compte pour comparer ces scores. Ces scores devaient conduire à des jeux de bandes les plus discriminants possible, et ceci de manière indépendante d'un classifieur particulier. Les solutions proposées devaient donc être discriminantes pour la plupart des classifieurs et non simplement au sens du critère de sélection d'attributs utilisé. Leur parcimonie, à savoir leur capacité à obtenir les meilleurs résultats avec le moins de bandes possible, a également été prise en compte. Par ailleurs, la stabilité des solutions proposées et, lorsque cela était possible, la signification des bandes sélectionnées par rapport aux spectres des classes ont aussi été prises en compte de manière qualitative par l'étude de profils d'importance des bandes générés à partir des résultats intermédiaires de l'algorithme génétique.

On s'est ensuite intéressé au problème de l'optimisation de la largeur des bandes. La méthode mise en œuvre a consisté d'abord à construire une hiérarchie de bandes fusionnées. Différents critères de fusion ont été testés, permettant de rassembler les bandes les plus "similaires". Différentes configurations spectrales peuvent ensuite être testées au sein de cette hiérarchie.

Les apports de cette étude sont les suivants :

- Une comparaison de critères pour la sélection d'attributs a été menée. L'approche mise en place pour les comparer est assez originale dans le sens où elle les évalue à la fois de manière quantitative (par le biais des taux de bonne classification obtenus par différents classifieurs pour les configurations spectrales optimisées au sens des différents critères), mais également qualitative en s'intéressant au comportement des sélections proposées par le biais de profils d'importance des bandes au sens des différents scores de sélection d'attributs testés. On notera toutefois que même si les configurations spectrales proposées sont différentes, la plupart des scores testés permettent d'atteindre, du point de vue de l'évaluation quantitative, des taux de bonne classification ne présentant pas de différences significatives.
- Une mesure d'importance des bandes calculée à partir des résultats intermédiaires d'un algorithme génétique a été proposée. On obtient alors des profils d'importance de bandes qui permettent de constater visuellement quelles parties du spectre sont importantes. Notre intention initiale était également d'utiliser ensuite ces profils d'importance pour définir les bandes larges en les croisant avec des informations de corrélation entre bandes.
- Des critères de type *wrapper* pour la sélection d'attributs ont été proposés : ces critères sont associés à un classifieur et prennent en compte la confiance avec laquelle ce classifieur classe les échantillons. Ils ne se limitent donc pas comme la plupart des scores *wrapper* à un simple taux de bonne classification. Cela nous donne un score intermédiaire entre les séparabilités de type filtre et les scores taux de bonne classification *wrapper* classiques. Lors du parangonnage des différents scores de sélection d'attributs, ces scores notamment associés à un classifieur RF sont apparus comme étant parmi les meilleurs critères.

- Une approche hiérarchique a été proposée pour la sélection de bandes larges. Cette stratégie permet de contrôler la croissance de la largeur des bandes, en ne basant pas tout le processus sur le critère de sélection d’attribut, mais en intégrant également des contraintes sur la similarité entre bandes par le biais d’un critère de fusion. On commence donc par construire une hiérarchie de bandes fusionnées, en fusionnant de proche en proche les bandes adjacentes selon un critère. Trois de ces critères de fusion ont été testés, visant à fusionner les bandes en considérant leur corrélation, leur contribution à la séparabilité entre les classes, ou leur impact sur la forme du spectre. Les deux derniers se sont avérés meilleurs que le premier. La sélection de bandes fusionnées se déroule ensuite au sein de la hiérarchie de configurations spectrales produite.

A l’issue de ce travail se dessinent plusieurs perspectives.

- Dans le cadre du parangonnage de critères pour la sélection d’attributs, nous nous sommes limités à des critères compatibles avec les heuristiques d’optimisation générique mises en œuvre. Certaines méthodes de sélection d’attributs de type *embedded*, pour lesquelles le score à optimiser et la méthode d’optimisation sont liés, n’ont donc pas été testées, comme par exemple [Tuia *et al.* 2014b]. Ces méthodes sont assez récentes et plus rapides que celles utilisées ici. (Rappelons toutefois que le temps de calcul n’était pas une contrainte dans notre cas.) Il serait donc intéressant d’intégrer quelques uns de ces algorithmes dans notre comparatif. Par ailleurs, une approche comme celle de [Tuia *et al.* 2014b], plus rapide, serait bien adaptée lors de l’étape d’optimisation de la largeur des bandes pour tester un nombre plus important de bandes fusionnées possibles, et donc davantage de configurations spectrales. Cette approche consisterait, à chaque itération, à générer aléatoirement une bande fusionnée, et à tester si, une fois ajoutée au jeu de bandes déjà sélectionnées elle contribue à l’amélioration de la qualité du modèle (inspiré d’un SVM en norme L1). Le cas échéant, cette bande est conservée dans la sélection. Les bandes déjà sélectionnées et contribuant insuffisamment à la qualité du modèle peuvent aussi être supprimées.
- Une autre perspective de travail déjà mentionnée concerne également l’optimisation des bandes fusionnées. L’approche qui a été mise en œuvre est l’approche hiérarchique présentée plus haut. Notre intention originale était aussi de tester une méthode alternative exploitant les profils d’importance des bandes générés à partir des résultats de l’algorithme génétique appliqué aux bandes individuelles. En effet, lorsque l’on observe ces profils, on constate visuellement la présence de “blobs” correspondant à des groupes de bandes le long de ces profils. Il est donc tentant de les détecter de manière automatique. Une solution possible pourrait consister à utiliser conjointement ces profils d’importance et la similarité (ou la corrélation) entre les bandes. Cette première information nous apporterait un renseignement sur les zones du spectre à sélectionner (terme d’attache à la donnée), tandis que la seconde inciterait à fusionner ou non des bandes voisines (terme de régularisation). De premiers tests dans ce sens avaient été effectués par des méthodes très simples [Najjar 2013, Chehata *et al.* 2014] à partir de profils d’importances des bandes issues de méthodes de type filtre.

## 10.2 Application au cas d’étude des matériaux urbains

Dans cette seconde partie, les algorithmes et critères de sélection de bandes définis dans la partie précédente ont été mis en œuvre pour l’identification des meilleures configurations spectrales pour la classification des matériaux. On cherchait à identifier plusieurs éléments : le nombre de bandes utiles, leur position dans le spectre, en particulier de savoir si l’utilisation de bandes situées dans le domaine SWIR permet d’améliorer la distinction des matériaux et dans quelle

mesure.

Une difficulté importante rencontrée dans cette partie était celle de la disponibilité de données sur lesquelles effectuer cette optimisation spectrale. Il était initialement prévu d'effectuer ce travail à partir d'images hyperspectrales aéroportées acquises au cours de la campagne [Adeline *et al.* 2013b], mais la disponibilité tardive de ces données nous a conduit à adopter une autre stratégie consistant à travailler à partir d'une librairie de spectres de référence, issus de mesures terrain ou de mesures en laboratoire. Le travail préalable aux expériences d'optimisation spectrale a alors consisté se doter d'une taxonomie de matériau, puis à récupérer les spectres de matériaux dans différentes bases de données spectrales disponibles, avant de les mettre dans un format commun et dans cette nomenclature commune. Certains matériaux étaient peu représentés dans cette collection de spectres, ainsi que la totalité de leur variabilité possible. Il a également fallu composer avec les informations associées à ces spectres et qui n'étaient pas toujours aussi détaillées que nous aurions pu le souhaiter. Nous avons donc finalement dû nous restreindre à des tests et une nomenclature moins ambitieuse que ce que nous aurions souhaité.

Les principaux résultats obtenus sont les suivants :

- Les expériences ont porté sur deux nomenclatures regroupant les classes de matériaux communément rencontrés en milieu urbain. Ces nomenclatures étaient les suivantes { ardoise - asphalte - ciment - gravier - métal - pavés en pierre - shingle - terre - tuile } et { amiante - ardoise - asphalte - ciment - fibro-ciment - gravier - métal - métal peint - pavés en pierre - shingle - terre - tuile en ciment - tuile en terre cuite }. On a alors vérifié qu'un jeu limité de bandes spectrales (environ 10) est suffisant pour la classification de ces matériaux. Utiliser davantage de bandes n'a que très peu d'influence sur la qualité des résultats obtenus pour ces nomenclatures.  
Il serait maintenant intéressant de pouvoir y intégrer des classes appartenant à la végétation et aux zones d'eau, afin d'identifier quelles autres bandes devraient être ajoutées à la sélection afin de pouvoir traiter ces nouveaux problèmes.
- L'apport de l'utilisation de bandes appartenant au domaine spectral du SWIR a également été confirmé. En effet, à nombre égal de bandes sélectionnés, les résultats obtenus en utilisant des configurations spectrales comportant des bandes appartenant à la fois au VNIR et au SWIR fournissent des classifications significativement meilleures que celles composées exclusivement de bandes issues du domaine VNIR (420-1000 nm). Ceci a été vérifié à la fois pour des jeux de 10 et de 4 bandes. On a d'ailleurs pu constater qu'un jeu de 4 bandes bien choisies dans le VNIR et le SWIR permettait d'obtenir des résultats comparables, voire meilleurs (notamment dans le cas du classifieur RF) qu'un ensemble de 10 bandes sélectionnées uniquement dans le VNIR.
- La sélection de bandes individuelles a été effectuée à la fois pour des résolutions spectrales de 10 nm et de 1 nm. Les configurations spectrales proposées dans les 2 cas restaient assez semblables. De même, les indicateurs de qualité des classifications obtenues dans ces 2 cas étaient assez proches. Si pour certaines classes, des améliorations ou des diminutions plus significatives ont pu être observées selon que l'on travaille à une résolution de 10 ou 1 nm, elles n'étaient pas forcément les mêmes selon le classifieur utilisé. Une résolution plus fine (1nm) serait peut-être intéressante pour diagnostiquer des phénomènes plus fins (comme par exemple, le niveau de dégradation de certains matériaux, ou le stress de la végétation), mais n'apparaît pas comme nécessaire dans le cas présent de discrimination des différents matériaux.

- Ces expériences de sélection de bandes ont toutes été effectuées avec le même critère basé sur la confiance d'un classifieur RF, c'est-à-dire un classifieur à même de gérer dans une certaine mesure l'existence d'une variabilité intra-classe. Aussi, n'a-t-on pas pris en compte de sous-classes lors des expériences d'optimisation spectrale. D'un point de vue opérationnel, il était toutefois intéressant de voir dans quelle mesure la prise en compte des sous-classes correspondant à différents aspects de même matériaux pouvait améliorer les résultats de classification pour une configuration spectrale donnée. Il est alors apparu que la prise en compte de sous-classes lors de l'apprentissage améliorait les résultats de la classification pour le classifieur RF, en particulier pour des bandes issues exclusivement du VNIR. Cette amélioration concerne les résultats globaux, mais conduit à des résultats plus nuancés pour certaines classes.

Néanmoins, certains des résultats obtenus (notamment les évaluations quantitatives) sont à nuancer à cause du faible nombre de spectres représentatifs disponibles pour plusieurs classes. Ainsi, lors de l'expérience de sélection de bandes menée pour une légende un peu plus détaillée mais dont les nouvelles classes étaient généralement décrites par très peu de spectres dans la librairie spectrale collectée, il est apparu que ces classes étaient généralement très bien détectées lors de la classification. Les résultats obtenus sont donc à nuancer : la solution proposée de générer des spectres supplémentaires par application d'un facteur multiplicatif aléatoire ne permet pas de tenir compte de la véritable variabilité des matériaux, qui n'affecte pas nécessairement de manière identique les différentes parties du spectre. Aussi des classes décrites par peu de spectres dans la base de données sont plus faciles à retrouver pour le classifieur, car présentant une variabilité moindre dans le jeu de données test généré. Dans ces conditions, il peut être difficile de mesurer dans quel mesure on ne tombe pas dans du sur-ajustement.

Il serait donc intéressant d'affiner ce travail, lorsque de nouveaux spectres seront disponibles. De nouvelles mesures de spectres pourront notamment être réalisées dans le cadre du projet ANR HYEP (Hyperspectral imagerY for Environmental urban Planning). Ce projet qui a débuté en 2015 s'intéresse à l'utilisation de l'imagerie hyperspectrale pour l'étude du milieu urbain, notamment pour des applications de planification urbaine. Une de ses tâches consiste notamment en la réalisation d'une base de données morpho-spectrale. Si de nouveaux spectres sont disponibles, notamment pour les classes les moins bien représentés au sein de la librairie que nous avons collectée, il sera donc intéressant de relancer le processus d'optimisation spectrale en prenant en compte cette fois les nouveaux spectres. Une autre perspective de travail consisterait aussi en une analyse plus fine de l'impact de la prise en compte de sous-classes, en terme d'usure des matériaux cette fois.

D'autres perspectives de travail consistent en la mise en application de la classification des matériaux (pour les jeux de bandes sélectionnés) sur les images hyperspectrales acquises lors de la campagne UMBRA et désormais disponibles, ainsi que lors de nouvelles campagnes sur Toulouse réalisées en 2014 et 2015. Cela permettra d'aborder le problème de la classification des matériaux de manière plus opérationnelle, ainsi que nous avions initialement prévu de le faire. Cette application plus opérationnelle sur données "réelles" permettrait vraisemblablement de mieux cerner les limites de la classification des matériaux et de mieux identifier les confusions qui se produisent. D'autres expériences consisteraient aussi à évaluer l'impact de la prise en compte de données complémentaires (comme par exemple un modèle numérique de surface) dans le processus de classification, mais également celui de certains post-traitements de la classification (comme des méthodes de régularisation). On pourra aussi voir dans quelle mesure il est possible d'entraîner le classifieur à partir des spectres de la librairie spectrale, puis de l'appliquer à l'image.

D'un point de vue plus thématique, certaines familles de classes d'occupation du sol pourtant importantes ont été exclues des expérimentations (pour des raisons détaillées en 8.5). Il s'agit des classes décrivant la végétation et les zones d'eau. Afin d'être plus exhaustif, il conviendrait de les prendre en compte lors de l'optimisation spectrale et de déterminer quelles autres bandes devraient être ajoutées à la sélection pour être en mesure de traiter les problématiques qui leur sont liées (comme par exemple la discrimination des espèces, la détection des toitures végétalisées ou le suivi du stress hydrique dans le cas de la végétation).

Une dernière perspective de travail concerne le fait d'aller plus loin dans la discrimination des matériaux. Dans les expériences précédentes, on a cherché à obtenir une configuration spectrale qui soit un compromis permettant de classer au mieux les différents matériaux de la nomenclature. Si, pour un matériau donné, on souhaite également caractériser des sous-classes de façon plus fine, comme par exemple quantifier différents niveaux d'usure, il pourra être nécessaire d'identifier des bandes supplémentaires, différentes de celles permettant de distinguer ce matériau des autres. Cette caractérisation plus fine d'un matériau peut en effet être liée à des variations locales de son spectre. La prise en compte de ces phénomènes locaux au moyen d'indices spécifiques (à l'instar de ceux proposés par [Heiden *et al.* 2007]) pourrait alors être une voie d'amélioration pour caractériser ce matériau plus finement. Dans ce but, on pourrait poursuivre les quelques expériences présentées dans la section 6.6.2 visant à définir des indices simples (impliquant uniquement des paires de bandes) calculés à partir des bandes sélectionnées conjointement avec le processus de sélection de bandes ont d'ailleurs été menées.

# Annexes



---

## Annexe A

# Glossaire

**AG** (Algorithme Génétique) : heuristique d'optimisation (pour plus de détails, consulter la section 6.3.2)

**OCS** : OCcupation du Sol

**RF ou FA** : (*Random Forest* ou Forêt Aléatoire) : classifieur (pour plus de détails, consulter la section 3.1.6)

**SAM** (*Spectral Angle Mapper* ou angle spectral) : mesure de similarité entre spectres (pour plus de détails, consulter la section 3.1.2)

**SFFS** (*Sequential Forward Floating Search*) : heuristique de sélection d'attributs (pour plus de détails, consulter la section 6.3.1)

**SID** (*Spectral Information Divergence*) : mesure de similarité entre spectres (pour plus de détails, consulter la section 3.1.2)

**SVM** (*Support Vector Machines* ou Séparateurs à Vastes Marges) : classifieur (pour plus de détails, consulter la section 3.1.4)

**SWIR** (*Short-Wave InfraRed*) : domaine spectral de l'infra-rouge ondes courtes allant approximativement de 1000 nm à 2500 nm.

**UMC** : Unité Minimales de Collecte. Spécifient pour chaque classe de la nomenclature la taille en deçà de laquelle les objets sont considérés comme trop petits pour apparaître dans la base de données.

**VNIR** (*Visible Near InfraRed*) : domaine spectral du visible et du proche infra-rouge, allant approximativement de 400 nm à 1000 nm.





## Annexe B

# Rappel des configurations de quelques capteurs satellite

### Pléiades

Dates de lancement : 2011 (Pléiades 1-A) et 2012 (Pléiades 1-B)

Fauchée : 20 km

TABLE B.1 – Capteur Pléiades

Bande	Domaine spectral	Résolution spatiale (au nadir)
Panchromatique	470 – 820 nm	0,7 m
Bleu	430 – 550 nm	2 m
Vert	500 – 620 nm	2 m
Rouge	590 – 710 nm	2 m
Proche infrarouge	740 – 940 nm	2 m

### SPOT-6 et SPOT-7

Dates de lancement : 2012 (SPOT 6) et 2014 (SPOT 7)

Fauchée : 60 km

TABLE B.2 – Capteurs SPOT 6 et 7

Bande	Domaine spectral	Résolution spatiale (au nadir)
Panchromatique	455–745 nm	1,5 m
Bleu	455 – 525 nm	6 m
Vert	530 – 590 nm	6 m
Rouge	625 – 695 nm	6 m
Proche infrarouge	760 – 890 nm	6 m

## Worldview-3

Date de lancement : 2014

Fauchée : 13,1 km

TABLE B.3 – Capteur Worldview-3

Bande	Domaine spectral	Résolution spatiale (au nadir)
Panchromatique	450 - 800 nm 31 cm	
Coastal	400 - 452 nm	1,24 m
Bleu	448 - 510 nm	1,24 m
Vert	518 - 586 nm	1,24 m
Jaune	590 - 630 nm	1,24 m
Rouge	632 - 692 nm	1,24 m
Red-edge	706 - 746 nm	1,24 m
Proche infrarouge 1	772 - 890 nm	1,24 m
Proche infrarouge 2	866 - 954 nm	1,24 m
SWIR-1	1195 - 1225 nm	3,7 m
SWIR-2	1550 - 1590 nm	3,7 m
SWIR-3	1640 - 1680 nm	3,7 m
SWIR-4	1710 - 1750 nm	3,7 m
SWIR-5	2145 - 2185 nm	3,7 m
SWIR-6	2185 - 2225 nm	3,7 m
SWIR-7	2235 - 2285 nm	3,7 m
SWIR-8	2295 - 2365 nm	3,7 m

## Annexe C

# Publications

## C.1 Liste des publications et communications dans le cadre de ce travail

### Revue nationale avec comité de lecture

ADELIN, K., LE BRIS, A., COUBARD, F., BRIOTTET, X., PAPANODITIS, N., VIALLEFONT, F., RIVIÈRE, N., PAPELARD, J.-P., DAVID, N., DÉLIOT, P., DUFFAUT, J., POUTIER, L., FOUCHER, P., ACHARD, V., SOUCHON, J.-P., THOM, C., AIRAULT, S. et MAILLET, G. (2013). Description de la campagne aéroportée UMBRA : étude de l'impact anthropique sur les écosystèmes urbains et naturels avec des images thr multispectrales et hyperspectrales. *Revue Française de Photogrammétrie et de Télédétection*, 202:79–92.

### Conférences internationales avec comité de lecture

LE BRIS, A., CHEHATA, N., BRIOTTET, X. et PAPANODITIS, N. (2015). Extraction of optimal spectral bands using hierarchical band merging out of hyperspectral data. *In ISPRS Annals of Photogrammetry, Remote Sensing and the Spatial Information Sciences*, volume X(X).

LE BRIS, A., CHEHATA, N., BRIOTTET, X. et PAPANODITIS, N. (2015). A random forest class memberships based wrapper band selection criterion : application to hyperspectral. *In Proc. of the 2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS'2015)*.

LE BRIS, A., CHEHATA, N., BRIOTTET, X. et PAPANODITIS, N. (2014). Identify important spectrum bands for classification using importances of wrapper selection applied to hyperspectral. *In Proc. of the 2014 International Workshop on Computational Intelligence for Multimedia Understanding (IWCIM'14)*.

LE BRIS, A., CHEHATA, N., BRIOTTET, X. et PAPANODITIS, N. (2014). Use intermediate results of wrapper band selection methods : a first step toward the optimization of spectral configuration for land cover classifications. *In Proc. of the 6th Workshop on Hyperspectral Image and Signal Processing : Evolution in Remote Sensing (WHISPERS'14)*.

CHEHATA, N., LE BRIS, A. et NAJJAR, S. (2014). Contribution of band selection and fusion for hyperspectral classification. *In Proc. of the 6th Workshop on Hyperspectral Image and Signal Processing : Evolution in Remote Sensing (WHISPERS'14)*.

### Conférences internationales sans comité de lecture

LE BRIS, A., CHEHATA, N., BRIOTTET, X. et PAPANODITIS, N. (2013). Very high resolution land cover extraction in urban areas. *In Proc. of the 8th EARSeL Imaging Spectrometry Workshop*.

ADELIN, K., LE BRIS, A., COUBARD, F., BRIOTTET, X., PAPANODITIS, N., VIALLEFONT, F., DÉLIOT, P., DUFFAUT, J., AIRAULT, S., RIVIÈRE, N., DAVID, N., MAILLET, G., PAPELARD, J.-P., POUTIER, L., ACHARD, V., FOUCHER, P., SOUCHON, J.-P. et THOM, C. (2013a). The UMBRA experiment : study of urban and natural ecosystems. *In Proc. of the 8th EARSeL Imaging Spectrometry Workshop*.

### Colloques nationaux sans comité de lecture

LE BRIS, A. (2015). Optimisation spectrale pour la classification de l'occupation du sol (ocs) à partir d'imagerie hyperspectrale. Présenté aux Journées de la Recherche de l'IGN, 19-20 mars 2015, Saint-Mandé, France.

LE BRIS, A., CHEHATA, N., BRIOTTET, X. et PAPARODITIS, N. (2014). Optimisation de configuration spectrale pour la classification – exemple d'application au milieu urbain. Présentation donnée au 3eme colloque scientifique du groupe hyperspectral de la SFPT.

## C.2 Liste des publications et communications sur d'autres sujets en parallèle de ce travail

### Revue nationale avec comité de lecture

CHEHATA, N., GHARIANI, K., LE BRIS, A. et LAGACHERIE, P. (2015). Délimitation des parcelles agricoles par classification d'images pléiades. *Revue Française de Photogrammétrie et de Télédétection*, 209:165–171.

### Conférences internationales avec comité de lecture

SIDI YOUSSEF, M., CHEHATA, N., MALLET, C., LE BRIS, A. et GRESSIN, A. (2014). Détection de bâtiments à partir d'une image satellitaire par combinaison d'approches ascendante et descendante. In *Actes du 19eme congrès sur la Reconnaissance de Formes et l'Intelligence Artificielle (RFIA '14)*.

SIDI YOUSSEF, M., MALLET, C., CHEHATA, N., LE BRIS, A. et GRESSIN, A. (2014). Combining top-down and bottom-up approaches for building detection in a single very high resolution satellite image. In *Proc. of the 2014 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*.

GHARIANI, K., CHEHATA, N., LE BRIS, A. et LAGACHERIE, P. (2014). Agricultural field delimitation using active learning and random forests margin. In *Proc. of the 2014 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*.

CHEHATA, N., LE BRIS, A. et LAGACHERIE, P. (2013). Comparison of VHR panchromatic texture features for tillage mapping. In *Proc. of the 2013 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*.

LE BRIS, A., TASSIN, F. et CHEHATA, N. (2013). Contribution of texture and red-edge band for vegetated areas detection and identification. In *Proc. of the 2013 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*.

LE BRIS, A. (2012). Extraction of vineyards out of aerial ortho-image using texture information. In *ISPRS Annals of Photogrammetry, Remote Sensing and the Spatial Information Sciences*, volume 1(3), pages 383–388.

### Conférences internationales sans comité de lecture

SELLAMI-KAANICHE, E., DE GOVELLO, B., LE BRIS, A., GROMAIRE, M.-C. et GHEBBO, G. (2012). Modelling the zn emissions from roofing materials at créteil city scale - defining a methodology. *In 12th World Wide Workshop for Young Environmental Scientists WWW-YES-2012 - Urban waters : resource or risks ?*, pages 71–80.

### Colloques nationaux sans comité de lecture

LE BRIS, A. (2013). Détection et identification de zones de végétation arborée et viticole : utilisation d'images satellite rapideye et de données bdortho. Présenté aux Journées de la Recherche de l'IGN, 24-25 avril 2013, Saint-Mandé, France.

## C.3 Liste des publications et rapports techniques antérieurs à ces travaux

### Revue internationale avec comité de lecture

LE BRIS, A. et BOLDO, D. (2008). Extraction of land cover themes from aerial ortho-images in mountainous areas using external information. *The Photogrammetric Record*, 23(124):387–404.

### Revue nationale avec comité de lecture

DURUPT, M., FLAMANC, D., LE BRIS, A., IOVAN, C. et CHAMPION, N. (2006). Evaluation of the potential of pleiades system for 3d city models production : building, vegetation and dtm extraction. *Revue Française de Photogrammétrie et de Télédétection*, 184(4):83–88.

### Revue nationale sans comité de lecture

GONDOL, L., LE BRIS, A. et LECORDIX, F. (2007). Cartographie des zones de haute montagne : essais de cartographie numérique des rochers. *Le Monde des Cartes*, 193:7–13.

### Conférences internationales avec comité de lecture

LE BRIS, A. et CHEHATA, N. (2011). Change detection in a topographic building database using submetric satellite images. *In International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, volume 38(3/W22), pages 25–30.

LE BRIS, A. et PAPANODITIS, N. (2010). Matching terrestrial images captured by a nomad system to images of a reference database for pose estimation purpose. *In International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, volume 38 (3A), pages 133–138.

GONDOL, L., LE BRIS, A. et LECORDIX, F. (2008b). A new approach for mountain areas cartography. *In Headway in Spatial Data Handling : 13th International Symposium on Spatial Data Handling*, Lecture Notes in Geoinformation and Cartography, pages 315–333, Montpellier,

---

France. Springer Berlin Heidelberg.

### Conférences internationales sans comité de lecture

LE BRIS, A. et ROBERT-SAINTE, P. (2009). Classification of roof materials for rainwater pollution modelization. *In International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, volume 38(1-4-7/W5).

GONDOL, L., LE BRIS, A. et LECORDIX, F. (2008). Cartography of high mountain areas – testing of a new digital cliff drawing method. *In 6th ICA Mountain Cartography Workshop Mountain Mapping and Visualisation*, pages 71–80, Lenk, Switzerland. ICA.

LE BRIS, A. et BOLDO, D. (2007). Extraction of landcover themes out of aerial orthoimages in mountainous areas using external information. *In International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, volume 36(3/W49A), pages 123–128, Munich, Germany. ISPRS.

DURUPT, M., FLAMANC, D., LE BRIS, A., IOVAN, C. et CHAMPION, N. (2006). Evaluation of the potential of pleiades system for 3d city models production : building, vegetation and dtm extraction. *In International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, volume 36(1), Marne-La-Vallee, France.

### Colloques nationaux sans comité de lecture

#### Rapports techniques

LE BRIS, A. (2010). Détection de changements 2d à partir d'images optiques submétriques Pléiades : utilisation d'outils de classification de l'occupation du sol et application au thème bâti. Rapport technique, Institut Géographique National (IGN-France) - Laboratoire MATIS.

LE BRIS, A. (2010). Expériences d'appariement d'images avec SIFT. Rapport technique, IGN/MATIS.

LE BRIS, A. (2010). Extraction semi-automatique de thèmes d'occupation du sol en milieu montagneux à partir d'ortho-images et de connaissances complémentaires, en vue de la production de la carte de base. Rapport technique, IGN/MATIS.

## C.4 Compilation des publications effectuées dans le cadre de ce travail



# DESCRIPTION DE LA CAMPAGNE AÉROPORTÉE UMBRA : ÉTUDE DE L'IMPACT ANTHROPIQUE SUR LES ÉCOSYSTÈMES URBAINS ET NATURELS AVEC DES IMAGES THR MULTISPECTRALES ET HYPERSPECTRALES :

## Urban Material characterization in the sun and shade of Built-up structures and trees and their Retrieval from Airborne image acquisitions over two French cities (UMBRA)

Karine R.M. Adeline<sup>1</sup>, Arnaud Le Bris<sup>2</sup>, Fabien Coubard<sup>2</sup>, Xavier Briottet<sup>1</sup>, Nicolas Paparoditis<sup>2</sup>, Françoise Viallefont<sup>1</sup>, Nicolas Rivière<sup>1</sup>, Jean-Pierre Papelard<sup>2</sup>, Nicolas David<sup>2</sup>, Philippe Déliot<sup>1</sup>, Joël Duffaut<sup>1</sup>, Laurent Poutier<sup>1</sup>, Pierre-Yves Foucher<sup>1</sup>, Véronique Achard<sup>1</sup>, Jean-Philippe Souchon<sup>2</sup>, Christian Thom<sup>2</sup>, Sylvain Airault<sup>2</sup>, Grégoire Maillet<sup>2</sup>

1 : ONERA, The French Aerospace Lab, 2 avenue Edouard Belin, 31055 Toulouse cedex 4, France, prénom.nom@onera.fr

2 : IGN, 73 avenue de Paris, 94160 Saint-Mandé, France, prénom.nom@ign.fr

### Résumé

Durant ces dernières décennies, l'imagerie par télédétection aéroportée des milieux urbains reste un enjeu scientifique majeur. L'arrivée d'une nouvelle génération de caméras aéroportées permettant d'effectuer des acquisitions à très haute résolution spatiale et possédant un meilleur rapport signal sur bruit ouvre de nouvelles perspectives pour extraire l'information de ces environnements. En effet, la principale limitation de la plupart des méthodes de traitement des images dans ces milieux est due à la grande variété des matériaux qui les compose et à la géométrie dense et complexe qui les caractérise et peut induire de larges zones d'ombre. La campagne (UMBRA) a pour but d'acquérir un nouveau jeu de données de référence représentatif de deux villes françaises distinctes en vue de développer de nouvelles méthodes de correction atmosphérique au soleil et à l'ombre, de concevoir de futures caméras superspectrales dédiées à des applications de télédétection urbaine, et d'étudier des applications pour "ré-éclairer" des scènes à partir d'images urbaines terrestres. Ce papier détaille cette campagne ainsi que les prétraitements qui ont été effectués sur les différentes données acquises. De premiers résultats sont également présentés.

**Mots clés** : campagne expérimentale, imagerie aéroportée, haute résolution spatiale et spectrale, milieux urbains, propriétés optiques des matériaux.

### Abstract

*Remote sensing imagery of urban environments from airborne acquisitions still remains a major scientific issue over the last decades. As urban areas are characterized by a high variety of materials and many shadowed areas, most of the processing methods are limited. Moreover, due to the high spatial resolution and better signal-to-noise ratio of the new generation of airborne sensors, this opens the way to new developments to improve the extraction of information from such environments. This campaign (UMBRA) aims at acquiring a new reference dataset representative of two different French cities to develop a new atmospheric correction method in sunlit and shaded urban areas, to design a future generation of superspectral cameras system dedicated to geomatic applications, and to study relighting applications from terrestrial urban image data. This paper details this experiment and the preprocessing done on the different acquired data. Some first results are presented.*

**Keywords** : field campaign, airborne imagery, high spatial and spectral resolution, urban areas, material optical properties.

## 1. Introduction

A l'échelle du sol, les interactions globales Homme-Milieus sont plus complexes à expliquer dans les environnements urbains qu'en milieux naturels. Cela peut

s'expliquer d'une part à cause de la grande variabilité et hétérogénéité des matériaux qui les composent (Herold et al., 2004 ; Lachérade et al., 2005 ; Heiden et al., 2007 ; Le Bris et al., 2008), et d'autre part à cause du relief très accidenté qui les caractérise (structures 3D et ef-

fets de pente (Heiden et al., 2012), effets d'ombre (Ade-line et al., 2013a), etc.). Depuis ces dernières décennies et grâce à l'avancée de nouveaux capteurs imageurs à haute résolution spatiale, la télédétection aéroportée a démontré sa capacité à expliquer et identifier certains phénomènes difficiles à observer à partir du sol (Heldens et al., 2011 ; Schafri et al., 2012), parmi lesquels : îlots de chaleur urbain (Sobrino et al., 2009), suivi météorologique (Heldens et al., 2010), pollution urbaine (Mestayer et al., 2005 ; Mestayer et al., 2011), bilans énergétiques et perméabilité des sols (Pauwels et al., 2008 ; Demarchi et al., 2012 ; Weng, 2012). Avec cette perspective, plusieurs campagnes de mesures ont exploité différents moyens d'acquisition, qu'ils soient satellitaires, aéroportés ou terrestres, afin de mieux appréhender ces phénomènes anthropiques et atmosphériques, ainsi que leurs échanges. On en déduit par conséquent la nécessité de disposer d'un jeu de données de référence qui serait représentatif de l'application souhaitée. Dans le cas de l'étude des matériaux urbains dans le domaine réflectif 0,4-2,5  $\mu\text{m}$ , plusieurs jeux de données existent (Roessner et al., 2001 ; Cavalli et al., 2008 ; Masson et al., 2008 ; Doz et al., 2010) mais n'exploitent pas totalement la complémentarité entre l'information à haute résolution spatiale et spectrale en prenant en compte notamment les différents couplages Terre-Atmosphère-Capteur grâce à l'acquisition de données atmosphériques simultanées. Dans ce contexte, la campagne UMBRA a été motivée et réalisée dans le cadre d'une collaboration entre l'IGN et l'Onera. Cet article décrit la campagne et les mesures effectuées afin d'obtenir un jeu de données de qualité permettant de couvrir les trois principales applications visées :

- La validation de nouvelles méthodes de correction atmosphérique adaptées aux milieux urbains et à leur végétation spécifique ;
- La définition des futures caméras superspectrales optimisées pour l'identification des matériaux urbains ;
- L'identification des propriétés optiques des matériaux de façades de rue à partir d'acquisitions terrestres mobiles grâce au système Stereopolis.

La campagne UMBRA s'est déroulée sur trois jours du 23 au 25 octobre 2012. Elle comprend à la fois l'acquisition d'images aéroportées et un ensemble de mesures terrain principalement sur deux villes françaises : Toulouse et Amiens. Ces villes ont été choisies entre autres pour leurs caractéristiques urbanistiques et climatiques différentes (Sud-Ouest et Nord de la France), et aussi parce qu'elles peuvent être considérées comme représentatives du paysage urbain français et vraisemblablement européen. Par ailleurs, Toulouse et Amiens sont des lieux stratégiques respectivement pour l'Onera et l'IGN pour lesquels de nombreuses études ont déjà été menées.

Une importante spécificité du jeu de données UMBRA réside dans le fait que différents capteurs optiques

étaient placés dans le même avion, rendant possible l'acquisition simultanée d'images présentant des caractéristiques complémentaires :

- Données multispectrales à très haute résolution spatiale (12 cm après fusion P+XS) ;
- Données hyperspectrales à haute résolution spectrale (VNIR : 4 nm, SWIR : 6 nm) et spatiale (VNIR : 80 cm, SWIR : 1,6 m) ;
- Clichés photogrammétriques en recouvrement multistéréoscopique permettant d'améliorer le processus de géoréférencement et de calculer un modèle numérique de surface des zones survolées ;
- Données panchromatiques stéréoscopiques à très haute résolution spatiale, qui couplées aux données multispectrales et hyperspectrales permettront de tester des outils de pan-sharpening a posteriori.

Une seconde particularité de ce jeu de données concerne le fait que de nombreuses mesures terrain ont été relevées durant l'acquisition aérienne, afin d'une part, de caractériser les scènes étudiées d'un point de vue optique et géométrique, et d'autre part, de caractériser l'état de l'atmosphère.

Le jeu acquis permettra également d'aborder d'autres thématiques supplémentaires relatives aux milieux urbains : suivi de la biodiversité, qualité des eaux (marécages, lacs, fleuves) et études hydrologiques (croissance des algues, etc.), qualité de l'air liée à la pollution urbaine et industrielle (autoroutes, incinérateur, etc.), contrôle du vieillissement des routes (pistes de vol aéroportuaires) (Herold et Roberts, 2005), détection d'anomalie (cibles camouflées). De plus, il servira de jeu de référence pour le dimensionnement de la future mission hyperspectrale HYPXIM (Lefèvre-Fonollosa et al., 2012). Outre les milieux urbains, la campagne UMBRA a permis des acquisitions sur différents sites ruraux : le site montagneux de Bernadouze (atelier du labex DRIHM dont l'objectif est d'analyser les interactions Homme-Milieu) et le site du centre Onera-Fauga à Mauzac afin d'évaluer l'évolution de la végétation après un feu de biomasse.

La figure 1 donne la localisation géographique des différents lieux survolés ainsi que de possibles axes d'étude scientifique futurs.

## 2. Les sites d'étude

Pour chacun des quatre sites d'étude sont présentés leur description physique, les différents moyens et ateliers de mesures, et enfin les conditions atmosphériques au moment des acquisitions aériennes. Le tableau 1 résume et détaille pour chaque site d'étude ces informations.

### 2.1. Toulouse

**Description.** La zone d'étude de Toulouse couvre différents types de quartiers parmi lesquels on rencontre

Date et heure	Sites		Instruments	Nature des mesures	Fréquence des mesures	Cibles	Applications
23/10/2012 autour de 13h TU	Fauga-Mauzac		Spectroradiomètre (ASD)	Eclairage	Ponctuellement	Cible de réflectance standard	Caractérisation atmosphérique
				Luminance	Ponctuellement autour des passages avion	Mires de référence claire et le sol en « quick »	Etalonnage en vol
			Spectroradiomètre (GER)	Eclairage	En continu	Panneau de réflectance standard	Caractérisation atmosphérique
			Radiomètre micro-ondes	Température, pression, contenu en vapeur d'eau et en eau liquide dans les nuages	En continu	-	Caractérisation atmosphérique
24/10/2012 entre 9h30 et 12h40 TU	Toulouse	Site n°1	Spectroradiomètre (ASD)	Eclairage	Ponctuellement	Cible de réflectance standard	Caractérisation atmosphérique
				Luminance	Ponctuellement autour des passages avion	Mires de référence claire et sombre	Etalonnage en vol
			Spectroradiomètre (GER)	Eclairage	En continu	Cible de réflectance standard	Caractérisation atmosphérique
			Radiomètre micro-ondes	Température, pression, contenu en vapeur d'eau et en eau liquide dans les nuages	En continu	-	Caractérisation atmosphérique
			Appareil photo avec objectif fisheye	Photos hémisphériques de ciel	Ponctuellement	-	Caractérisation atmosphérique
	Site n°2 Site n°3	Deux spectroradiomètres (ASD)	Réflectance et/ou transmittance	Ponctuellement	Matériaux au sol et mires de référence, arbres : feuilles, tronc et branches	Construction d'une vérité terrain pour les matériaux	
			Luminance et éclairage	Ponctuellement	Matériaux au sol et panneau de réflectance standard	Correction atmosphérique	
			Eclairage	Ponctuellement	Panneau de réflectance standard	Caractérisation atmosphérique	
		GPS	Coordonnées géographiques	-	Repères au sol	Recalage des images et atelier détection d'anomalies	
		Laser scanner terrestre	Nuages de points 3D	-	4 arbres et un bâtiment	Reconstruction du modèle 3D	
24/10/2012 autour de 13h TU	Bernadouze		-	-	-	-	-
25/10/2012 entre 11h30 et 13h30 TU	Amiens		Spectroradiomètre (ASD)	Réflectance	Ponctuellement	Matériaux au sol et une mire de référence	Construction d'une vérité terrain pour les matériaux
				Eclairage	Ponctuellement	Cible de réflectance standard	Caractérisation atmosphérique
			Caméras (Stereopolis)	Comptes numériques	En continu	Rues et la partie de ciel visible	Estimation de l'illumination et de la réflectance
			Lidar (Stereopolis)	Distance et intensité	En continu	Rues	Reconstruction 3D

**TABLE 1** : Récapitulatif des mesures effectuées sur le terrain sur les différents sites d'étude.


un centre historique présentant un bâti dense, des zones résidentielles pavillonnaires et collectives, des infrastructures sportives, de grandes zones commerciales et industrielles, ainsi que des réseaux ferrés et autoroutiers, et un aéroport. Toulouse comprend également des surfaces végétalisées ainsi qu'un fleuve et un canal qui la traversent.

**Ateliers et mesures terrain.** On distingue trois sites de mesures : le centre Onera à Toulouse (site n°1), le CREPS (site n°2) et l'Université Paul Sabatier (site n°3). Les mesures effectuées sur le site n°1 avaient pour but de contrôler l'évolution des conditions atmosphériques au cours de l'acquisition aérienne, et de valider l'étalonnage en vol des capteurs. Pour cette dernière application, une mire de référence claire (lino gris clair)

et sombre (bâche noire) dont les dimensions leur permettent d'être visibles par les capteurs aéroportés, ont été disposées au sol et (Figure 2).

Sur les sites n°2 et n°3, des données de différentes natures ont été collectées visant à étudier la végétation urbaine (Figure 3) : mesures laser scanner terrestre pour remonter au modèle 3D des arbres, mesures des propriétés optiques des feuilles et éléments ligneux (réflectance et/ou transmittance), mesures radiométriques au sol au soleil et à l'ombre des arbres et d'un bâtiment pour constituer une vérité terrain à la validation de méthodes de correction atmosphérique.

Pour compléter cette vérité terrain, des mesures de spectres de réflectances de plusieurs matériaux ont été acquises sur le site n°2. Enfin, sur le site n°3, des cibles ont été installées pour un atelier de détection d'anomalie.

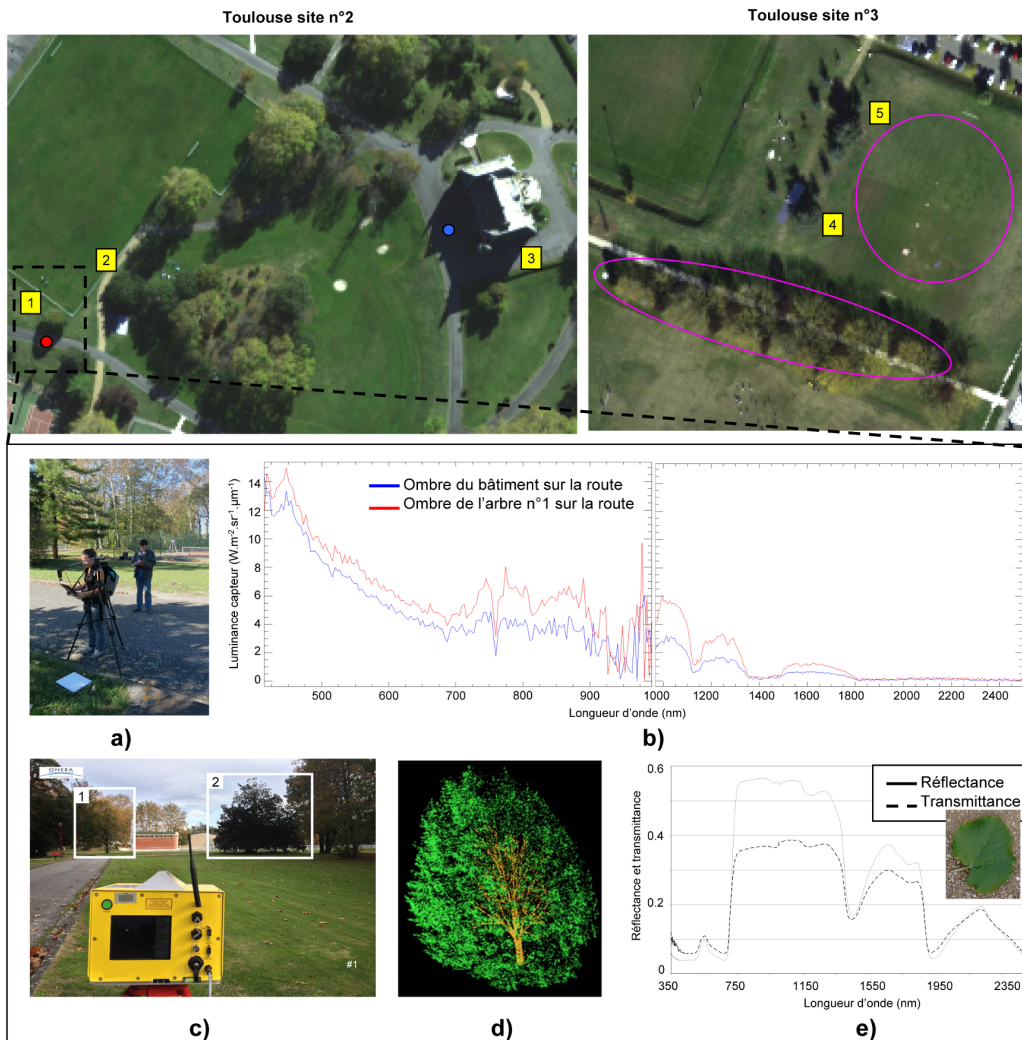


**FIGURE 1 :** Zones survolées au-dessus de Toulouse, Bernadouze, Amiens et Fauga-Mauzac (vues Google Earth) avec leurs délimitations (rectangles rouges), comprenant les centre-villes (cercles oranges), les sites de mesures terrain (points jaunes) et les zones à fort intérêt scientifique (panneaux de signalisation).





**FIGURE 2** : Lieux des ateliers d'étalonnage en vol (mires signalées par des flèches rouges) et de détection d'anomalie (position des cibles dans les cercles magentas).



**FIGURE 3** : Lieux de l'atelier de détection d'anomalie (position des cibles dans les cercles magentas) et des mesures terrain sur l'étude de la végétation urbaine (arbres : 1-2-4-5, bâtiment : 3). Exemples pour l'arbre n°1 : a) mesures radiométriques dans l'ombre de l'arbre, b) comparaison de la luminance capteur au-dessus d'un même matériau à l'ombre (disques rouge et bleu dans l'image Toulouse site n°2), c) prise de vue du laser scanner terrestre, d) reconstruction du modèle 3D de l'arbre et e) réflectance et transmittance des feuilles.

**Conditions météorologiques.** Le matin, le temps était un peu humide avec du brouillard qui s'est dissipé à partir du début des premiers passages avion. Puis la présence de cirrus épars dans le ciel a été notée. A partir de 11h-12h TU, le ciel s'est complètement dégagé, et ce, jusqu'à la fin des mesures.

## 2.2. Amiens

**Description.** Amiens présente des types de quartiers similaires à Toulouse mais s'en distingue par un emploi de matériaux urbains différents et généralement plus variés. La ville d'Amiens est traversée par un fleuve et comporte une importante zone d'étangs et de canaux. Les zones imagées comprennent également un village en périphérie ainsi que quelques zones plus rurales.

**Mesures terrain.** Les mesures terrain effectuées concernaient la caractérisation de l'atmosphère et l'étalonnage en vol des capteurs. Ces mesures se sont concentrées sur un seul atelier de mesure où a été disposée une mire de référence claire (lino brun clair, cf. Figure 2). D'autre part, des spectres de réflectance de matériaux urbains ont été acquis sur le terrain. Des acquisitions de données terrestres avec le système Stereopolis ont aussi été effectuées dans les rues d'Amiens simultanément à l'acquisition aérienne.

**Conditions météorologiques.** Les conditions météorologiques se sont progressivement dégradées au cours de l'acquisition des données. Ainsi le couvert nuageux est devenu de plus en plus dense jusqu'à être complet à la fin des acquisitions aéroportées.

## 2.3. Fauga-Mauzac

**Description.** Au centre de l'Onera-Fauga à Mauzac, se situent une zone dédiée aux mesures d'étalonnage en vol et une zone herbeuse et boisée récemment brûlée par un feu accidentel en août 2012. Par ailleurs, des cibles ont été également disposées sur le terrain pour une application de détection d'anomalie.

**Mesures terrain.** Pour les mesures dédiées à l'étalonnage en vol, une mire de référence claire (lino gris clair) a été utilisée conjointement avec le revêtement au sol en "quick" de la zone d'étalonnage qui a servi de mire de référence sombre (Figure 2).

**Conditions météorologiques.** Le temps était relativement nuageux à cause du passage ponctuel de nuages.

## 2.4. Bernadouze

**Description.** Bernadouze est une zone protégée près de la commune de Suc-et-Sentenac dans la chaîne montagneuse des Pyrénées. Sur ce site se trouvent deux tourbières à côté d'une importante forêt gérée par l'ONF. Ce site est actuellement sous surveillance scientifique afin d'évaluer l'impact de l'Homme sur des écosystèmes fragiles en paysages montagneux suite dans ce cas à

une déforestation sur plusieurs années (labex DRIIMH). Ce premier jeu permettra d'effectuer un bilan de la végétation présente avant l'exploitation de la forêt.

**Mesures terrain.** Aucune mesure.

**Conditions météorologiques.** Bonnes.

## 3. Caractérisation de l'atmosphère

Afin de caractériser les conditions atmosphériques, les instruments suivants ont été utilisés :


- Un radiomètre micro-ondes RPG-Hapto de RPG (Allemagne) et un second TP/WVP-300 de Radiometrics (USA) ont fait des acquisitions au nadir de profils altimétriques et temporels de plusieurs données météorologiques troposphériques jusqu'à 10km d'altitude : contenu en vapeur d'eau, contenu en eau liquide dans les nuages et température. Associées à ces instruments, des mesures de température et de pression de surface ont également été effectuées ;
- Le photomètre du réseau AERONET sur le site de Seysses situé à 15 km environ de Toulouse a mesuré l'épaisseur optique des aérosols ;
- Une caméra avec objectif fisheye a pris des photos hémisphériques permettant d'analyser la distribution spatiale et la trajectoire locale des nuages sur le demi-hémisphère de ciel ;
- Trois spectroradiomètres passifs portables ASD FieldSpec de Analytical Spectral Devices Inc. ([www.asdi.com](http://www.asdi.com)) et un autre GER3700 de Geophysical and Environmental Research Corporation (<http://www.spectravista.com/3700.html>) ont mesuré l'éclairement solaire durant les journées de la campagne au-dessus d'une cible de réflectance standard ou Spectralon, élaboré par Labsphere (<http://www.labsphere.com/products/reflectance-standards-and-targets/>).

Un exemple du suivi des conditions atmosphériques est illustré sur le site n°1 de Toulouse dans la figure 4. L'observation de la présence de cirrus le matin (Partie 2.1) est validée à la fois par les mesures d'un spectroradiomètre, l'analyse des photos de ciel et les données du radiomètre micro-ondes. Toutes ces informations sont des paramètres importants pour modéliser l'atmosphère et notamment quantifier la contribution de grandeurs physiques telles que la transmission atmosphérique due aux gaz et aux aérosols, la luminance atmosphérique et d'environnement. Elles seront utilisées a posteriori pour les traitements de l'étalonnage en vol et pour les méthodes de correction atmosphérique.


## 4. Moyens aéroportés

### 4.1. Instrumentation

Des instruments hyperspectraux et multispectraux ont été installés sur l'avion Beechcraft200 de l'IGN. Les



**FIGURE 4** : Mesures des conditions atmosphériques sur le site n°1 de Toulouse : a) évolution de l'éclairement solaire mesurée par le spectroradiomètre ASD et illustrée par deux photos hémisphériques de ciel (il a été mis en évidence le passage de cirrus devant le soleil vers 10h TU affectant drastiquement la quantité d'éclairement solaire reçu au sol), et b) profils altimétriques d'humidité relative et de contenu en eau liquide des nuages par le radiomètre micro-ondes.



**FIGURE 5** : Photo du montage du système PELICAN-HYPER de l'Onera.


Description	Système PELICAN-HYPER			Système IGN	
	HySpex VNIR	HySpex SWIR	CamV2 panchro	CamV2 multi	CamV2 panchro
Type d'acquisition	barrette	barrette	matrice	matrice	matrice
Nombre de pixels	1600	320	7256 x 5462	7256 x 5462	7256 x 5462
Intervalle spectral	0,4-1 µm	1-2,5 µm	0,4-0,8 µm	0,4-0,8 µm	0,35-0,75 µm
Nombre de bandes spectrales	160	256	panchro	4	panchro
Résolution spatiale	0,80m	1,6m	0,14m	0,24m	0,12m
Fauchée	645m	520m	1033m	1775m	1775m

**TABLE 2** : Récapitulatif des caractéristiques des systèmes imageurs PELICAN-HYPER et IGN.



configurations de prise de vue des différentes caméras sont résumées dans le tableau 2.

La caméra numérique CamV2 de l'IGN (Souchon et al., 2010) est un système photogrammétrique modulaire composé de plusieurs caméras matricielles (capteurs CCD de taille  $7216 \times 5412$ ). Elle est en effet constituée à la fois de quatre caméras multispectrales (bandes Bleu-Vert-Rouge-PIR) et de quatre caméras panchromatiques qui visent la scène en couvrant avec une meilleure résolution spatiale les quatre quadrants des images multispectrales. Ce système permet donc la production d'images fusionnées P+XS avec un rapport de pan-sharpening de  $2 \times 2$ . Ces images fusionnées ont une taille de  $14600 \times 10650$  pixels. Ce système comporte un dispositif de compensation de filé électronique par TDI (Time delayed integration) avec précision d'un demi pixel. Enfin, le système IGN est placé sur une plateforme gyro-stabilisée et inséré dans un ensemble fonctionnel avec FMS (Flight Management System : logiciel de gestion de vol exploitant un fichier dans lequel tous les sommets de prise de vue sont déterminés avant la mission), GPS et centrale inertielle (Figure 6).



**FIGURE 6** : Photo du montage du système IGN : 8 caméras multispectrales et panchromatiques avec la centrale inertielle et les deux racks d'acquisition.

Le système PELICAN-HYPER de l'Onera est dédié aux acquisitions hyperspectrales et est composé d'un assemblage de trois caméras : deux caméras hyperspectrales de type push-broom de Norsk Elektro Optikk, HySpex-VNIR1600 et HySpex-SWIR320m-e et une caméra à prise de vue instantanée CamV2 de l'IGN qui donne des images panchromatiques (Figure 5). Cette dernière est équipée de la même tête optique que les caméras du système de l'IGN. Elle produit des images qui ont la même ligne de visée que les images hyperspectrales mais avec une bien meilleure résolution spatiale. Au final, ce système permet d'obtenir des acquisitions à la fois à haute résolution spectrale et spatiale avec des images multispectrales, hyperspectrales et panchromatiques.

Comme l'une des principales applications visées porte sur la correction atmosphérique qui s'intéresse notamment au signal dans les ombres, il était nécessaire d'avoir un bon rapport signal sur bruit dans les images. Ceci a impliqué d'augmenter le temps d'intégration pour les caméras. Mais en parallèle, il est souhaitable d'étudier plusieurs pixels dans l'ombre et donc d'avoir la meilleure résolution spatiale possible, ce qui se traduit par une augmentation de la fréquence d'acquisition. En définitive, un compromis a été choisi qui limite la résolution spatiale à moins de 2m pour le capteur hyperspectral pour une vitesse avion d'environ  $82 \text{ m.s}^{-1}$  à une altitude de vol de 2160 m. Il en résulte une période d'acquisition de 10 ms, ce qui permet d'avoir une bonne dynamique dans l'image. En effet, vu les dates et les heures d'acquisition des différents sites survolés pendant la campagne UMBRA, les ombres peuvent représenter une part non négligeable dans l'image. Par exemple à Toulouse, l'angle solaire zénithal a varié entre  $55^\circ$  et  $65^\circ$  pendant la durée totale des mesures terrain. Des exemples d'applications utilisant des images multi-hyper-panchro provenant du jeu de données UMBRA sont illustrés dans la figure 7.

#### 4.2. Etalonnage radiométrique des capteurs

**Etalonnage en laboratoire.** Le système PELICAN-HYPER est étalonné radiométriquement en laboratoire en plaçant les caméras devant une sphère intégrante. La sphère délivre un flux maîtrisé et mesuré par un spectroradiomètre ASD qui sert d'étalon secondaire. Cette procédure permet d'établir les coefficients de gain pour chaque détecteur et dans chaque bande spectrale. L'offset est déterminé sur la caméra panchromatique par des acquisitions avec l'obturateur fermé. Pour les caméras HySpex, le niveau d'obscurité fait automatiquement parti de la procédure d'acquisition et le niveau est donc déterminé pour chaque image et sauvegardé dans l'en-tête des images. Il est ensuite utilisé lors de la correction radiométrique qui fournit une image en luminance par l'application d'un modèle gain-offset. On peut noter également que par construction, les caméras HySpex ont des valeurs très faibles de "smile" (changement de la longueur d'onde centrale en fonction de la position du pixel) et de "keystone" (mauvais recalage entre bandes) de l'ordre inférieur au dixième de pixel ; ce qui ne nécessite donc pas de corrections supplémentaires. Les performances radiométriques attendues sont, en terme de bruit équivalent en luminance (NER en  $\text{mW.m}^{-2}.\text{sr}^{-1}.\text{nm}^{-1}$ ) de 0,05-0,1 dans le visible, de 0,1-0,6 dans le NIR et de 0,01-0,02 dans le SWIR pour les caméras HySpex-VNIR et HySpex-SWIR ([http://www.opairs.aero/hyspex\\_en.html](http://www.opairs.aero/hyspex_en.html)). Le système IGN pourra par la suite être inter-étalonné radiométriquement à partir des images hyperspectrales étalonnées en luminance.

**Etalonnage en vol et sa validation (pour la caméra HySpex).** Elle s'appuie sur des mires de référence dont



DONNEES HYPERSPECTRALES, MULTISPECTRALES ET PANCHROMATIQUES




Image hyperspectrale VIS-NIR à 0,8m de résolution spatiale (composition colorée)





Image multispectrale à 0,24m de résolution spatiale (composition colorée)



Masque des ombres obtenu à partir de l'image multispectrale et de la méthode de (Nagao, 1979)





Image panchromatique à 0,12m de résolution spatiale avec ajustement de la dynamique adapté aux ombres



MODELE NUMERIQUE DE SURFACE




FIGURE 7 : Exemples d'applications utilisant les données multispectrales, hyperspectrales et panchromatiques de la campagne UMBRA : détection des ombres (Adeline et al., 2013a), identification de matériaux à l'ombre, construction du modèle surfacique 3D.

les propriétés optiques ont été mesurées en laboratoire et sur les connaissances des conditions atmosphériques (Partie 3). A partir de ces informations, il est possible d'estimer les luminances en entrée du capteur aéroporté avec des outils de transfert radiatif ; celui qui a été utilisé est COMANCHE (Poutier et al., 2002). La comparaison entre ces luminances estimées et les luminances réelles données par le capteur au-dessus de ces mires de référence permettent de valider l'étalonnage de l'instrument et aussi la modélisation choisie pour l'atmosphère. Le vol au-dessus de Fauga-Mauzac est dédié à cet étalonnage en vol ; les autres vols au-dessus de Toulouse et Amiens doivent permettre sa validation. La démarche et la méthodologie globale de ces étapes sont détaillées dans (Viallefont et al., 2013). La figure 8 montre les résultats pour la caméra hyperspectrale HySpex au-dessus de Toulouse en dehors des bandes d'absorption atmosphérique. On peut remarquer que les écarts les plus importants sont compris dans le bleu autour de 430 nm et entre 1000-1800nm dans le NIR. Des investigations en laboratoire vont être menées pour comprendre et améliorer ces écarts.




FIGURE 8 : Les résultats de l'étalonnage instrumental pour la caméra hyperspectrale.

### 4.3. Mise en géométrie des images

**Géoréférencement des images acquises par le système PELICAN-HYPER.** La correction géométrique est effectuée à l'issue des vols en utilisant les données d'une centrale inertielle fixée à proximité des caméras et d'un modèle géométrique donnant l'angle de visée de chaque pixel. Pour déterminer l'orientation précise de la ligne de visée, nous utilisons également des amers visibles sur une des images et dont les positions ont fait l'objet d'une mesure par GPS différentiel. L'incertitude résultante est estimée à une valeur de l'ordre de grandeur du pixel soit moins d'un mètre pour la caméra HySpex-VNIR.

**Géoréférencement des images acquises par le système IGN.** L'étalonnage de la caméra étant connu, les clichés fournis avaient déjà fait l'objet d'une correction de la distorsion. Un géoréférencement direct des clichés était donné par un système GPS+INS. Celui-ci

est généralement d'excellente qualité en relatif. Néanmoins, il peut nécessiter d'être recalé en absolu. Aussi les orientations des clichés des chantiers d'Amiens et de Toulouse ont finalement été estimées lors d'un processus classique d'aérotriangulation, en prenant en compte quelques points de stéréo-préparation. Parmi ces points dont les coordonnées terrain sont connues, certains ont été utilisés comme points d'appui (i.e. intervenant dans le calcul) et d'autres comme points de contrôle (afin d'évaluer la qualité de mise en géométrie des clichés). Les autres mesures prises en compte dans le calcul sont des points de liaison (points homologues entre images extraits de manière automatique) ainsi que les coordonnées des sommets de prise de vue fournies par le géoréférencement direct. Les résidus image et terrain obtenus à l'issue du calcul d'aérotriangulation sont donnés dans le tableau 3.

**Calcul d'un modèle numérique de surface par appariement dense multivue.** Les clichés acquis par la caméra numérique de l'IGN ont été pris dans une configuration multistéréoscopique avec des recouvrements de l'ordre de 60% en intra-bande et de près de 80% en inter-bande. Leur pixel sol est de l'ordre de 12 cm. Une telle configuration permettait le calcul d'un modèle numérique de surface à très haute résolution par corrélation multistéréoscopique dense. Les algorithmes mis en œuvre sont présentés dans (Pierrot-Deseilligny and Paparoditis, 2006). Ce modèle numérique de surface permettra de calculer des ortho-images vraies, ainsi qu'un modèle 3D urbain. Il pourra être utilisé lors de calculs d'inversion d'image.

## 5. Mesures terrain

### 5.1. Caractérisation des propriétés optiques de matériaux urbains


Les spectres de réflectance d'un certain nombre de matériaux urbains ont été mesurés sur le terrain à l'aide d'un spectroradiomètre ASD de terrain. La plupart de ces spectres concernent des matériaux de couverture du sol (pavé, asphalte, gravier, terre...). Ces mesures répondent à un double objectif. D'une part, elles peuvent constituer une vérité terrain pour des expériences de correction atmosphérique des images (inversion des images et correction dans les ombres). D'autre part, elles pourront venir enrichir une base de données de spectres de matériaux. La méthode de mesure mise en œuvre pour calculer la réflectance  $\rho_{mat}$  d'un matériau est la suivante : chaque mesure de luminance d'un matériau  $L_{mat}$  était effectuée entre deux mesures de luminance  $\{L_{spec}^1, L_{spec}^2\}$  d'un matériau de référence (spectralon) de réflectance  $\rho_{spec}$  connue (Equation 1).

$$\rho_{mat} = 2 \cdot \frac{L_{mat} \cdot \rho_{spec}}{(L_{spec}^1 + L_{spec}^2)} \quad (1)$$

Les bandes spectrales les plus sensibles aux phénomènes d'absorption atmosphérique sont ensuite exclues des spectres mesurés.

	Toulouse			Amiens		
<b>Résidus image</b>						
	EMQ points liaison (pix)	EMQ points liaison interbande (pix)		EMQ points liaison (pix)	EMQ points liaison interbande (pix)	
x	0,17	0,18		0,2	0,2	
y	0,16	0,16		0,16	0,16	
xy	0,24	0,24		0,25	0,25	
<b>Résidus terrain</b>						
	EMQ Appui (m)	EMQ Contrôle (m)	EMQ GPS (m)	EMQ Appui (m)	EMQ Contrôle (m)	EMQ GPS (m)
X	0,09	0,13	0,08	0,04	0,1	0,06
Y	0,11	0,15	0,07	0,07	0,08	0,08
Z	0,26	0,36	0,06	0,22	0,29	0,07
XY	0,14	0,19	0,11	0,08	0,13	0,1
XYZ	0,29	0,41	0,12	0,23	0,32	0,13

**TABLE 3 :** Résidus image et terrain du calcul d'aérotriangulation (EMQ = Erreur Moyenne Quadratique).



**FIGURE 9 :** Exemples de quelques spectres mesurés sur le terrain à Toulouse.

A Amiens, au cours des acquisitions terrain de spectres, les conditions météorologiques s'étaient dégradées et le couvert nuageux était devenu très dense. Du fait de ces conditions, l'éclairement a parfois varié au cours des acquisitions de mesures, perturbant donc les résultats obtenus. Afin de pouvoir prendre en compte ces problèmes, un indice de qualité  $I_Q$  est associé à chacun des spectres de réflectance calculés ; il s'agit simplement du ratio des deux mesures de luminance effectuées au-dessus du spectralon, avant et après la mesure sur le matériau (cf. Equation 2). Quelques exemples de spectres de matériaux mesurés sur le terrain sont présentés sur la figure 9.

$$I_Q = \frac{L_{spec}^1}{L_{spec}^2}. \quad (2)$$

## 5.2. Etude de la végétation arborée urbaine pour correction atmosphérique

Des mesures terrain ont été menées sur les sites n°2 et n°3 à Toulouse afin de construire un modèle de vérité terrain qui servira à la validation de nouvelles méthodes de correction atmosphérique prenant en compte la végétation arborée en milieux urbains (Adeline et al., 2012 ; Adeline et al., 2013b). Ces méthodes inverses ont pour but de remonter à la réflectance spectrale des matériaux à la fois au soleil et à l'ombre en prenant en compte les conditions atmosphériques (Partie 3), le relief 3D de la

scène (Partie 4.3) et les flux de transfert radiatif existant entre l'atmosphère, la scène et le capteur aéroporté. Les arbres étudiés sont de type feuillu sur le site n°2 : un tilleul *Tilia Cordata* (arbre n°1) et un magnolia *Magnolia Grandiflora* (arbre n°2). Tandis que sur le site n°3, on a des arbres de type conifère de la même essence Cèdre bleu de l'atlas *Cedrus Atlantica Glauca* pour les arbres n°4 et n°5.


**Mesures des propriétés optiques des feuilles et éléments ligneux (arbres n°1 et n°2).** Des mesures de réflectance et transmittance de feuilles ont été effectuées grâce à l'accessoire Leaf-Clip du spectroradiomètre de la marque ASD comportant un étalon de référence blanc et noir (Figure 3.e). En parallèle, la réflectance du tronc et des branches a été mesurée avec l'accessoire Contact Probe de ASD.

**Mesures au laser scanner terrestre et reconstruction de la géométrie 3D de l'arbre (arbres n°1-2-4-5).** Les lasers scanner 3D sont des systèmes dits à balayage qui reconstituent la surface géométrique des objets à partir d'un nuage de points 3D. Pour chaque point de la scène, ils fournissent l'information de distance et le flux rétrodiffusé par l'objet observé dans cette direction. Plusieurs points de vue sont nécessaires pour reconstituer l'intégralité de la forme 3D d'un objet. En effet, la directivité de l'éclairement et l'aspect monostatique du système introduisent des zones d'ombre si l'on considère un unique point de vue. L'ensemble des acquisitions est ensuite combiné dans un référentiel général. L'imageur laser scanner 3D de l'Onera qui a été utilisé est constitué par :

- Une source laser dont les caractéristiques en font un système facilement opérable sur le terrain (sécurité oculaire à 1,5  $\mu\text{m}$ . . .) ;
- Un capteur permettant de collecter soit le premier soit le dernier écho reçu ;
- L'acquisition et les outils de post-traitement spécifiques ;
- Une caméra visible qui permet d'imager en temps réel la scène.

Lors des mesures terrain, nous avons acquis des nuages de points sur plusieurs arbres dans leur environ-





**FIGURE 10** : Exemple d'image panoramique assemblée pour une position du véhicule Stereopolis.


nement en utilisant le mode "dernier écho" car il permet de traverser le feuillage externe d'un arbre pour imager sa structure interne. En pratique, deux points de vue ont été effectués pour reconstituer l'intégralité des arbres (Figure 3.c). Au final et après post-traitement, les branches et le tronc sont correctement maillés. Le feuillage des arbres représenté sous forme de facettes est partiellement retrouvé en considérant la variance moyenne de la taille des feuilles mesurée sur le terrain. Cette approche sous-estime le nombre de feuilles présentes dans l'arbre mais permet cependant de remonter à un modèle 3D précis de la couronne extérieure et des éléments ligneux composant les arbres (Figure 3.d).

**Mesures radiométriques pour analyser le comportement spectral et la porosité de la couronne d'un arbre (arbres n°1-2-4-5) comparativement à des structures opaques (bâtiment n°3).** Afin d'étudier l'impact radiatif des arbres notamment dans leur ombre, deux spectroradiomètres de terrain ont mesuré différentes composantes radiatives d'éclairement et de luminance reçues au niveau du sol (Figure 3.a) au-dessus à la fois de matériaux naturels (route, herbe, chemin non goudronné, etc.) et de mires de réflectance connue (lino gris clair et lino gris foncé pour les arbres n°2 et n°4). En effet, l'influence de cet impact radiatif est variable selon différents critères spécifiques à chaque espèce d'arbre : propriétés optiques des éléments de l'arbre, structure géométrique de la couronne de l'arbre et sa densité de feuille, etc. La figure 3.b illustre ces particularités propres aux arbres comparativement à des structures 3D opaques tels que des bâtiments, en montrant les écarts en luminance capteur à l'ombre qui peuvent atteindre jusqu'à peu près 50% dans le NIR et SWIR.

### 5.3. Cartographie mobile de canyons de rues urbaines et de façades


**Système de numérisation mobile Stereopolis.** Stereopolis est un système de cartographie mobile com-

posé de 16 caméras Full HD (permettant l'acquisition d'images panoramiques quasi-complètes : Figure 10), d'instruments Lidar et d'un système de navigation (2 GPS, une centrale inertielle (IMU) et un odomètre), montés sur un véhicule (Paparoditis et al., 2012) (Figure 11). Le capteur de chaque caméra est constitué d'une matrice CCD de 2 Mpixels à grande dynamique (12 bits) et un rapport signal sur bruit d'environ 200. Le champ d'un pixel est d'environ  $0,04^\circ$ , soit 0,7 cm à une distance de 10 m. Deux Lidar métrologiques à balayage Riegl LMS-Q120i ayant une précision centimétrique en distance et un champ de vue de  $80^\circ$  sont placés sur chaque côté du véhicule (observant principalement les façades des bâtiments). Un Lidar rotatif VELODYNE HDL-64E avec une fréquence d'acquisition de 1,3 millions de points par seconde et une fréquence de rotation de 10-15 Hz, est placé sur un mât sur le toit du véhicule (observant la rue et le premier étage des façades).



**FIGURE 11** : Les différents instruments embarqués sur le système de cartographie mobile Stereopolis.

**Description des données.** Stereopolis peut donc produire des jeux d'images panoramiques prises à inter-



**FIGURE 12 :** Dispositif permettant de mesurer l'éclairement solaire avec un spectralon en utilisant le bord des ombres.

valle régulier le long du parcours du véhicule, ainsi qu'un nuage de points ne possédant que peu de "zones d'ombre". Ces données sont géoréférencées en utilisant les données de navigation (GPS + IMU + odomètre) et les paramètres d'étalonnage intrinsèques aux capteurs, ainsi que la géométrie relative entre les capteurs. Les images sont corrigées radiométriquement par le flat-field de chaque caméra. Une caméra spécifique a été ajoutée pour cette campagne sur le site d'Amiens : elle pointe vers une plaque blanche horizontale de référence placée sur le toit du véhicule. Un masque composé de plusieurs bandes opaques surplombe cette plaque, permettant d'obtenir une succession de zones ensoleillées et à l'ombre quand le véhicule est exposé à la lumière directe du soleil (Figure 12). Cela permet d'estimer l'éclairement direct solaire au niveau du sol, information qui n'est pas accessible directement dans les images pointant vers le soleil, du fait de la surexposition des pixels dans le halo solaire. Ces données permettent l'étude de l'illumination de la scène à partir des images (Coubard et al., 2012), et l'estimation de la réflectance des matériaux des façades, pour des applications de corrections des images et de réalité augmentée (par exemple le ré-éclairage de la scène) (Coubard et al., 2011).

## 6. Conclusion

La campagne UMBRA a permis d'acquérir un jeu de données de référence en milieux urbains et naturels pour les applications suivantes : la validation de méthodes de correction atmosphérique adaptées notamment à la végétation urbaine, l'étude de la faisabilité de futures caméras superspectrales IGN adaptées aux caractéristiques spectrales des matériaux urbains, et enfin l'estimation de la réflectance des matériaux de façades de rues et de l'illumination du ciel à partir d'images terrestres acquises par le système Stereopolis. Ce jeu de données sera disponible et sera constitué des images corrigées radiométriquement (en luminance) et géoréférencées. L'accès à

l'ensemble des spectres de matériaux acquis se fera à partir de la base de données MEMOIRES de l'Onera (Martin et Bernard, 2012). En perspectives, l'analyse de résultats de la campagne UMBRA aidera au projet de dimensionnement du projet HYPXIM actuellement en phase A.

## Remerciements

Les auteurs remercient l'équipe de l'unité POS ainsi que des représentants de l'équipe IODI au sein du département DOTA à l'Onera, plus particulièrement Bernard Tanguy, Olivier Vaudelin, Yannick Boucher, Christophe Leroy, Thierry Huet et l'ensemble des doctorants pour leur généreuse participation sur le terrain. Sont remerciés également ceux qui ont prêté les différents instruments de mesure nécessaires à la campagne, le CEA, le LISAH, Guillaume Carrié et Laurent Castanet (DEMR, Onera). Nous remercions également les PI pour leurs efforts à établir et maintenir le site AERONET de Seysses. Les différents agents de l'IGN ayant participé à la campagne ou aux pré-traitements des données sont également remerciés. Nous remercions chaleureusement l'Université Paul Sabatier (UPS) et le CREPS à Toulouse pour nous avoir autorisé à mener des mesures terrain sur leur site. Enfin, nous remercions également le projet ANR VegDUD qui a financé la partie étude de la végétation urbaine.

## Références

- Adeline, K., Briottet, X., Paparoditis, N., 2012. Material reflectance retrieval in shadow due to urban vegetation from 3d lidar data and hyperspectral airborne imagery. In : Journal of Advances in Geoscience, Proc. of the 32nd Earsel symposium. Mykonos, Greece.
- Adeline, K., Briottet, X., Paparoditis, N., Gastellu-Etchegorry, J.-P., 2013a. Material reflectance retrieval in urban tree shadows with physics-based empirical atmospheric correction. In : Joint Urban Remote Sensing Event. São Paulo, Brazil.
- Adeline, K., Chen, M., Briottet, X., Pang, S., Paparoditis, N., 2013b. Shadow detection in very high spatial resolution aerial images : a comparative study. ISPRS Journal of Photogrammetry and Remote Sensing 80, 21–38.
- Cavalli, R. M., Fusilli, L., Pascucci, S., Pignatti, S., Santini, F., 2008. Hyperspectral sensor data capability for retrieving complex urban land cover in comparison with multispectral data : Venice city case study (Italy). Sensors 8, 3299–3320.
- Coubard, F., Brédif, M., Paparoditis, N., Briottet, X., 2011. Reflectance estimation from urban terrestrial images : Validation of a symbolic ray-tracing method on synthetic data. International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences 38 (3/W22), 71–76.
- Coubard, F., Lelégard, L., Brédif, M., Paparoditis, N., Briottet, X., 2012. Reconstruction of sky illumination domes from ground-based panorama. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences 39(B3), 269–274.
- Demarchi, L., Cheung-Wai, C., Ma, J., Canters, F., 2012. Mapping impervious surfaces from superresolution enhanced CHRIS/Proba imagery using multiple endmember unmixing.

- ISPRS Journal of Photogrammetry and Remote Sensing 72 (8), 99–112.
- Doz, S., Briottet, X., Porez-Nadal, F., Lachérade, S., 2010. Simulation of urban optical images from high spectral and spatial resolution multi-angular airborne acquisitions. In : Proc. of the IEEE International Geoscience and Remote Sensing Symposium (IGARSS). Honolulu, Hawaii, USA, pp. 3572–3575.
- Heiden, U., Heldens, W., Roessner, S., Segl, K., Esch, T., Mueller, A., 2012. Urban structure type characterization using hyperspectral remote sensing and height information. *Landscape and Urban Planning* 105 (4), 361–375.
- Heiden, U., Segl, K., Roessner, S., Kaufmann, H., 2007. Determination of robust spectral features for identification of urban surface materials in hyperspectral remote sensing data. *Remote Sensing of Environment* 111 (4), 537–552.
- Heldens, W., Heiden, U., Esch, T., Dech, S., 2010. Potential of hyperspectral data for urban micro climate analysis. In : Proc. of the Hyperspectral 2010 Workshop. Frascati, Italy.
- Heldens, W., Heiden, U., Esch, T., Stein, E., Müller, A., 2011. Can the future EnMAP mission contribute to urban applications? a literature survey. *Remote Sensing* 3, 1817–1846.
- Herold, M., Roberts, D., 2005. Spectral characteristics of asphalt road aging and deterioration : implications for remote-sensing applications. *Applied Optics* 44 (20), 4327–4334.
- Herold, M., Roberts, D., Gardner, M., Dennison, P., 2004. Spectrometry for urban area remote sensing : Development and analysis of a spectral library from 250 to 2400 nm. *Remote Sensing of Environment* 91, 304–319.
- Idoughi, R., Foucher, P.-Y., Poutier, L., Achard, V., Briottet, X., 2012. Détection de polluants atmosphériques par imagerie hyperspectrale infrarouge : étude du cas de polluants gazeux en zone industrielle à haute résolution spatiale. In : Congrès de la SFTH. Toulouse, France.
- Lachérade, S., Miesch, C., Lemaître, F., Briottet, X., Le Men, H., Boldo, D., Valorge, C., 2005. Analysis of the spectral variability of urban materials for classification. A case study over Toulouse (France). *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences* 36 (8/W27).
- Le Bris, A., Robert-Sainte, P., 2009. Classification of roof materials for rainwater pollution modelization. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences* 38(1-4-7/W5).
- Lefèvre-Fonollosa, M.-J., Michel, S., Hosford, S., 2012. HYPXIM : an innovative spectroimager for science, security, and defence requirements. *Revue Française de Photogrammétrie et de Télédétection* 200, 20–27.
- Martin, C., Bernard, R., 2012. Status of “MEMOIRES” - a thermal and optical data base (Mean of Exchange and valorization of Measurements of thermal, Optical and InfraREd properties of Samples and scenes). In : Fraunhofer IOSB. Ettlingen, Allemagne.
- Masson, V., 2008. The Canopy and Aerosol Particles Interactions in TOulouse Urban Layer (CAPITOU) experiment. *Meteorology and Atmospheric Physics* 102 (3-4), 135–157.
- Mestayer, P., Bagga, I., Calmet, I., Fontanilles, G., Gaudin, D., Lee, J., Piquet, T., Rosant, J.-M., Chancibault, K., Lebourg, L., Letellier, L., Mosini, M.-L., Rodriguez, F., Rouaud, J.-M., Sabre, M., Tétard, Y., Brut, A., Selves, J.-L., Solignac, P.-A., Brunet, Y., Dayau, S., Irvine, M., Lagouarde, J.-P., Kassouk, A., Launeau, P., Connan, O., Defenouillère, P., Goriaux, M., Hébert, D., Letellier, B., Maro, D., Najjar, G., Nerry, F., Quentin, C., Biron, R., J.-M., C., Galvez, J., Klein, P., 2011. FluxSAP 2010 Experimental campaign over an heterogeneous urban zone, Part 1 heat and vapour flux assessment. In : Proceedings of the 14th Conference on Harmonisation within Atmospheric Dispersion Modelling for Regulatory Purposes. Kos, Greece.
- Mestayer, P., Durand, P., Augustin, P., Bastin, S., Bonnefond, J.-M., Benech, B., Campistron, B., Coppalle, A., Delbarre, H., Dousset, B., Drobinski, P., Druilhet, A., Frejafon, E., Grimmond, C., Groleau, D., Irbine, M., Kergomard, C., Kermadi, S., Lagouarde, J.-P., Lemonsu, A., Lohou, F., Long, N., Masson, V., Moppert, C., Noilhan, J., Offerle, B., Oke, T., Pigeon, G., Puygrenier, V., Roberts, S., Rosant, J.-M., Saïd, F., Salmont, J., Talbaut, M., Voogt, J., 2005. The urban boundary-layer field campaign in Marseille (UBL/CLU-ESCOMPTE) : set-up and first results. *Boundary-Layer Meteorology* 114 (2), 315–365.
- Nagao, M., Matsuyama, T., Ikeda, Y., 1979. Region extraction and shape analysis in aerial photographs. *Computer Graphics and Image Processing* 10 (3), 195–223.
- Paparoditis, N., Papelard, J.-P., Cannelle, B., Devaux, A., Soheilian, B., David, N., Houzay, E., 2012. Stereopolis II : A multi-purpose and multi-sensor 3D mobile mapping system for street visualisation and 3D metrology. *Revue Française de Photogrammétrie et de Télédétection* 200, 69–79.
- Pauwels, V., Timmermans, W., Loew, A., 2008. Comparison of the estimated water and energy budgets of a large winter wheat field during AgriSAR 2006 by multiple sensors and models. *Journal of Hydrology* 349 (3-4), 425–440.
- Pierrot-Deseilligny, M., Paparoditis, N., 2006. A multiresolution and optimization-based image matching approach : An application to surface reconstruction from SPOT5-HRS stereo imagery. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 36 (1/W41).
- Poutier, L., Miesch, C., Lénot, X., Achard, V., Boucher, Y., 2002. COMANCHE and COCHISE : two reciprocal atmospheric codes for hyperspectral remote sensing. In : Proc. AVIRIS Earth Science and Applications Workshop.
- Roessner, S., Segl, K., Heiden, U., Kaufmann, H., 2001. Automated differentiation of urban surfaces based on airborne hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing* 39 (7), 1525–1532.
- Shafri, H., Taherzadeh, E., Mansor, S., Ashurov, R., 2012. Hyperspectral remote sensing of urban areas : an overview of techniques and applications. *Research Journal of Applied Sciences, Engineering and Technology* 4 (11), 1557–1565.
- Sobrino, J., Bianchi, R., Paganini, M., Sória, G., Jiménez-Muñoz, J., Oltra-Carrió, R., Mattar, C., Romaguera, M., Franch, B., Hidalgo, V., Cuenca, J., Julien, Y., Atitar, M., Fernández-Renau, A., Gómez, J., de Miguel, E., Gutiérrez de la Cámara, O., Jiménez, M., Prado, E., Rodríguez-Cantano, R., Ruiz, I., Nerry, F., Najjar, G., Kastendeutch, P., Pujadas, M., Molero, F., Moreno, J., Alonso, L., Fernández, F., Galán, E., Cañada, R., Romero, J., Calpe-Maravilla, J., Camps-Valls, G., Bosch-Magraner, M., Puente-Robles, R., Cordero-Salvador, J., Torres-Carrero, J., Duque-Cuesta, M., Moya, F., Labajo, A., Labajo, S., Hidalgo-Rodríguez, J., Acero, J., Hernández-Martín, E., Martilli, A., Salamanca, F., Gimeno-Presa, L., Pigeon, G., 2009. Dual-use European Security IR Experiment 2008 (DESIREX 2008) Final Report. Tech. rep., European Space Agency, contract n° : 21717/08/LG, <http://www.uv.es/desirex>.
- Souchon, J.-P., Thom, C., Meynard, C., Martin, O., 2012. A large format camera system for national mapping purposes. *Revue Française de Photogrammétrie et de Télédétection* 200, 48–53.
- Souchon, J.-P., Thom, C., Meynard, C., Martin, O., Pierrot-Deseilligny, M., 2010. The IGN CAMv2 system. *The Photogrammetric Record* 25 (32), 402–421.
- Vermote, E., Tanré, D., Deuzé, J., Herman, M., Morcrette, J.-J., 1997. Second Simulation of the Satellite Signal in the Solar Spectrum, 6S : an overview. *IEEE Transactions on Geos-*

cience and Remote sensing 35 (3), 675–686.

Viallefont, F., Poutier, L., Foucher, P.-Y., Adeline, K., Briottet, X., 2013. Radiometric calibration and validation of hyperspectral camera for UMBRA airborne campaign. ISPRS Journal of Photogrammetry and Remote Sensing Submitted.

Weng, Q., 2012. Remote sensing of impervious surfaces in the urban areas : requirements, methods and trends. Remote Sensing of Environment 117 (2), 24–49.

# VERY HIGH RESOLUTION LAND COVER EXTRACTION IN URBAN AREAS: VERY HIGH RESOLUTION URBAN LAND COVER EXTRACTION USING AIRBORNE HYPERSPETRAL IMAGES

A. Le Bris<sup>a</sup>, N. Chehata<sup>a,c</sup>, X. Briottet<sup>b</sup>, N. Paparoditis<sup>a</sup>

<sup>a</sup> IGN/SR, MATIS, Université Paris Est, Saint Mandé, France - (arnaud.le-bris, nicolas.paparoditis, nesrine.chehata)@ign.fr

<sup>b</sup> ONERA, The French Aerospace Lab, Toulouse, France – Xavier.briottet@onera.fr

<sup>c</sup> IRD/UMR LISAH, Tunis, Tunisie

**KEY WORDS:** Classification, Land cover, Urban areas, Material classification, Airborne imagery, Camera design

## ABSTRACT:

During last decade, needs for high resolution land cover data have been growing. Such knowledge is namely often required in environment monitoring studies. Thus, to answer these needs, national mapping or environment agencies, in many countries, have undertaken the production of such large scale national land cover database. Nevertheless, these databases provide a general classification and may not suit some specific (often new) applications requiring a semantic or geometric finer level of details. That is to say that, on one hand, additional land cover classes should sometimes be specified, whereas, on the other hand, some existing classes should be delineated at a finer level.

More particularly, in urban areas, knowledge concerning very high resolution land cover and especially material classification are necessary for several city modelling applications. Most of these applications are still experimental scientific ones in various fields such as micro-meteorology, hydrology, pollutants flow monitoring and ground perviousness monitoring. Thus, knowledge concerning the roofing materials or the different kinds of ground areas (pervious, vegetated, impervious...) are required. Airborne remote sensing techniques appear to be convenient for providing such information at a large scale since no existing map contains such information. However, remote sensing imagery of urban environments from airborne acquisitions namely still remains a major scientific issue, since on one hand, urban areas are characterized by a high variety of materials, and on the other hand, results provided by most of the traditional processing methods based on usual red-green-blue-near infrared multispectral images remain limited for such applications. A possible way to improve classification results is to enhance the imagery spectral resolution using superspectral or hyperspectral imagery.

Thus, the present experiments are part of a work aiming at designing a future superspectral camera system dedicated to high resolution urban land cover classification applications, and especially material mapping. The choice of optimal band sets will here be processed from a set of airborne hyperspectral data.

A data acquisition campaign named UMBRA has recently been carried out thanks to the French collaboration of IGN<sup>1</sup> and ONERA<sup>2</sup>. Data have been captured over two French cities chosen for their difference in building architecture, urbanization planning and their variety in urban material. Airborne images have been acquired simultaneously by multispectral and hyperspectral cameras with a ground sampling distance ranging from 0.12m for multispectral to 1.6m for hyperspectral in the SWIR channels. The images were radiometrically and geometrically calibrated and have a noticeable low signal-to-noise ratio.

The first urban land cover / material classification results obtained from this new reference data set will be presented in this paper.

## 1. NEEDS AND POTENTIAL APPLICATIONS INVOLVING VERY HIGH RESOLUTION URBAN LAND COVER

In urban areas, knowledge about very high resolution land cover and especially maps of the urban materials are required by several city modelling applications. Urban environment is indeed strongly influenced, in terms of ecology, energy and climate by the present materials. These materials can be either natural or artificial. Most of these applications are still experimental scientific ones such as micro-meteorology, hydrology, pollutants flow monitoring and ground perviousness monitoring. Several possible applications requiring very high resolution knowledge about urban land cover and materials are listed in (Heldens et al., 2011) and (Shafri et al., 2012).

---

<sup>1</sup> IGN is the French National Institute of Geographic and Forest Information

<sup>2</sup> ONERA is the French Aerospace Lab, that is to say the French aeronautics, space and defense research lab



### **1.1 Quantification of pollutant flows from roofs in urban rainwaters**

Some roofing materials can generate pollutant elements. Thus, in the actual context of the European Water Framework Directive (2000/60 CE), whose aim is to obtain a good ecological state of aquatic environments, it seems necessary to reduce the production of pollutants at their sources. This implies to identify sources and to quantify emissions.

Several kinds of pollutions are generated by roofing materials. First, it has been proven that roof runoff water plays an important role in the high metallic concentration levels in urban rainwater since metallic elements are generated by corrosion of roof materials before being swept away by rainwater. Zinc-based materials are largely used in urban areas, especially for infrastructure, such as furniture or siding and roofing for buildings. Exposed to atmospheric conditions, these materials are progressively corroded. During a rain event, a part of the corrosion products formed at their surface will be released and washed off. In Paris, experiments have established that atmospheric corrosion of roofing materials could be a major source of zinc, cadmium, lead and copper during wet weather (Chebbo et al., 2001). Several researches on identification of metals from roofing materials have been carried out, showing that zinc emissions are mainly in the labile form (Heijerick et al., 2002), which is bioavailable and therefore harmful to aquatic organisms (both animals and plants). Copper roofs have also been identified as a possible source of pollution.

Last, some other kinds of roofing materials can help to release organic polluting elements (polycyclic aromatic compounds, organic carbon) due to a not visible bitumen layer (Lemp et al., 2004 ; Lemp et al., 2005).

Laboratory experiments have often already been done to model pollutant runoff rates for roofing materials (for instance, see (Robert-Sainte, 2009) for metallic elements). Knowledge about the different roof coverage areas is thus required to be able to extrapolate these results to whole drainage areas: a map of roofing materials is thus needed.

Previous works aiming at extracting maps of roofing material out of airborne imagery exist. (Le Bris et al., 2009) performed supervised classification of red-green-blue-near infra-red aerial ortho-images. Non roof areas were masked using building objects of a topographic database. (Lemp et al., 2004 ; Lemp et al., 2005) used hyperspectral HyMap data in association with Lidar measurements. Slope information derived from such 3D data was shown to be useful to help the discrimination between some roofing material classes. More recently, (Chisense et al., 2012) obtained good results using HyMap data: 11 features were first extracted (using projection pursuit and LDA) and supervised classification was then performed.

### **1.2 Monitoring of asbestos-cement roofs**

Another possible application in the field of urban materials concerns the monitoring of asbestos-cement roofing materials (Heldens et al., 2011 ; Bassani et al., 2007 ; Marino et al., 2000). Asbestos-cement based materials can indeed be dangerous for human health, especially when they are deteriorated. Therefore, it is important to be at least able to evaluate the amount of buildings covered by asbestos-cement roofing sheets. Evaluating their deterioration status is also a useful issue. A method to achieve this using hyperspectral images has been proposed in (Bassani et al., 2007): it focuses on special spectral bands identified from spectrum analysis.

### **1.3 Electro-magnetic wave propagation models used to define the best location for telecommunication infrastructure**

Such possible application is mentioned by (Carrileiro et al., 2001). (Carrileiro et al., 2001) indeed aimed at obtaining material maps in order to enrich 3D building models used as input data of electro-magnetic waves propagation simulators used to define the best location for telecommunication infrastructures (that is to say antennas).

### **1.4 Determination of road type and monitoring of road condition**

Other applications in the field of urban materials concern road materials. At least, maps of road types (cobblestone, asphalt ...) can be useful for some applications. A more important and complex application focuses on the monitoring of road condition: such information indeed offers great interest for authorities in charge of the planning of road network renovation projects. Extracting this knowledge out of aerial data could be a way to avoid expensive and long field investigation (Herold et al., 2004b).

Two examples of methods aiming at determining road condition from aerial hyperspectral data are presented in (Herold et al., 2004b) and (Mohammadi, 2012). These works focus on special spectral bands identified from spectrum analysis.

### **1.5 Monitoring of ground perviousness**

Two kinds of applications requiring knowledge about ground perviousness exist.

On one hand, it has been shown that the continuous development of impervious areas (especially in the periphery of cities), such as wide parking areas in commercial districts, plays an important role in the aggravation of flooding events, both in terms of magnitude and speed. Thus, having tools making it possible to monitor the extension of impervious areas and to check their appliance to new legislations would really be useful.

On the other hand, perviousness maps are required by ("micro") hydrological models (Heldens, 2011). For instance, (Kermadi et al., 2010) extracted a land cover classification out of multispectral images with a very high spatial resolution such as BDOortho or QuickBird and then integrated this data in hydrological models. This example is not a "micro" hydrological one and land cover classes do not correspond to specific materials. Other studies aiming at mapping ground perviousness in urban areas used unmixing approaches applied to lower spatial resolution hyperspectral data (Roessner et al., 2001 ; Demarchi et al., 2012).

## 1.6 Weather models

Very fine knowledge concerning urban land cover (in terms of materials, perviousness and vegetation) are required by “micro” weather (wind, temperature, ...) model simulators (Heldens et al., 2011 ; Heldens et al., 2010).

## 2. VERY HIGH RESOLUTION URBAN LAND COVER: WHICH NOMENCLATURE AND EXTRACTION PROCESS?

### 2.1 Urban land cover nomenclatures

Several urban land cover nomenclatures have been proposed in literature. Most of them are related to the specific applications aimed at in the different papers and have therefore more or less detailed material classes as in (Cavalli et al., 2008).

Some of them include different levels of details, as (Heiden et al., 2007) or (Franke et al., 2009).

The most exhaustive ones focused on urban materials and have been presented in (Heiden et al., 2007) and (Herold et al., 2004a).

### 2.2 Extracting very high resolution urban land cover

Very high resolution urban land cover is required to provide knowledge about the roofing materials and the different kinds of ground areas. Such information can be a map of urban material (i.e. a classification) as for instance in (Lemp et al., 2005) or statistics giving the proportion of the different materials in some cells (cf unmixing approaches) as in (Demarchi et al., 2012 ; Franke et al., 2009 ; Roessner et al., 2001).

Since no existing map contains such information, airborne remote sensing techniques often appear to be convenient for obtaining such a map at a large scale. However, remote sensing of urban environments from airborne acquisitions namely still remains a major scientific issue, since on one hand, urban areas are characterized by a high variety of materials which can appear very on images, and on the other hand, results provided by most of the traditional processing methods based on usual red-green-blue-near infrared multispectral images remain limited for such applications. A possible way to improve classification results is to enhance the imagery spectral resolution using superspectral or hyperspectral imagery.

### 2.3 Toward a superspectral camera dedicated to urban materials application ?

Our final goal aims at identifying the most suitable set of 25 spectral bands (defining both their position in spectrum and their width), in order to design a superspectral camera system dedicated to urban land cover applications, that is to say more particularly to identify urban materials. It has namely been shown by (Herold et al., 2004) that it was possible to select a subset of spectral bands making it possible to discriminate between most urban materials classes.

Such sensor could be adapted (especially in case of bands in the VNIR domain) from IGN CamV2 aerial cameras (Souchon et al., 2010), which offer a very modular system, making it possible to use adapted spectral filters.

Such superspectral system could offer some advantages compared to most hyperspectral sensors. It would first offer the possibility to combine the use of suitable spectral bands for a specific application with a high spatial resolution. It would also offer a larger swath. It would be a photogrammetric system, making it possible to obtain 3D models (DSM). Besides, using a CCD array sensor instead of a push-broom sensor, it would make it possible to capture multistereoscopic images, offering thus a possible calculation of BRDF models (Martinoty, 2005).

The choice of optimal band sets will be processed here from a set of airborne hyperspectral data captured during a data acquisition campaign named UMBRA (Adeline et al., 2013).

## 3. THE UMBRA CAMPAIGN

The UMBRA campaign (Adeline et al., 2013) was carried out thanks to the French collaboration of IGN and ONERA, and took place on 23th-25th October 2012. It aims at acquiring a new reference dataset representative of two different kinds of French cities. This data set is first devoted to two main applications : on one hand, the development and validation of a new atmospheric correction method in sunlit and shaded urban areas and, on the other hand, to the definition of a future superspectral camera system for high resolution urban land cover classification, as explained above. However, several secondary studies have also been considered: target detection, sensor radiometric calibration, fusion (~ pan sharpening) of hyperspectral images with very high spatial resolution IGN CamV2 images in the context of the preparatory program of the HypXim satellite, aerosol and smoke analysis and other various applications aiming at evaluating the human influence on urban ecosystems.

Images were captured over two French cities: Toulouse and Amiens. These two cities had been chosen for their difference in building architecture, urbanization plan and their variety in urban materials. On one hand, they are sufficiently important cities to offer distinct kinds of urban land covers with dense downtowns, residential areas with individual or collective housings, industrial/commercial areas, transport infrastructures highway, railway, airport), vegetated (parks, gardens) and water areas. On the other hand, these two cities can be considered as typical of most French cities: Amiens as an example of Northern French cities and Toulouse for the South-Western part of the country.

Airborne images were acquired at high spatial and spectral resolution by panchromatic, multispectral and hyperspectral cameras. Images were indeed captured simultaneously by two distinct sensors mounted on a same aircraft: very high spectral resolution images were captured by an hyperspectral Hypspx sensor (wavelength is between 400 and 2500nm, ground sample distance (GSD) ~ 80cm for VNIR and 1.6m for SWIR) while very high spatial resolution images were acquired by the IGN CamV2 system (Souchon et al.,

2010) (4 bands red-green-blue-near infrared, GSD ~ 12.5cm). Thus, both remote sensing data and photogrammetric data have been acquired, which will make it possible to calculate 3D models.

Radiometric field measurements were also collected during the whole aerial acquisition, aiming both at characterizing the atmosphere, acquiring a ground truth for reflectance retrieval, and collecting spectra of some urban materials.

#### 4. VERY FIRST CLASSIFICATION RESULTS FROM THE UMBRA DATA SET

This paper intends to present very first land cover classification results obtained using the UMBRA data set. It must be kept in mind that at present the data set has still not been fully pre-processed. Therefore, **only raw radiance VNIR** hyperspectral images have here been used.

The nomenclature retained for this classification remains quite simple, with 9 material/land cover classes : red tiles – slates – metal 1 based roofing material - metal 2 based roofing material – asphalt – cobblestone pavements – bare soil – high vegetation – low vegetation. We are aware that this legend remains quite simple for a study of urban materials and that other important classes should be added, as for instance railway areas, gravels (which will here be classified as bare soil or cobblestone pavements), cement and water areas.

All the land cover classification results presented above have been obtained using a per pixel linear SVM classifier. The ability of SVM to perform good classification of hyperspectral data has indeed already been shown (Melgani et al., 2004 ; Camps-Valls et al., 2005). The libSVM implementation (Cheng et al., 2011) has here been used and trained by 200 pixels per class. Obtained classification results have been evaluated from a small test data set, plotted with the help of aerial very high resolution images (texture information) and “streetview” images.

##### 4.1 Results obtained using raw VNIR radiance hyperspectral data

Encouraging results are obtained directly from the whole raw hyperspectral VNIR spectra. No optimisation of the “c” parameter of the SVM (i.e. the penalty associated to classification errors during training phase) has been performed, in order to better compare the influence of input data. Almost 92.5 % of ground truth test pixels have been well classified (see confusion matrix in table 1, user and producer accuracies in table 2 and examples of classification results in figure 1).

It can be noticed from figure 1, that because of slope effect, some roof parts covered by red tiles have been misclassified as cobblestone pavement areas. Because of their specular behaviour, slates are sometimes misclassified with other classes, such as metal when they are enlighten, or asphalt, which is also a “dark” class.

Some misclassification between cobblestone pavements and bare soils occurs: it can be caused by the fact that there is no specific gravel class, and that some gravel areas have been included in the bare soil ground truth, while they sometimes tend to be classified as concrete. There are also sometimes misclassifications between asphalt and concrete (but some of them could correspond to the presence of mixed pixels).

GT/classif	RedTile	Slates	Metal1	HighVeget	LowVeget	Asphalt	BareSoil	Metal2	Cobblestone
RedTiles	10371	41	6	0	17	31	564	23	160
Slates	0	692	15	0	0	62	0	3	5
Metal 1	0	88	1111	0	0	12	1	53	2
HighVeget	0	0	0	8174	1020	0	1	0	0
LowVeget	79	8	0	1407	37364	1	10	0	2
Asphalt	6	62	0	7	47	9209	13	110	650
Bare soil	4	0	3	0	8	2	1348	9	3
Metal 2	0	1	19	0	0	9	14	831	5
Cobblestone	19	61	4	0	37	1394	43	50	7146

Table 1. Confusion matrix obtained from classification of raw radiance VNIR spectra

	User accuray	Producer accuracy
RedTiles	98.97	92.49
Slates	72.61	89.06
Metal 1	95.94	87.69
HighVeget	85.25	88.90
LowVeget	97.07	96.12
Asphalt	85.90	91.14
Bare soil	67.60	97.89
Metal 2	77.02	94.54
Cobblestone	89.63	81.63

Table 2. User and producer accuracies of classification of raw radiance VNIR spectra




Figure 1. Examples of classification results on the Toulouse data set. Only raw radiance VNIR images have been used. On these illustrations, classification results have been regularized: the label given to a pixel is decided after a vote of pixels belonging to a 5x5 neighbourhood window around the current pixel.

#### 4.2 Results obtained using normalized VNIR radiance hyperspectral data

In order to try to take into account slope effects, an other classification experiment has been performed on normalized radiance spectra. Overall accuracy has not changed a lot (92.9% well classified pixels), but discrimination of red tiles has been improved. On the opposite, more asphalt areas have been misclassified as slates, and more bare ground areas have been considered as cobblestone pavements. As for previous test, no optimisation of the  $c$  parameter of the SVM has been performed.

GT/classif	RedTile	Slates	Metal1	HighVeget	LowVeget	Asphalt	BareSoil	Metal2	Cobblestone
RedTiles	10531	33	12	0	5	52	462	7	111
Slates	0	713	32	0	0	23	0	1	8
Metal 1	0	35	1202	0	0	8	1	12	9
HighVeget	0	0	0	8477	716	2	0	0	0
LowVeget	42	66	0	1081	37606	25	51	0	0
Asphalt	7	465	2	28	16	9113	13	15	445
Bare soil	1	1	5	0	5	3	1327	1	34
Metal 2	0	0	20	0	0	5	5	847	2
Cobbelstone	15	96	5	1	35	1325	515	9	6753

Table 3. Confusion matrix obtained from classification of normalized radiance VNIR spectra

	User accuracy	Producer accuracy
RedTiles	99.39	93.92
Slates	50.60	91.76
Metal 1	94.05	94.87
HighVeget	88.42	92.19
LowVeget	97.98	96.75
Asphalt	86.33	90.19
Bare soil	55.90	96.37
Metal 2	94.96	96.36
Cobblestone	91.73	77.14

Table 4. User and producer accuracies of classification of normalized radiance VNIR spectra

#### 4.3 Results obtained using only 4 bands belonging to red-green-blue-near infrared

Classification was also performed on only 4 bands corresponding to red-green-blue-near infrared bands. An overall accuracy of 73% is obtained without optimizing the “*c*” parameter of the SVM (i.e. the penalty associated to classification errors during training phase), and reached 85% after having optimized this parameter.

#### 4.4 Results obtained using a subset of ACP components

An ACP of the VNIR data set has been calculated. Classification has been performed using only 10 and 20 bands of the PCA. Using the 20 first bands of the PCA, 86% of ground truth pixels have been well classified, without optimizing the “*c*” parameter of SVM. This rate has increased to 90.5% when this parameter is optimized. Classification result from the 10 first bands of the PCA, the overall accuracy has reached almost 75% without optimization of the “*c*” parameter of the SVM and has also increased to 90%, after optimization.

#### 4.5 Conclusion and future work

Obtained results are encouraging, even if some misclassifications between some classes have occurred. Nevertheless, it must be kept in mind that these are very first results, and that further investigations must be led, to improve the classification nomenclature and the ground truth reference data set.

Other classifiers, such as Spectral Angle Mapper, Import Vector Machines (Zhu et al., 2005) which have been shown to perform well when applied to hyperspectral data (Braun et al., 2012), or Random Forest (Breiman, 2001) should also be tested. Further investigation will also strongly focus on band selection.

The SWIR spectra of the airborne acquisition is also available and should be used.

### REFERENCES

- Adeline, K., Le Bris, A., Briottet, X., Papanoditis, N., Achard, V., Airault, S., Boucher, Y., Coubard, F., David, N., Deliot, P., Duffaut, J., Foucher, P.-Y., Leroy, C., Maillet, G., Papelard, J.-P., Poutier, L., Rivière, N., Souchon, J.-P., Tanguy, B., Thom, C., Vaudelin, O., Viallefont, F., 2013. Urban Material characterization in the sun and shade of Built-up structures and trees and their Retrieval from Airborne image acquisitions (UMBRA) over two French cities. In: *Proc. of the 8<sup>th</sup> EARSeL SIG Imaging Spectroscopy Workshop*, Nantes, France.
- Bassani, C., Cavalli, R.M., Cavalcante, F., Cuomo, V., Palombo, A., Pascucci, S., Pignatti, S., 2007. Deterioration status of asbestos-cement roofing sheets assessed by analyzing hyperspectral data. *Remote Sensing of Environment*, 109(3), pp. 361-378.
- Braun, A.C., Weidner, U., Hinz, S., 2012. Classification in High-Dimensional Feature Spaces – Assessment Using SVM, IVM and RVM With Focus on Simulated EnMAP Data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(2), pp. 436-443.
- Breiman, L. 2001. Random Forests. *Machine Learning*, 45(1), pp. 5–32.
- Camps-Valls, G., Bruzzone, L., 2005. Kernel-based methods for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 43(6), pp. 1351-1362.
- Carrilero, A.C., Maître, H., Roux, M., 2001. Material determination from reflectance properties in aerial urban images. In: *Proc. of the 11th International Conference on Image Analysis and Processing (ICIP'01)*, Palermo, Italy.

- Cavalli, R.M., Fusilli, L., Pascucci, S., Pignatti, S., Santini, F., 2008, Hyperspectral sensor data capability for retrieving complex urban land cover in comparison with multispectral data : Venice city case study (Italy). *Sensors*, 8, pp. 3299-3320.
- Chang, C.C., Lin, C.J., 2011, LIBSVM: a library for support vector machines. *ACM Transactions on Intelligent Systems and Technology*, 2(3), pp. 27:1-27:27.
- Chebbo, G., Gromaire, M.C., Ahyerre, M., Garnaud, S., 2001. Production and transport of urban wet weather pollution in combined sewer systems : the Marais experimental catchment in Paris. *Urban Water*, 3(1-2), pp. 3-15.
- Chisense, C., 2012. Classification of roof materials using hyperspectral data. In: *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, Melbourne, Australia, Vol. XXXIX, Part B7, pp. 103-107.
- Demarchi, L., Chan, J. C.-W., Ma, J., Canters, F., 2012. Mapping impervious surfaces from superresolution enhanced CHRIS/Proba imagery using multiple endmember unmixing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 72(8), pp.99-112.
- Franke, J., Roberts, D.A., Halligan, K., Menz, G., 2009. Hierarchical multiple endmember spectral mixture analysis (MESMA) of hyperspectral imagery for urban environments. *Remote Sensing of Environment*, 113(8), pp. 1712-1723.
- Heiden, U., Segl, K., Roessner, S., Kaufmann, H., 2007. Determination of robust spectral features for identification of urban surface materials in hyperspectral remote sensing data. *Remote Sensing of Environment*, 111(4), pp. 537-552.
- Heijerick, D., Janssen, J., Karlen, C., Odnevall Wallinder, I., Leygraf, C., 2002. Bioavailability of zinc in runoff water from roofing materials. *Chemosphere*, 47, pp. 1073-1080.
- Heldens, W., Heiden, U., Esch, T., Dech, S., 2010. Potential of hyperspectral data for urban micro climate analysis. In: *Proc. of the Hyperspectral 2010 Workshop*.
- Heldens, W., Heiden, U., Esch, T., Stein, E., Müller, A., 2011. Can the future enmap mission contribute to urban applications ? A literature survey. *Remote Sensing*, 3, pp. 1817-1846.
- Herold, M., Roberts, D.A., Gardner, M.E., Dennison, P.E., 2004a, Spectrometry for urban area remote sensing—development and analysis of a spectral library from 350 to 2400 nm. *Remote Sensing of Environment*, 91(3-4), pp. 304-319.
- Herold, M., Roberts, D.A., Smadi, O., Noronha, V., 2004b, Road condition mapping using hyperspectral remote sensing. In: *Proc. of the AVIRIS Workshop*, Pasadena, USA.
- Kermadi, S., Renard, F., Jacqueminet, C., Michel, K., 2010, Inondations et occupation du sol dans un bassin versant périurbain : l'Yzeron (ouest lyonnais). In *Risques et changement climatique : actes du 23ième Colloque de l'Association Internationale de Climatologie*, Rennes, France, pp. 313–318.
- Le Bris, A., Robert-Sainte, P., 2009. Classification of roof materials for rainwater pollution modelization. In: *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, Hanover, Germany, Vol. XXXVIII, Part 1-4-7/W5.
- Lemp, D., Weidner, U. 2004. Use of hyperspectral and laser scanning data for the characterization of surfaces in urban areas. In: *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol. XXXV, Part B7.
- Lemp, D., Weidner, U. 2005. Improvements of roof surface classification using hyperspectral and laser scanning data areas. In: *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, Vol. XXXVI, Part 8/W27.
- Marino, C.M., Panigada, C., Busetto, L., Galli, A., Boschetti, M., 2000. Environmental applications of airborne remote sensing : asbestos concrete sheeting identification and mapping. In: *Proc. of the 14<sup>th</sup> International Conference Workshops Applied Geologic Remote Sensing (WAGRS'2000)*.
- Martinoty, G., 2005. *Reconnaissance de matériaux sur des images aériennes en multirecouvrement, par identification de fonctions de réflectance bidirectionnelles*. PhD thesis, Université Paris 7 - Denis Diderot.
- Melgani, F., Bruzzone, L., 2004. Classification of hyperspectral remote sensing images with support vector machines. *IEEE Transactions on Geoscience and Remote Sensing*, 42(8), pp. 1778-1790.
- Mohammadi, M., 2012, Road classification and condition determination using hyperspectral imagery. In: *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Melbourne, Australia, Vol. XXXIX, Part B7, pp. 141-146.
- Roessner, S., Segl, K., Heiden, U., Kaufmann, H., 2001, Automated differentiation of urban surfaces based on airborne hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 39(7), pp. 1525-1532.

Souchon, J.-P., Thom, C., Meynard, C., Martin, O., Pierrot-Deseilligny, M., 2010. The IGN CAMv2 System. *The Photogrammetric Record*, 25(32), pp. 402-421.

Shafri, H. Z.M., Taherzadeh, E., Mansor, S., Ashurov, R., 2012. Hyperspectral remote sensing of urban areas: an overview of techniques and applications. *Research Journal of Applied Sciences, Engineering and Technology*, 4(11), pp. 1557-1565.

Zhu, J., Hastie, T., 2005. Kernel Logistic Regression and the Import Vector Machine. *Journal of Computational and Graphical Statistics*, 14(1), pp. 185–205.

# CONTRIBUTION OF BAND SELECTION AND FUSION FOR HYPERSPECTRAL CLASSIFICATION

Nesrine Chehata (a,b), Arnaud Le Bris (c) and Safa Najjar (d)

(a) IRD/UMR LISAH El Menzah 4, Tunis, Tunisia

(b) EA 4592 G&E, ENSEGD-IPB, University of Bordeaux, 1, allée F. Daguin, 33 607 Pessac Cedex, France

(c) Université Paris-Est, IGN/SR, MATIS, 73 avenue de Paris, 94160 Saint Mandé, France

(d) ENSI Ecole Nationale des Sciences Informatiques, La mannouba, Tunisie

## ABSTRACT

For some specific land cover classification problems, it may be interesting to design superspectral camera systems with reduced numbers of bands ( $\sim 20$ ) and optimized band widths. This paper assesses the contribution of band selection and band fusion processes separately and jointly for dimensionality reduction. The proposed approach is fully automatic and based on a wrapper feature selection using Random forest classifier and a similarity-based fusion process. While combining both processes, selection before fusion gave the best results, reducing by almost 91% the number of bands while keeping satisfying accuracies. Results are presented on Indian Pines, Salinas and Pavia Centre hyperspectral datasets.

*Index Terms*— Hyperspectral, feature selection, band fusion, random forests, classification, dimensionality reduction

## 1. INTRODUCTION

Airborne or satellite hyperspectral imagery allows the collection of ground spectra in hundreds of narrow spectral bands. These images provide detailed spectral signatures of different objects but they lead to large datasets with highly redundant spectral bands. Classifying a high dimensionality data using a small training set may reduce the classifier performance [1]. This behaviour is known as Hughes phenomenon. In order to process hyperspectral data more efficiently in terms of computing time, storage volume, and to alleviate the Hughes phenomenon, dimensionality reduction is often processed. There are two approaches to reduce the number of features: 1) feature extraction which generates new features by combining existing features such as principal components analysis (PCA), Minimum Noise Fraction (MNF) 2) feature selection which consists in selecting a subset of initial features with regard to a given criteria. This approach has the advantages of keeping physical meanings of selected bands.

Feature selection (FS) methods can be distinguished into 3 groups; 1) **Filter** methods compute a score of relevance for each feature independently from any classifier but they ignore variable dependencies [2]. Some FS methods rank features

according to a score of importance, as the well known Relief-F method [3], or the Fischer score. Separability measures such as Bhattacharyya or Jeffreys-Matusita (JM) distances can be used in order to identify the set of features that best separate classes [4, 5]. High order statistics from information theory such as entropy and mutual information can also be used to select the best feature sets [6] 2) **Wrapper** methods are application-dependent since they depend on classifiers. Best subset features are those that still achieve a good predictive performance while reducing the number of features. Examples can be found in [7] using SVM classifier or [8] using random forests. 3) **Embedded** methods are also related to a classifier, but feature selection is performed using a feature relevance score different from a classification accuracy. SVM-RFE [9] considers the importance of different features using a SVM model. It has been extended to multiple kernel SVM by [10]. Other embedded approaches evaluate the relevance of feature subsets. For instance, [11] uses the margin of a SVM classifier as a separability measure to rank sets of features.

All previous works provide a selected subset of initial bands. At our knowledge, band fusion has not been investigated in literature as a dimensionality reduction approach. In this work, we aim to assess the contribution of band selection and band fusion processes separately and jointly for hyperspectral data classification.

## 2. PROPOSED METHODOLOGY

### 2.1. Random forests and feature importance

Random Forests (RF) [12] is an ensemble classifier that combines decision trees built from  $T$  multiple bootstrapped training samples. For each node of a tree, a subset of features is randomly selected. The best feature that minimizes the Gini impurity [12] of the node is used for the split. For an instance, each tree gives a unit vote for the most popular class. The final label is determined by a majority vote of all trees.

Besides RF provide a measure of feature importance that is processed on OOB data (Out-Of-Bag samples). The per-



mutation importance measure of a feature  $f$  is estimated by randomly permuting all its values in the OOB samples for each tree. The feature importance corresponds to the difference between prediction accuracy before and after permuting feature  $f$ , averaged over all the trees. The higher the mean accuracy decrease, the more important the feature. This feature importance measure has been successfully applied to hyperspectral data [13].

## 2.2. Band selection by Random Forests

Band selection is processed by a wrapper approach based on iterative backward elimination of features using random Forests (varSelRF). It was first proposed by [8] to select genes of microarray data. The authors showed its robustness to noise and redundant features. It was then applied to remote sensing data [14].

To select the most relevant features, Random Forests is iteratively fit. The feature importances are calculated once to avoid overfitting. At each iteration, a fraction of the least important features is eliminated and a new forest is built. By default, the fraction is fixed to 0.2. It allows a relatively fast operation, and increases the resolution as the number of considered features becomes smaller. After fitting all forests, the selected set of features is the one whose OOB error rate is within  $\sigma = 1$  standard error of the minimum error rate of all forests. This strategy can lead to solutions with fewer features while achieving an error rate that is similar, within sampling error, to the best solution.

## 2.3. Similarity-based band fusion

A simple fully automatic method is proposed to fuse similar spectral bands that were originally adjacent. Their fusion consists in averaging the corresponding reflectances. Starting from the shorter wavelength band, adjacent spectral bands are fused in a stepwise way till the similarity or divergence measure is higher or lower than a fixed threshold  $T_d$ , respectively.  $T_d$  is fixed automatically to the median value of divergence measures between adjacent spectral bands.

Three similarity measures were considered; the classic Pearson correlation score, Bhattacharyya divergence measure and mutual information between spectral bands. The correlation score  $C$  measures the strength and direction of the linear relationship between two variables  $x$  and  $y$ . Bhattacharyya measure was introduced by Fukunaga in 1990 [15]. It measures the divergence between two discrete or continuous probability distributions. The more the bands are different, the higher Bhattacharyya distance.

The mutual information measures the shared information between two discrete random variables  $x$  and  $y$ . The mutual information can be expressed using the entropy definition. It corresponds to the reduction of entropy  $H$  of  $x$  when  $y$  is known.

## 2.4. Combining band fusion and selection

In this study, we aim to assess the impact of band selection and fusion processes separately and their combination on classification accuracies. Two approaches for combining band fusion and selection are tested 1) fusion before selection and 2) fusion after selection. For the first approach, the band fusion is firstly processed then a band selection is applied. The second approach consists in first selecting the best bands and then in fusing adjacent bands as explained above.

## 3. HYPERSPECTRAL DATASETS

Three well-known hyperspectral datasets were used in our experiments.

**Indian Pines:** an AVIRIS image showing 16 classes of interest of different crops. It consists of 220 spectral reflectance bands (after removing water absorption bands) ranging in [0.4-2.5 nm].

**Salinas:** a 224-band AVIRIS image with a high spatial resolution (3.7-m). The image consists of 204 spectral bands, after removing water absorption bands. It was available only as at-sensor radiance data. 16 classes have been selected and include vegetables, bare soils, and vineyard fields.

**Pavia C:** It has been acquired by ROSIS sensor at a 4 nm spectral resolution and a 1.3 m spatial resolution. The image consists of 102 spectral bands. The ground truth differentiates 9 classes.

## 4. EXPERIMENTAL RESULTS

Experiments were run using R-project. Various packages were used among them RandomForests, VarSelRF for iterative feature elimination using RF, and FSelector for filter selection methods. Kappa accuracies are used for evaluation and are averaged over ten RF runs.

### 4.1. Band selection

Classical filter selection bands were tested; 1) selection by ranking where band weights are calculated. The number of selected bands corresponds to the size of feature subset selected automatically by varSelRF.  $\chi^2$  filter finds weights of bands basing on a  $\chi^2$  test. Then three entropy-based filter methods find weights of bands basing on their correlation with considered classes. RF importance is based on random forest importances. Relief-F finds weights of bands basing on a distance between instances. 2) a filter subset selection method called cfs (Correlation Feature Selection) was used. This algorithm finds the optimal feature subset using correlation and entropy measures. Table 1 resumes the number of selected bands and the kappa accuracies for all considered datasets.

	IP	S	PC
<b>Initial bands</b>	0.818	0.933	0.982
<b>Ranking selection (nb bands)</b>	<b>22</b>	<b>27</b>	<b>11</b>
$\chi^2$	0.616	0.884	0,971
info gain	0.494	0.890	0,815
gain ratio	0.646	0.889	0,923
sym.uncertainty	0.551	0.887	0,850
RF importance	0.732	0.916	0,891
relief	0.688	0.906	0,891
<b>Filter subset selection (nb bands)</b>	<b>20</b>	<b>41</b>	<b>26</b>
cfs	0.767	0.921	0,978
<b>Iter. RF elimination (nb bands)</b>	<b>22</b>	<b>27</b>	<b>11</b>
varSelRF	<b>0.786</b>	<b>0.927</b>	<b>0.978</b>

**Table 1.** Kappa accuracies for various feature selection methods. IP, S, and PC correspond to Indian Pines, Salinas, and Pavia Centre datasets, respectively.

One can observe that the iterative backward elimination of features using Random Forests (VarSelRF) outperforms the other methods while leading to less selected bands. This feature selection method is thus chosen for our experiments. Its impact on kappa accuracies, number of bands and computing time reduction is resumed in Table 2. One can see that the number of spectral bands and computing time can be highly reduced by up to 93% and 94% respectively, while keeping very satisfying classification accuracies (-3.2%, -0.6%, -0.4%), for IP, S and PC respectively. The most important loss occurred for highly imbalanced and mixed IP dataset.


Data	Kappa		Nb Bands		Computing time (s)	
	init	selection	init	selection	init	selection
IP	0.818	0.787	200	22	24.38	4.15
S	0.933	0.927	204	27	161.50	14.49
PC	0.982	0.978	102	11	143.63	18.57

**Table 2.** Impact of feature selection by VarSelRF on kappa accuracies, number of selected bands and computing time.

Figure 1 shows the selected bands by VarSelRF for all datasets. One can observe that many selected bands are adjacent and may be fused provided they are similar, thus the band fusion contribution will be studied in the next section.

#### 4.2. Band fusion contribution

Table 3 resumes kappa accuracies using initial bands and applying fusion process using various similarity measures. The three methods lead to the same number of selected bands (101, 103 and 53 for IP, S and PC respectively) but with different wavelengths (band positions). Bhattacharyya measure gave slightly better results than correlation and mutual information measures and thus will be used for the following experiments.



**Fig. 1.** Selected spectral bands using iterative feature elimination based on RF importance for all datasets.

	IP	S	PC
<b>Initial</b>	0.818	0.933	0.982
Correlation	0.799	0.926	0.980
Mutual Information	0.798	0.931	0.976
Bhattacharyya	0.805	0.930	0.980

**Table 3.** Kappa accuracies after similarity-based band fusion.

#### 4.3. Should band fusion be processed before or after band selection ?

In this section, the aim is to assess the contribution of using jointly Bhattacharyya-based fusion and VarSelRF selection processes. Two strategies combining fusion and selection processes are compared here, fusion before selection and selection before fusion. Results based on fusion and selection processes separately are also showed. Kappa accuracies are resumed in Table 4.

	Fusion before Selection		Selection before Fusion	
	Fusion	Fusion-Select	Selection	Select-Fusion
IP	0.80 (101)	0.78 (17)	0.79 (22)	0.79 (17)
S	0.93 (103)	0.93 (22)	0.93 (27)	0.93 (26)
PC	0.98 (53)	0.98 (5)	0.98 (11)	0.98 (8)

**Table 4.** Kappa accuracies using different strategies combining Bhattacharyya-based fusion and varSelRF feature selection. The number of bands is shown in brackets.

For the first approach fusion before selection, one can observe that the best accuracies are obtained using fusion process solely which confirms the contribution of fusing adjacent, redundant bands thus reducing the number of bands. The number of bands is reduced by 30%, 23%, and 29% for IP, S, and PC datasets, respectively. However, it remains relatively high (100, 102 and 72 for IP, S and PC respectively) and do not correspond to superspectral sensor specifications. In the second approach, fusing among the selected bands gave comparable kappa accuracies to those of selection process only while reducing the number of bands from 22 to 17, 27 to 26 and 11 to 5 for IP, S and PU datasets respectively. Fi-

nally, both combined approaches (selection before fusion Vs. fusion before selection) lead to comparable results. However selection before fusion gave a slighter better accuracy (+1%) for imbalanced IP dataset.

Table 5 compares the final results obtained by selection before fusion approach with the initial results using all spectral bands. The proposed approach reduces drastically the number of spectral bands while maintaining good classification accuracies. The number of bands was reduced by 90.5%, 86,8%, and 95.1% for IP, S, and PC while a little decrease occurred on kappa accuracies (-2.8%, -0.5%, -0.5%), respectively. The most important loss occurred for highly imbalanced and mixed IP dataset. Computing time was also highly reduced by 91.2%, 91%, 88,8% for IP, S, and PC, respectively.

Data	Kappa		Nb Bands		Computing time (s)	
	init	final	init	final	init	final
IP	0.818	0.790	200	17	24.38	2.14
S	0.933	0.928	204	26	161.50	14.49
PC	0.982	0.978	102	5	143.63	16.07

**Table 5.** Impact of combined approach varSelRF selection before band fusion on kappa accuracies, number of selected bands and computing time.

From a thematic point a view, on a urban scene (PC), 5 bands seem to be sufficient for classifying considered classes. This is probably due to the use of general classes such that adding bands do not improve results with comparison to multispectral data. Inversely, as expected, agricultural scenes need more bands ( $\sim 20$ ) to correctly describe the variety of cultures.

## 5. CONCLUSION

In this paper, we assessed the contribution of band spectral fusion to reduce the dimensionality of hyperspectral datasets while maintaining very satisfying classification accuracies. The proposed method is fully automatic and consists in a wrapper feature selection based on Random forest and a Bhattacharyya-based fusion process. In this scheme, we assessed the interest of combining both band selection and band fusion processes. The number of bands was reduced by almost 90% for various hyperspectral datasets. Besides, we showed the interest of band fusion process when dealing with unmixed classes and balanced datasets. As a conclusion, our study confirms the utility for superspectral sensors ( $\sim 20$  bands) with larger bands than hyperspectral bands that ensures better SNR and may lead to comparable classification accuracies. Future work will be focused on enhancing feature selection methods by integrating band fusion in the selection process, i.e. by taking into account the band width in the optimization process.

## 6. REFERENCES

- [1] G. Hughes, "On the mean accuracy of statistical pattern recognizers," *Information Theory, IEEE Transactions on*, vol. 14, no. 1, pp. 55–63, Jan 1968.
- [2] Isabelle Guyon and André Elisseeff, "An introduction to variable and feature selection," *Journal of Machine Learning Research*, vol. 3, pp. 1157–1182, Mar. 2003.
- [3] I. Kononenko, E. Simec, and M. Robnik-Sikonja, "Overcoming the myopia of inductive learning algorithms with relief," *Applied Intelligence*, vol. 7, no. 1, pp. 39–55, 1997.
- [4] L. Bruzzone and S. B. Serpico, "A technique for feature selection in multiclass problem," *International Journal of Remote Sensing*, vol. 21, no. 3, pp. 549–563, 2000.
- [5] S. B. Serpico and G. Moser, "Extraction of spectral channels from hyperspectral images for classification purposes," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 45, no. 2, pp. 484–495, Feb. 2007.
- [6] A. Martínez-Usó, F. Pla, J. Martínez Sotoca, and P. García-Sevilla, "Clustering-based hyperspectral band selection using information measures," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 45, no. 12, pp. 4158–4171, Dec. 2007.
- [7] S. Li, H. Wu, D. Wan, and J. Zhu, "An effective feature selection method for hyperspectral image classification based on genetic algorithm and support vector machine," *Knowledge-based Systems*, vol. 24, pp. 40–48, 2011.
- [8] R. Díaz-Urriarte and S. A. de Andrés, "Gene selection and classification of microarray data using random forest," *BMC Bioinformatics*, vol. 7, pp. 3, 2006.
- [9] I. Guyon, J. Weston, S. Barnhill, and V. Vapnik, "Gene selection for cancer classification using support vector machines," *Machine Learning*, vol. 46, pp. 289–422, 2002.
- [10] D. Tuia, G. Camps-Valls, G. Matasci, and M. Kanevski, "Learning relevant image features with multiple-kernel classification," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 48, no. 10, pp. 3780–3791, Oct. 2010.
- [11] M. Pal, "Margin-based feature selection for hyperspectral data," *International Journal of Applied Earth Observation and Geoinformation*, vol. 11, pp. 121–220, 2009.
- [12] L. Breiman, "Random forests," *Machine Learning*, vol. 45, no. 1, pp. 5–32, 2001.
- [13] J. Ham, Y. Chen, M.M. Crawford, and J. Ghosh, "Investigation of the Random Forest framework for classification of hyperspectral data," *IEEE T. on Geoscience and Remote Sensing*, vol. 43, no. 3, pp. 492–501, 2005.
- [14] N. Chehata, L. Guo, and C. Mallet, "Airborne lidar feature selection for urban classification using random forests," in *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, Vol. 38 (Part 3/W8)*, 207–212, Paris, 1-2 sep 2009.
- [15] K. Fukunaga, *Introduction to statistical pattern recognition (2nd ed.)*, Academic Press Professional, Inc., 1990.

# USE INTERMEDIATE RESULTS OF WRAPPER BAND SELECTION METHODS: A FIRST STEP TOWARD THE OPTIMIZATION OF SPECTRAL CONFIGURATION FOR LAND COVER CLASSIFICATIONS

Arnaud Le Bris (a), Nesrine Chehata (b,c), Xavier Briottet (d), Nicolas Paparoditis (a)

(a) Université Paris-Est, IGN/SR, MATIS, 73 avenue de Paris, 94160 Saint Mandé , France

(b) IRD/UMR LISAH El Menzah 4, Tunis, Tunisia

(c) EA 4592 G&E, ENSEGID-IPB, University of Bordeaux, 1, allée F. Daguin, 33607 Pessac Cedex, France

(d) ONERA, The French Aerospace Lab, 2 avenue Edouard Belin, BP 74025, 31055 Toulouse Cedex 4, France

## ABSTRACT

Intermediate results of two state-of-the-art wrapper feature selection approaches (GA and SFFS) associated to a classifier (linear SVM) applied to hyperspectral data sets were used to derive information about band importance for specific land cover classification problems. The impact of the number of selected bands on classification accuracy was obtained thanks to SFFS, while a band importance measure was derived from intermediate sets of bands tested by GA. Such results are a first step toward the identification of the most suitable spectral bands to design superspectral camera systems dedicated to specific applications (e.g. classification of urban land cover and material maps).

*Index Terms*— Feature selection, Classification, Support Vector Machines, Sequential Forward Floating Search, Genetic algorithm, Hyperspectral, Sensor design

## 1. INTRODUCTION

### 1.1. Feature selection for sensor design

Hyperspectral imagery generates huge data volumes, consisting of hundreds of contiguous and often highly redundant spectral bands. Difficulties are caused by this high dimensionality. First, the Hughes phenomenon can occur when classifying such data, even though modern classifiers such as Support Vector Machines (SVM) or Random Forests (RF) are less sensitive to these problems [1] except when very few training data is available. Second, important computing times are required to process high dimensionality data. Third, storing data requires huge volumes. Last, displaying high dimensionality imagery can be necessary. Thus, two strategies makes it possible to reduce the number of features. On the one hand, feature extraction methods reformulate and sum up original information. On the other, feature selection (FS) selects the most useful bands, i.e. the most relevant ones for a problem. The latter has advantages compared to feature extraction: first, it makes it possible not to lose the physical meaning

of the selected bands. Last but not least, it is adapted to the design of superspectral sensor. Indeed, our final work aims at identifying the most suitable spectral bands (both position in spectrum and width), to design superspectral cameras dedicated to specific applications (e.g. classification of urban land cover and material maps). Hence, both the most suitable number of spectral band and the most useful parts of the spectrum have to be identified thanks to band selection.

### 1.2. Band selection: state-of-the-art

Feature selection (FS) methods and criteria can be differentiated between “filter”, “wrapper” and “embedded”. Supervised and unsupervised ones can be differentiated too.

**Filter** methods compute relevance scores independently from any classifier. Some filter FS methods rank features according to a score of importance, as the ReliefF method. Other calculate importance measures from a feature extraction (e.g. PCA or LDA) [3]. In supervised cases, separability measures can be used to identify the sets of features making it possible to best separate classes, using Bhattacharyya or Jeffries-Matusita measures [4, 5, 6, 7] or other measures, such as Minimum Estimated Abundance Covariance [8]. High order statistics from information theory, e.g. mutual information, can also be used to select the best feature sets, either in unsupervised [9] or supervised [10, 11] cases. The Orthogonal Projection Divergence [12] is another measure of correlation between bands.

For **wrapper** methods, the relevance score associated to a feature set corresponds to the classification accuracy obtained using this feature set. Examples of such approaches can be found in [11, 13, 14] using SVM classifier, [15] using maximum likelihood classifier, [16] using random forests.

**Embedded** FS methods are also related to a classifier, but use feature relevance scores different from classification accuracy. SVM-RFE [17] considers the influence of the different features in a SVM model. It has been extended to multi-kernel SVM [18]. Random forests classifier gives another

measure of feature importance [19], estimated as the difference between prediction accuracy before and after permuting the features. Other embedded methods do not calculate a score for each feature, but for sets of features. For instance, [20, 21] use generalization performance, e.g. SVM margin, as separability measure to rank sets of features.

Nevertheless, hybrid approaches involving several criteria belonging to different categories often exist, as for instance in [11] or [13] where FS is based on a wrapper method respectively guided or associated to filter criteria (mutual information between selected bands, and between the ground truth).

Another issue for band selection is the optimization method: an exhaustive search of the best set of features is often impossible, especially for wrappers because of high computing times. Hence, heuristics have been proposed to find a near optimal solution without visiting the entire solution space. They can be differentiated into sequential (or incremental) and stochastic ones. Incremental search strategies includes the Sequential Forward Search (SFS) or its opposite the Sequential Backward Search (SBS). Variants such as Sequential Forward Floating Search (SFFS) or Sequential Backward Floating Search (SBFS) [22], or Steepest Ascent (SA) [7] have also been proposed. Several stochastic optimization strategies have also been used for feature selection, including Genetic Algorithms (GA) [13, 11, 20, 14], Particle Swarm Optimization (PSO) [8], clonal selection [15], ant colony [23] or even simulated annealing [6].

Thus, many FS methods have been proposed in literature. However, FS (and especially wrapper) is often considered as a first step in a classification workflow. Some methods even performed both band selection and optimization of classifier parameters jointly as [14]. Wrapper results are considered as obtaining the best classification accuracies for a problem, but also as sometimes lacking of generality and being too dependent to the associated classifier. As our final work aims at designing superspectral sensors dedicated to specific classification problems, this paper intends to use the intermediate results of two wrapper feature selection methods in order to draw conclusions about band importance, to define the most important parts of the spectra for a specific problem.

## 2. PROPOSED METHODS

As land cover classification is our final goal, two wrapper approaches (SFFS and GA) optimizing classification accuracies were used in this paper. This made it possible to examine sets of bands, instead of individual bands. Intermediate results of these methods will then be considered.

Both use linear one-against-one SVM classifier. Indeed this classifier directly implicitly takes “ratios” between bands into account, which would not have been done when using separability measures. Besides, using a linear kernel with a fixed cost parameter instead of a more complex kernel is a way to

avoid possible overfitting, caused by both feature selection and kernel optimization.

### 2.1. Sequential Forward Floating Search (SFFS) associated to SVM

The first band selection method used in this study was SFFS associated to a linear SVM classifier. SFFS is a state-of-the-art sequential optimization heuristic proposed by [22]. It is reminded below in pseudo-code, with  $C$  the original set of all bands,  $S$  the set of selected bands and  $p$  the maximum number of bands to select.

**Initialization :** Find band  $c \in C$  maximizing classification accuracy:  $S \leftarrow \{c\}$

**while** ( $\#S < p$ )

Find band  $c \in C \setminus S$  so that  $S \cup \{c\}$  maximizes classification accuracy:  $S \leftarrow S \cup \{c\}$

Question  $S$ : find band  $s \in S$  so that  $S \setminus \{s\}$  maximizes classification accuracy. It means that  $s$  is less important for classification than the other bands of  $S$ , since removing it decreases the classification accuracy less.

**if**  $s \neq c$  **then**  $S \leftarrow S \setminus \{s\}$  **endif**

**endwhile**

SFFS provides useful intermediate results. Indeed, it selects the “best” sets of bands for different dimensions, starting from 1. Thus, it makes it possible to observe the evolution of classification accuracy, depending on the number of selected bands, and then to decide how many bands are necessary to obtain suitable results. Other sequential methods, such as SVM-RFE [17] could also provide such information. However, contrary to RFE, SFFS question at each step the selected set of bands, obtained at previous step. Therefore, SFFS makes it possible to see whether the number of selected bands has a strong influence on the position of the selected bands along the spectrum.

### 2.2. Genetic algorithm associated to SVM

The second band selection method used in this study was a Genetic Algorithm (GA) associated to a linear SVM classifier. GA is a family of stochastic optimization heuristics. The variant used in our experiments is described below, with  $p$  the number of bands to select :

**Initialization** ( $t = 0$ ) : Randomly generate a population of  $N$  sets of  $p$  bands

**while** max number of generations unreached ( $t < tmax$ )  
 $t \leftarrow t + 1$

Calculate the score of each set of  $p$  bands of the current population

Keep only the  $n$  ( $n < N$ ) best sets of bands according to these scores. Let  $S(t)$  be this population.

Generate a new population of  $N$  sets of  $p$  bands from these remaining sets of bands :

**for all** new set of bands **do**

Create a new set of  $p$  bands by crossing two parents randomly chosen in  $S(t)$ . Random mutations can also occur with a fixed probability, randomly replacing a selected band by another band, in order to avoid to stay in a local minimum.

**endfor**  
**endwhile**

This approach has advantages for our problem. First, only the best solution is usually kept, while GA has visited many other candidates. Many of them have scores quite similar to the score of the best solution. Therefore, it appeared interesting to use these intermediate results to determine which bands are often selected in these intermediate solutions. Thus, the proposed method consist in associating a score  $I(c)$  to each band  $c$ , measuring the occurrence at which it has been selected by GA among the different  $n$  best sets of bands obtained at each generation:  $I(b) = \sum_t \sum_{S(t)} \delta(b, S(t))$  where  $\delta(b, S) = 1$  if  $b \in S$ , 0 otherwise.

To increase robustness, GA-SVM can be launched several times (i.e. different initializations/mutations) and over several training/testing sets randomly extracted from the whole data set. The proposed importance score is calculated for each of these results. Finally, the mean and the standard deviation of these scores are considered for each band: the mean gives the importance associated to each band, while the standard deviation is a way to detect potentially “unstable” good features. Last, intermediate results of GA could also be useful to detect repetitive patterns of selected bands. This time, the interesting information would not be the occurrence of detection of individual bands, but of sequences of bands.


### 3. TESTS AND RESULTS

The proposed algorithms were tested on the VNIR hyperspectral Pavia Center data set<sup>1</sup>. Training and testing sets included respectively 100 and 500 samples per class. The score to optimize was the overall accuracy. Even if average accuracy or F-score of the worst classified class could also be relevant, it must be kept in mind that both training and testing data included the same number of samples per class.


Information brought by SFFS-SVM about the number of useful bands is illustrated on fig. 1: classification accuracy tends to not increase a lot using more than 5-6 bands. This might be related to the fact that the classes are quite general, and additional bands do not bring much information compared to classic multispectral data, which is confirmed by the position of the most important features according to GA-SVM.

Thus, GA-SVM was launched to select 5 bands. Feature importance brought by GA-SVM are presented on fig. 2. Groups of adjacent important features are clearly visible, corresponding to the most important parts of the spectrum for this classification. The positions of these groups seem coherent with the spectra (just near or during changes in spectrum slope).

The standard deviation of the importances gave another interesting information: bands 3 to 5 appeared important (which seemed confirmed by the spectra) but standard deviation of their importance is high, corresponding to the fact they are quite noisy.



**Fig. 1.** Classification overall accuracy depending on the number of selected bands: on this data set, classification accuracy tends to not increase a lot using more than 5-6 bands



**Fig. 2.** Top row: GA-SVM band importances (blue: mean importance ; red: standard deviation). Second row: spectra of classes of the Pavia data set

### 4. CONCLUSION

These results are a first step toward the optimization of spectral configuration for specific land cover classifications, identifying the most relevant parts of the spectrum. Further works will cross them with information about correlation between bands, both to try to optimize the width of spectral bands and to identify whether one band is really more important than the others among clusters of highly correlated bands.

The occurrence score can also be modified to take into account how the selected bands influence the model among the set of bands they belong to (for instance accumulating SVM-RFE weights associated to the selected bands among

<sup>1</sup>[http://www.ehu.es/ccwintco/index.php/Hyperspectral\\_Remote\\_Sensing\\_Scenes](http://www.ehu.es/ccwintco/index.php/Hyperspectral_Remote_Sensing_Scenes)

the different band sets provided by GA). Another possible improvement mentioned above is to try to identify several patterns/sequences of bands, among selected sets of bands. Further experiments will also be carried out on a data set dedicated to urban material map, with a more detailed legend than for the Pavia data set and then for which hyperspectral imagery may be more relevant.

## 5. REFERENCES

- [1] G. Camps-Valls and L. Bruzzone, "Kernel-based methods for hyperspectral image classification," *IEEE TGRS*, vol. 43, no. 6, pp. 1351–1362, June 2005.
- [2] M. Pal and G.M. Foody, "Feature selection for classification of hyperspectral data by SVM," *IEEE TGRS*, vol. 48, no. 5, pp. 2297–2307, 2010.
- [3] C.-I. Chang, Q. Du, T.-L. Sun, and M.L.G. Althouse, "A joint band prioritization and band-decorrelation approach to band selection for hyperspectral image classification," *IEEE TGRS*, vol. 37, no. 6, pp. 2631–2641, Nov. 1999.
- [4] L. Bruzzone and S. B. Serpico, "A technique for feature selection in multiclass problem," *IJRS*, vol. 21, no. 3, pp. 549–563, 2000.
- [5] M. Herold, M. E. Gardner, and D. A. Roberts, "Spectral resolution requirements for mapping urban areas," *IEEE TGRS*, vol. 41, no. 9, pp. 1907–1919, Sept. 2003.
- [6] S. De Backer, P. Kempeneers, W. Debruyne, and P. Scheunders, "A band selection technique for spectral classification," *IEEE GRSL*, vol. 2, no. 3, pp. 319–232, 2005.
- [7] S. B. Serpico and G. Moser, "Extraction of spectral channels from hyperspectral images for classification purposes," *IEEE TGRS*, vol. 45, no. 2, pp. 484–495, Feb. 2007.
- [8] H. Yang, Q. Du, and G. Chen, "Particle swarm optimization-based hyperspectral dimensionality reduction for urban land cover classification," *IEEE JSTARS*, vol. 5, no. 2, pp. 544–554, Apr. 2012.
- [9] A. Martínez-Usó, F. Pla, J. Martínez Sotoca, and P. García-Sevilla, "Clustering-based hyperspectral band selection using information measures," *IEEE TGRS*, vol. 45, no. 12, pp. 4158–4171, Dec. 2007.
- [10] R. Battiti, "Using mutual information for selecting features in supervised neural net learning," *IEEE Transactions on Neural Networks*, vol. 5, no. 4, July 1994.
- [11] P. A. Estévez, M. Tesmer, C. A. Perez, and J. M. Zurada, "Normalized mutual information feature selection," *IEEE Transactions on Neural Networks*, vol. 20, no. 2, pp. 189–201, Feb. 2009.
- [12] Q. Du and H. Yang, "Similarity-based unsupervised band selection for hyperspectral image analysis," *IEEE GRSL*, vol. 5, no. 4, pp. 564–568, Oct. 2008.
- [13] S. Li, H. Wu, D. Wan, and J. Zhu, "An effective feature selection method for hyperspectral image classification based on genetic algorithm and support vector machine," *Knowledge-based Systems*, vol. 24, pp. 40–48, 2011.
- [14] L. Zhuo, J. Zheng, F. Wang, X. Li, A. Bin, and J. Qian, "A genetic algorithm based wrapper feature selection method for classification of hyperspectral images using support vector machine," *IAPRS*, vol. 37, no. B7, pp. 397–402, July 2008.
- [15] L. Zhang, Y. Zhong, B. Huang, J. Gong, and P. Li, "Dimensionality reduction based on clonal selection for hyperspectral imagery," *IEEE TGRS*, vol. 45, no. 12, pp. 4172–4186, Dec. 2007.
- [16] R. Díaz-Uriarte and S. A. De Andres, "Gene selection and classification of microarray data using random forest," *BMC bioinformatics*, vol. 7, no. 3, pp. 1–13, 2006.
- [17] I. Guyon, J. Weston, S. Barnhill, and V. Vapnik, "Gene selection for cancer classification using support vector machines," *Machine Learning*, vol. 46, pp. 289–422, 2002.
- [18] D. Tuia, G. Camps-Valls, G. Matasci, and M. Kanevski, "Learning relevant image features with multiple-kernel classification," *IEEE TGRS*, vol. 48, no. 10, pp. 3780–3791, Oct. 2010.
- [19] L. Breiman, "Random forests," *Machine Learning*, vol. 45, no. 1, pp. 5–32, 2001.
- [20] H. Fröhlich, O. Chapelle, and B. Schölkopf, "Feature selection for support vector machines by means of genetic algorithms," in *Proc. of the 15th IEEE International Conference on Tools with Artificial Intelligence*, 2003, pp. 142–148.
- [21] M. Pal, "Margin-based feature selection for hyperspectral data," *International Journal of Applied Earth Observation and Geoinformation*, vol. 11, pp. 121–220, 2009.
- [22] P. Pudil, J. Novovicova, and J. Kittler, "Floating search methods in feature selection," *Pattern Recognition Letters*, vol. 15, pp. 1119–1125, Nov. 1994.
- [23] S. Zhou, J.P. Zhang, and B.K. Su, "Feature selection and classification based on ant colony algorithm for hyperspectral remote sensing images," in *Proc. of CISP'09*, Oct. 2009, pp. 1–4.

# IDENTIFY IMPORTANT SPECTRUM BANDS FOR CLASSIFICATION USING IMPORTANCES OF WRAPPER SELECTION APPLIED TO HYPERSPECTRAL DATA

Arnaud Le Bris (a), Nesrine Chehata (b,c), Xavier Briottet (d), Nicolas Paparoditis (a)

(a) Université Paris-Est, IGN/SR, MATIS, 73 avenue de Paris, 94160 Saint Mandé , France

(b) IRD/UMR LISAH El Menzah 4, Tunis, Tunisia

(c) EA 4592 G&E, ENSEGID-IPB, University of Bordeaux, 1, allée F. Daguin, 33607 Pessac Cedex, France

(d) ONERA, The French Aerospace Lab, 2 avenue Edouard Belin, BP 74025, 31055 Toulouse Cedex 4, France

## ABSTRACT

Intermediate results of two state-of-the-art wrapper feature selection approaches (GA and SFFS) applied to hyperspectral data sets were used to derive information about band importance for specific land cover classification problems. Several feature selection performance scores (classification accuracies, Bhattacharyya separability) were tested. The impact of the number of selected bands on classification accuracy was obtained thanks to SFFS, while a band importance measure was derived from intermediate sets of bands tested by GA. Such results are a first step toward the identification of the most suitable spectral bands to design superspectral camera systems dedicated to specific applications (e.g. classification of urban land cover and material maps).

**Index Terms**— Feature selection, Classification, Support Vector Machines, Random Forests, Bhattacharyya, Sequential Forward Floating Search, Genetic algorithm, Hyperspectral, Sensor design

## 1. INTRODUCTION

### 1.1. Feature selection for sensor design

Hyperspectral imagery generates huge data volumes, consisting of hundreds of contiguous and often highly redundant spectral bands. Difficulties are caused by this high dimensionality. First, the Hughes phenomenon can occur when classifying such data, even though modern classifiers such as Support Vector Machines (SVM) or Random Forests (RF) are less sensitive to these problems [1] except when very few training data is available. Second, important computing times are required to process high dimensionality data. Third, storing data requires huge volumes. Last, displaying high dimensionality imagery can be necessary. Thus, two strategies makes it possible to reduce the number of features. On the one hand, feature extraction methods reformulate and sum up original information. On the other, feature selection (FS) selects the most useful bands, i.e. the most relevant ones for a problem. The latter has advantages compared to feature extrac-

tion: first, it makes it possible not to lose the physical meaning of the selected bands. Last but not least, it is adapted to the design of superspectral sensor. Indeed, our final work aims at identifying the most suitable spectral bands (both position in spectrum and width), to design superspectral cameras dedicated to specific applications (e.g. classification of urban land cover and material maps). Hence, both the most suitable number of spectral band and the most useful parts of the spectrum have to be identified thanks to band selection.

### 1.2. Band selection: state-of-the-art

Feature selection (FS) methods and criteria can be differentiated between “filter”, “wrapper” and “embedded”. Supervised and unsupervised ones can be differentiated too.

**Filter** methods compute relevance scores independently from any classifier. Some filter FS methods rank features according to a score of importance, as the ReliefF method. Other calculate importance measures from a feature extraction (e.g. PCA or LDA) [2]. In supervised cases, separability measures can be used to identify the sets of features making it possible to best separate classes, using Bhattacharyya or Jeffries-Matusita measures [3, 4, 5, 6] or other measures, such as Minimum Estimated Abundance Covariance [7]. High order statistics from information theory, e.g. mutual information, can also be used to select the best feature sets, either in unsupervised [8] or supervised [9, 10] cases. The Orthogonal Projection Divergence [11] is another measure of correlation between bands.

For **wrapper** methods, the relevance score associated to a feature set corresponds to the classification accuracy obtained using this feature set. Examples of such approaches can be found in [10, 12, 13] using SVM classifier, [14] using maximum likelihood classifier, [15] using random forests.

**Embedded** FS methods are also related to a classifier, but use feature relevance scores different from classification accuracy. SVM-RFE [16] considers the influence of the different features in a SVM model. It has been extended to multi-kernel SVM [17]. Random forests classifier gives another measure of feature importance [18], estimated as the differ-



ence between prediction accuracy before and after permuting the features. Other embedded methods do not calculate a score for each feature, but for sets of features. For instance, [19, 20] use generalization performance, e.g. SVM margin, as separability measure to rank sets of features.

Nevertheless, hybrid approaches involving several criteria belonging to different categories often exist, as for instance in [10] or [12] where FS is based on a wrapper method respectively guided or associated to filter criteria (mutual information between selected bands, and between the ground truth).

Another issue for band selection is the optimization method: an exhaustive search of the best set of features is often impossible, especially for wrappers because of high computing times. Hence, heuristics have been proposed to find a near optimal solution without visiting the entire solution space. They can be differentiated into sequential (or incremental) and stochastic ones. Incremental search strategies includes the Sequential Forward Search (SFS) or its opposite the Sequential Backward Search (SBS). Variants such as Sequential Forward Floating Search (SFFS) or Sequential Backward Floating Search (SBFS) [21], or Steepest Ascent (SA) [6] have also been proposed. Several stochastic optimization strategies have also been used for feature selection, including Genetic Algorithms (GA) [12, 10, 19, 13], Particle Swarm Optimization (PSO) [7], clonal selection [14], ant colony [22] or even simulated annealing [5].

Thus, many FS methods have been proposed in literature. However, FS (and especially wrapper) is often considered as a first step in a classification workflow. Some methods even performed both band selection and optimization of classifier parameters jointly as [13]. Wrapper results are considered as obtaining the best classification accuracies for a problem, but also as sometimes lacking of generality and being too dependent to the associated classifier. As our final work aims at designing superspectral sensors dedicated to specific classification problems, this paper intends to use the intermediate results of two wrapper feature selection methods in order to draw conclusions about band importance, to define the most important parts of the spectra for a specific problem.

## 2. USE INTERMEDIATE RESULTS OF TWO FEATURE SELECTION METHODS

As land cover classification is our final goal, two wrapper approaches (SFFS and GA) optimizing classification accuracies were used in this paper. This made it possible to examine sets of bands, instead of individual bands. Intermediate results of these methods will then be considered.

Both have been tested for several scores to optimize (see 2.3).

### 2.1. Sequential Forward Floating Search (SFFS)

The first band selection method used in this study was SFFS. SFFS is a state-of-the-art sequential optimization heuristic proposed by [21]. It is reminded below in pseudo-code, with  $C$  the original set of all bands,  $S$  the set of selected bands and  $p$  the maximum number of bands to select.

**Initialization :** Find band  $c \in C$  maximizing classification accuracy:  $S \leftarrow \{c\}$

**while** ( $\#S < p$ )

Find band  $c \in C \setminus S$  so that  $S \cup \{c\}$  maximizes classification accuracy:  $S \leftarrow S \cup \{c\}$

Question  $S$ : find band  $s \in S$  so that  $S \setminus \{s\}$  maximizes classification accuracy. It means that  $s$  is less important for classification than the other bands of  $S$ , since removing it decreases the classification accuracy less.

**if**  $s \neq c$  **then**  $S \leftarrow S \setminus \{s\}$  **endif**

**endwhile**

SFFS provides useful intermediate results. Indeed, it selects the “best” sets of bands for different dimensions, starting from 1. Thus, it makes it possible to observe the evolution of classification accuracy, depending on the number of selected bands, and then to decide how many bands are necessary to obtain suitable results. Other sequential methods, such as SVM-RFE [16] could also provide such information. However, contrary to RFE, SFFS question at each step the selected set of bands, obtained at previous step. Therefore, SFFS makes it possible to see whether the number of selected bands has a strong influence on the position of the selected bands along the spectrum.

### 2.2. Genetic algorithm

The second band selection method used in this study was a Genetic Algorithm (GA). GA is a family of stochastic optimization heuristics. The variant used in our experiments is described below, with  $p$  the number of bands to select :

**Initialization** ( $t = 0$ ) : Randomly generate a population of  $N$  sets of  $p$  bands

**while** max number of generations unreached ( $t < tmax$ )  
 $t \leftarrow t + 1$

Calculate the score of each set of  $p$  bands of the current population

Keep only the  $n$  ( $n < N$ ) best sets of bands according to these scores. Let  $S(t)$  be this population.

Generate a new population of  $N$  sets of  $p$  bands from these remaining sets of bands :

**for all** new set of bands **do**

Create a new set of  $p$  bands by crossing two parents randomly chosen in  $S(t)$ . Random mutations can also occur with a fixed probability, randomly replacing a selected band by another band, in order to avoid to stay in a local minimum.


**endfor**

**endwhile**

This approach has advantages for our problem. First, only the best solution is usually kept, while GA has visited many other candidates. Many of them have scores quite similar to the score of the best solution. Therefore, it appeared interesting to use these intermediate results to determine which bands are often selected in these intermediate solutions (see figure 1). Thus, the proposed method consist in associating a score  $I(c)$  to each band  $c$ , measuring the occurrence at which it has been selected by GA among the different  $n$  best sets of bands obtained at each generation:  $I(b) = \sum_t \sum_{S(t)} \delta(b, S(t))$  where  $\delta(b, S) = 1$  if  $b \in S$ , 0 otherwise.

To increase robustness, GA can be launched several times (i.e. different initializations/mutations) and over several training/testing sets randomly extracted from the whole data set. The proposed importance score is calculated for each of these results. Finally, the mean and the standard deviation of these scores are considered for each band: the mean gives the importance associated to each band, while the standard deviation is a way to detect potentially “unstable” good features.

Last, intermediate results of GA could also be useful to detect repetitive patterns of selected bands. This time, the interesting information would not be the occurrence of detection of individual bands, but of sequences of bands.



**Fig. 1.** Each line is a set of bands selected in the intermediate results of GA and each black dot represents a selected band.

### 2.3. Scores to optimize

Several scores to optimize have been tested independently (both for SFFS and GA approaches).

**1 - SVM OA : Classification overall accuracy obtained using a linear one-against-one SVM classifier.** Indeed this classifier directly implicitly takes “ratios” between bands into account, which would not have been done when using separability measures. Besides, using a linear kernel with a fixed cost parameter instead of a more complex kernel is a way to avoid possible overfitting, caused by both feature selection and kernel optimization.

**2 - RF OA : Classification overall accuracy obtained using a Random Forest classifier.** RF classifier [18] is faster

than non linear SVM and provides quite as good results. It was used here as a less model constrained classifier than linear SVM.

For SVM and RF classifier, the score to optimize was the overall accuracy (OA). Even if average accuracy (AA) or F-score of the worst classified class could also be relevant, it must be kept in mind that both training and testing data included the same number of samples per class.

**3 - Mean Bhattacharyya distance (B-distance) separability measure.** It has often been used for band selection in hyperspectral data [3, 4]. The B-distance between 2 classes for set of spectral bands measures the way it is efficient to separate these classes. (Indeed it measures the similarity between the radiometric probability distributions of these classes). It was here aimed at optimizing the mean B-distance over all pairs of classes.

## 3. TESTS AND RESULTS

The proposed algorithms were tested on the VNIR hyperspectral Pavia Center data set <sup>1</sup>. Its associated land cover groundtruth includes the next classes : “water”, “trees”, “meadows”, “self blocking bricks”, “bare soil”, “asphalt”, “roofing bitumen”, “roofing tiles” and “shadows”.

Training and testing sets included respectively 100 and 500 samples per class.

### 3.1. Number of bands to select according to SFFS

Information brought by SFFS about the number of useful bands is illustrated on fig. 2. Several classification accuracy measures were calculated for an optimized RBF kernel SVM classification using the best set of bands identified by SFFS. These accuracy measures were the Kappa index, the overall accuracy (OA), the average accuracy (AA), the mean and the minimum among F-scores obtained by the different classes (resp. Fscoremoy and Fscoremin).

All of them tend to not increase a lot using more than 5-6 bands. This phenomenon can be observed for both scores to optimize. This might be related to the fact that the classes are quite general, and additional bands do not bring much information compared to classic multispectral data, which is confirmed by the position of the most important features according to GA.

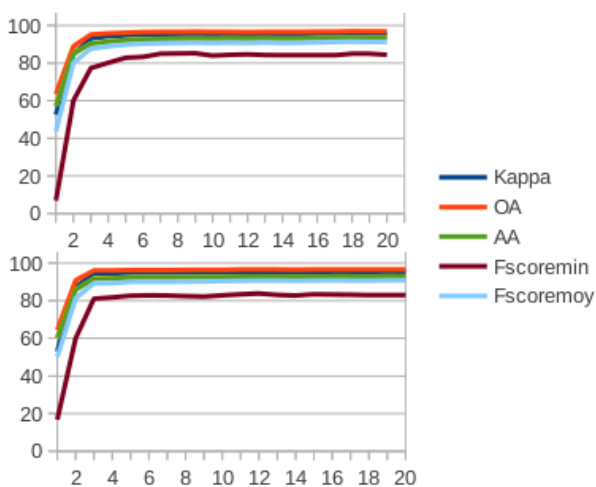
Thus, GA was launched to select 5 bands.

### 3.2. Band importances provided by GA

Feature importance brought by GA are presented on fig. 3. Groups of adjacent important features are clearly visible, corresponding to the most important parts of the spectrum for

<sup>1</sup>[http://www.ehu.es/ccwintco/index.php/Hyperspectral\\_Remote\\_Sensing\\_Scenes](http://www.ehu.es/ccwintco/index.php/Hyperspectral_Remote_Sensing_Scenes)

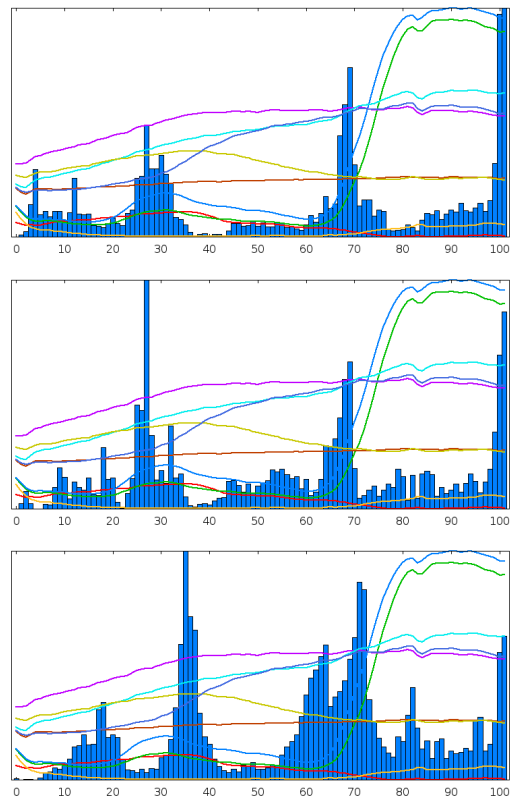
this classification. The positions of these groups seem coherent with the spectra (just near or during changes in spectrum slope). Important parts of the spectrum identified using linear SVM OA or RF OA scores are quite similar, identifying 3 very important band clusters (plus a less important one for SVM OA at the beginning of the spectrum) while B-distance based result is slightly different, identifying 4-5 important parts of the spectrum. However, these results are coherent with the results provided by SFFS (fig. 2). The positions of the important band clusters are also slightly different for B-distance optimization score. Besides, the cluster of important bands identified near band 85 using this score is suspect, since it seems to correspond to an atmospheric correction artifact.



**Fig. 2.** Classification accuracies (obtained by an optimized RBF kernel SVM classifier) depending on the number of selected bands for 2 band selection criteria : classification OA of linear SVM (bottom row) and mean B-distance (top row). (x-axis = number of selected bands ; y-axis = classification accuracies expressed in %). The different classification accuracies tends to not increase using more than 5-6 bands for both band selection scores

#### 4. CONCLUSION

These results are a first step toward the optimization of spectral configuration for specific land cover classifications, identifying the most relevant parts of the spectrum. Further works will cross them with information about correlation/similarity between bands, both to try to optimize the width of spectral bands and to identify whether one band is really more important than the others among clusters of highly similar bands. The occurrence score can also be modified to take into account how the selected bands influence the model among the set of bands they belong to (for instance when using SVM accumulating SVM-RFE weights associated to the selected



**Fig. 3.** GA band importances obtained selecting 5 bands, according to the 3 different optimization scores : linear SVM classification overall accuracy (top row), RF classification overall accuracy (middle row) and mean B-distance (bottom row). (x-axis = band numbers ; y-axis = band importances (histogram) and spectra (curves)). The spectra of the different classes are also displayed.

bands among the different band sets provided by GA). Another possible improvement mentioned above is to try to identify several patterns/sequences of bands, among selected sets of bands.

Further experiments will test other band optimization scores based on the margin of the classifier.

Further experiments will also be carried out on a data set dedicated to urban material map, with a more detailed legend than for the Pavia data set and then for which hyperspectral imagery may be more relevant.

#### 5. REFERENCES

- [1] G. Camps-Valls and L. Bruzzone, "Kernel-based methods for hyperspectral image classification," *IEEE TGRS*, vol. 43, no. 6, pp. 1351–1362, June 2005.
- [2] C.-I. Chang, Q. Du, T.-L. Sun, and M.L.G. Althouse,

- “A joint band prioritization and band-decorrelation approach to band selection for hyperspectral image classification,” *IEEE TGRS*, vol. 37, no. 6, pp. 2631–2641, Nov. 1999.
- [3] L. Bruzzone and S. B. Serpico, “A technique for feature selection in multiclass problem,” *IJRS*, vol. 21, no. 3, pp. 549–563, 2000.
- [4] M. Herold, M. E. Gardner, and D. A. Roberts, “Spectral resolution requirements for mapping urban areas,” *IEEE TGRS*, vol. 41, no. 9, pp. 1907–1919, Sept. 2003.
- [5] S. De Backer, P. Kempeneers, W. Debruyne, and P. Scheunders, “A band selection technique for spectral classification,” *IEEE GRSL*, vol. 2, no. 3, pp. 319–232, 2005.
- [6] S. B. Serpico and G. Moser, “Extraction of spectral channels from hyperspectral images for classification purposes,” *IEEE TGRS*, vol. 45, no. 2, pp. 484–495, Feb. 2007.
- [7] H. Yang, Q. Du, and G. Chen, “Particle swarm optimization-based hyperspectral dimensionality reduction for urban land cover classification,” *IEEE JSTARS*, vol. 5, no. 2, pp. 544–554, Apr. 2012.
- [8] A. Martínez-Usó, F. Pla, J. Martínez Sotoca, and P. García-Sevilla, “Clustering-based hyperspectral band selection using information measures,” *IEEE TGRS*, vol. 45, no. 12, pp. 4158–4171, Dec. 2007.
- [9] R. Battiti, “Using mutual information for selecting features in supervised neural net learning,” *IEEE Transactions on Neural Networks*, vol. 5, no. 4, July 1994.
- [10] P. A. Estévez, M. Tesmer, C. A. Perez, and J. M. Zurada, “Normalized mutual information feature selection,” *IEEE Transactions on Neural Networks*, vol. 20, no. 2, pp. 189–201, Feb. 2009.
- [11] Q. Du and H. Yang, “Similarity-based unsupervised band selection for hyperspectral image analysis,” *IEEE GRSL*, vol. 5, no. 4, pp. 564–568, Oct. 2008.
- [12] S. Li, H. Wu, D. Wan, and J. Zhu, “An effective feature selection method for hyperspectral image classification based on genetic algorithm and support vector machine,” *Knowledge-based Systems*, vol. 24, pp. 40–48, 2011.
- [13] L. Zhuo, J. Zheng, F. Wang, X. Li, A. Bin, and J. Qian, “A genetic algorithm based wrapper feature selection method for classification of hyperspectral images using support vector machine,” *IAPRS*, vol. 37, no. B7, pp. 397–402, July 2008.
- [14] L. Zhang, Y. Zhong, B. Huang, J. Gong, and P. Li, “Dimensionality reduction based on clonal selection for hyperspectral imagery,” *IEEE TGRS*, vol. 45, no. 12, pp. 4172–4186, Dec. 2007.
- [15] R. Díaz-Uriarte and S. A. De Andres, “Gene selection and classification of microarray data using random forest,” *BMC bioinformatics*, vol. 7, no. 3, pp. 1–13, 2006.
- [16] I. Guyon, J. Weston, S. Barnhill, and V. Vapnik, “Gene selection for cancer classification using support vector machines,” *Machine Learning*, vol. 46, pp. 289–422, 2002.
- [17] D. Tuia, G. Camps-Valls, G. Matasci, and M. Kanevski, “Learning relevant image features with multiple-kernel classification,” *IEEE TGRS*, vol. 48, no. 10, pp. 3780–3791, Oct. 2010.
- [18] L. Breiman, “Random forests,” *Machine Learning*, vol. 45, no. 1, pp. 5–32, 2001.
- [19] H. Fröhlich, O. Chapelle, and B. Schölkopf, “Feature selection for support vector machines by means of genetic algorithms,” in *Proc. of the 15th IEEE International Conference on Tools with Artificial Intelligence*, 2003, pp. 142–148.
- [20] M. Pal, “Margin-based feature selection for hyperspectral data,” *International Journal of Applied Earth Observation and Geoinformation*, vol. 11, pp. 121–220, 2009.
- [21] P. Pudil, J. Novovicova, and J. Kittler, “Floating search methods in feature selection,” *Pattern Recognition Letters*, vol. 15, pp. 1119–1125, Nov. 1994.
- [22] S. Zhou, J.P. Zhang, and B.K. Su, “Feature selection and classification based on ant colony algorithm for hyperspectral remote sensing images,” in *Proc. of CISP’09*, Oct. 2009, pp. 1–4.

# A RANDOM FOREST CLASS MEMBERSHIPS BASED WRAPPER BAND SELECTION CRITERION : APPLICATION TO HYPERSPECTRAL

Arnaud Le Bris (a), Nesrine Chehata (b,c), Xavier Briottet (d), Nicolas Paparoditis (a)

(a) Université Paris-Est, IGN/SR, MATIS, 73 avenue de Paris, 94160 Saint Mandé , France

(b) IRD/UMR LISAH El Menzah 4, Tunis, Tunisia

(c) Bordeaux INP, G

E, EA 4592, F-33600, Pessac, France

(d) ONERA, The French Aerospace Lab, 2 avenue Edouard Belin, BP 74025, 31055 Toulouse Cedex 4, France

## ABSTRACT

Hyperspectral imagery generates huge data volumes, consisting of hundreds of contiguous and often highly redundant spectral bands. Difficulties are caused by this high dimensionality. Feature selection (FS) is a possible strategy to reduce the number of bands, consisting in selecting the most relevant bands for a classification problem. It is adapted to the design of superspectral sensor dedicated to specific applications. FS is an optimization problem involving both a metric (that is to say a FS score or criterion measuring the relevance of feature subsets) to optimize and an optimization strategy. In this paper, a wrapper FS score based on Random Forests (RF) and taking into account RF class membership measures was proposed. It was compared to a state-of-the-art wrapper FS score (classification Kappa obtained by RF). Both were then evaluated quantitatively considering both classification performance reached applying different classifiers. A qualitative analysis was also performed to consider the stability/regularity of the selected features along the spectrum. Even though the quantitative evaluation showed little differences between the two tested FS criteria, there seemed to be a trend in favour of the proposed criterion. Taking into account the measures of class membership provided by a RF classifier slightly improved results, regularizing feature selection.

**Index Terms**— Random Forests, Classification, Feature selection, Confidence

## 1. INTRODUCTION

Hyperspectral imagery generates huge data volumes, consisting of hundreds of contiguous and often highly redundant spectral bands. Difficulties are caused by this high dimensionality. First, the Hughes phenomenon can occur when classifying such data, even though modern classifiers such as Support Vector Machines (SVM) or Random Forests (RF) are less sensitive to these problems. Second, important computing times are required to process high dimensionality data. Feature selection (FS) is a possible strategy to reduce the number of

bands. It consists in selecting the most useful bands, i.e. the most relevant ones for a problem. It has the advantage not to lose the physical meaning of the selected bands. It is also adapted to the design of superspectral sensor, that is to say to identify the most suitable spectral bands, to design superspectral cameras dedicated to specific applications (e.g. classification of urban land cover and material maps). Hence, both the most suitable number of spectral band and the most useful parts of the spectrum have to be identified thanks to supervised band selection.

### 1.1. Supervised band selection: state-of-the-art and proposed idea

Feature Selection (FS) is an optimization problem involving both a metric (that is to say a FS score or criterion measuring the relevance of feature subsets) to optimize and an optimization strategy. Supervised FS methods and criteria can be differentiated between “filter”, “wrapper” and “embedded”.

**Filter** methods compute relevance scores independently from any classifier. Many filter FS methods rank features according to an importance score, as the ReliefF method. In supervised cases, separability measures can be used to identify the sets of features making it possible to best separate classes, using Bhattacharyya or Jeffries-Matusita measures [1]. High order statistics from information theory, e.g. mutual information, can also be used to select the best feature sets [2].

For **wrapper** methods, the relevance score associated to a feature set corresponds to the classification accuracy obtained using this feature set. Examples of such approaches can be found in [2, 3] using SVM classifier or [4] using random forests.

**Embedded** FS methods are also related to a classifier, but use feature relevance scores different from classification accuracy. SVM-RFE [5] considers the influence of the different features in a SVM model. Random forests classifier gives another measure of feature importance [6], estimated as the difference between prediction accuracy before and af-

ter permuting the features. Other embedded methods do not calculate a score for each feature, but for sets of features. For instance, [7] use generalization performance, e.g. SVM margin, as separability measure to rank sets of features.

Another issue for band selection is the optimization method: an exhaustive search of the best set of features is often impossible, especially for wrappers because of high computing times. Hence, heuristics have been proposed to find a near optimal solution without visiting the entire solution space. They can be differentiated into sequential (or incremental) and stochastic ones.

To put it in a nutshell, on the one hand, feature selection wrapper methods for classification often rely on traditional classification error rates (overall or average accuracies, Kappa,...) taking into account only final hard labellisation. On the other hand, filter separability scores (e.g. Bhattacharyya distance) measure the theoretical ability of a feature subset to well discriminate classes.

However, for each sample to classify, most classifiers provide not only the best label, but also a set of values measuring the degree of membership to the different possible classes, making it possible to assess the confidence of the obtained labellisation. Thus, it can be interesting to use such information as a FS criterion. That is to say to try to select the subset of features, making it possible to achieve a classification highly confident when samples are well classified and very uncertain for bad classified samples. This paper presents such FS criterion, based on the Random Forests classifier.

## 2. PROPOSED FEATURE SELECTION CRITERION

### 2.1. Random Forests

Random Forests (RF) [6] is a modification of bagging applied with decision trees. It can achieve a classification accuracy comparable to boosting [6], or SVM [8]. It does not require assumptions on the distribution of the data, which is interesting when different types or scales of input features are used. It was successfully applied to remote sensing data such as multispectral data, hyperspectral data, or multisource data. This ensemble classifier is a combination of tree predictors built from  $T$  multiple bootstrapped training samples. For each node of a tree, a subset of features is randomly selected. Then, the best feature with regard to Gini impurity measure is used for node splitting. For classification, each tree gives a unit vote for the most popular class at each input instance and the final label is determined by a majority vote of all trees. Thus, for each sample to classify, the number of votes obtained by each possible label can be used as a class membership measure. Besides, it is provided by random forests at no additional computational cost.

Let  $\mathcal{C} = \{c_1, \dots, c_{nc}\}$  be the set of possible classes and  $v(\mathbf{x}, c)$

the number of votes obtained by class  $c$  when classifying sample  $\mathbf{x}$ . A class membership score  $m$  can then be obtained by normalizing the number of votes by the number of trees, i.e.  $m(\mathbf{x}, c) = \frac{v(\mathbf{x}, c)}{T}$

### 2.2. A feature selection score taking into account RF class membership measures

Let  $\mathcal{X} = \{(\mathbf{x}_i, y_i)\}_{1 \leq i \leq n}$  be a set of groundtruth samples  $\mathbf{x}_i$  and their associated true label  $y_i$ . A possible feature selection score  $\mathcal{R}$  taking into account class membership measures and thus classification confidence can be defined as :

$$\mathcal{R}(\mathcal{X}) = \sum_{i=1}^n \delta(y_i, c(\mathbf{x}_i)) \cdot m(\mathbf{x}_i, c(\mathbf{x}_i))$$

with  $\delta(i, j) = \{-1$  if  $i \neq j$  and  $1$  otherwise $\}$ , and  $c(\mathbf{x})$  the label given to  $\mathbf{x}$  by the classifier.

This score has the advantage to measure the ability to well classify the test samples for a given feature set and the separability between classes. Indeed, the more the samples are well classified, the more the score increases. The more the classifier is confident for well classified samples, the more the score increases. The more the classifier is confident for bad labelled samples, the more the score decreases.

## 3. EXPERIMENTS AND RESULTS

The proposed FS criterion was compared to an alternative FS score to optimize : the classification Kappa ( $\kappa$ ) obtained by RF. Their relevance was assessed considering both classification accuracies reached applying different classifiers and the stability/regularity of the selected features.

Band selection was performed optimizing the FS scores using a genetic algorithm (GA). The process was launched several times to benefit from the stochastic behaviour of the algorithm and to get several near optimal solutions [9]. FS was performed for fixed numbers of bands. In our experiments, this happened to be 5 bands (the number of bands from which classification performance is no more greatly improved when adding new bands for both data sets) and 15 bands (that is to say more features than really required).

The proposed algorithms were tested on the VNIR ROSIS hyperspectral ‘‘Pavia City Center’’ and the VNIR-SWIR AVIRIS hyperspectral ‘‘Salinas’’ scenes <sup>1</sup>. Training and testing sample sets included respectively 100 and 500 samples per class for feature selection, while for evaluation training sample sets were limited to 50 samples per class and testing sample sets included all remaining pixels.

<sup>1</sup>[http://www.ehu.es/ccwintco/index.php/Hyperspectral\\_Remote\\_Sensing\\_Scenes](http://www.ehu.es/ccwintco/index.php/Hyperspectral_Remote_Sensing_Scenes)

### 3.1. Classification accuracies reached using the selected feature subsets

The selected band subsets were then quantitatively evaluated according to the classification error rates obtained using several classifiers.

#### Evaluation using other classifiers different from RF

In order to be able to draw conclusions about the relevance of the FS criteria independently from RF classifier, selected band subsets were also evaluated considering the classification error rates obtained using two other classifiers : an optimized RBF kernel SVM and a maximum likelihood (ML) classifier assuming gaussian class models classifier. Indeed, FS can be used to design superspectral sensors dedicated to specific application, and thus the used wrapper FS score must not be too dependent to its associated classifier. Classification Average Accuracies (AA) and  $\kappa$  were considered.

Accuracies reached using either the proposed FS score or the  $\kappa$  as FS criterion are presented in table 1. Even though they are very similar, it can be observed that they are slightly increased using the proposed score. This is more explicit selecting more features (e.g. 15) than required.

#### Evaluation using RF

Selected band subsets were evaluated according to RF classification. Classification Average Accuracies (AA) and  $\kappa$  were considered in association to several indices taking into account class memberships measures provided by the classifier : the measure proposed in this paper for FS, the RF margin [6] (defined as the difference between the two best class membership measures) and the entropy of the membership measures [10]. Each of these indices was computed on all testing samples and synthesized into a overall value using the same formula as the FS score proposed in this paper. An average of these indices onfor true positive (TP) samples was also calculated.


These indices reached using either the proposed FS score or the  $\kappa$  as FS criterion are presented in table 2. There are very little differences between the two tested FS criteria.  $\kappa$  and AA reached using RF classifier for evaluation are very similar whatever the FS criterion, and contrary to previous evaluation using SVM or ML, no real trend in favour of the proposed FS criterion can be observed, even when selecting more bands than required.

On the opposite, the other indices taking into account class membership measures are generally improved using the proposed criterion instead of the  $\kappa$  coefficient as FS criterion.

### 3.2. Stability/regularity of the selected features

As described in [9], band importance profiles (fig.1) can be derived from intermediate results of a GA feature selection. Indeed, GA visits many band subsets almost as good as the final solution. Thus, the occurrence at which a band has been

selected by GA among the intermediate best band subsets obtained at each generation can be used as a band importance measure. In the case of hyperspectral data, as the contiguous bands are correlated, such band importance profile should be regular (not too noisy). Its regularity is also related to the stability of the solutions obtained according to a FS criterion. This analysis remained qualitative. For Pavia data set, band importance profiles obtained selecting 5 bands are displayed on figure 1. It can then be noted that the importance of the first bands (e.g. band 3) is less important using the proposed criterion than using  $\kappa$  FS criterion, which is positive since these bands are noisy. To some extent, the overall shape of the profile obtained using the proposed criterion appears also smoother.



**Fig. 1.** GA band importances obtained selecting 5 bands for Pavia data set, according to the proposed FS score (left) and RF classification  $\kappa$  accuracy (right) as FS criterion. (x-axis = band numbers ; y-axis = band importances (histogram) ; The spectra of the different classes are also displayed).

## 4. CONCLUSION

Even though the quantitative evaluation showed little differences between the two tested FS criteria, there seemed to be a trend in favour of the proposed criterion : taking into account the class membership measures provided by a RF classifier slightly improves results and tends to regularize feature selection. This result was confirmed by a more obvious trend when selecting more features than required. Indeed, according to evaluation using classifiers different from RF, it seemed to select band subsets that are more general and less dependent to RF. Similar results were obtained with other data sets.

**Table 1.** Quantitative evaluation, assessing classification performance reached using rbf svm and ml classifiers

		Pavia				Salinas			
		SVM		ML		SVM		ML	
Nb bands	FS score	$\kappa$ (%)	AA (%)	$\kappa$ (%)	AA (%)	$\kappa$ (%)	AA (%)	$\kappa$ (%)	AA (%)
5	Proposed score	94.96	92.18	94.29	91.73	87.02	93.99	84.35	93.33
5	$\kappa$	94.84	92.16	94.17	91.63	86.82	93.93	84.19	93.26
15	Proposed score	95.46	93.17	94.03	91.16	87.82	94.67	84.73	93.82
15	$\kappa$	95.19	92.84	93.76	90.81	86.85	94.18	83.70	93.32

**Table 2.** Quantitative assessment of classification performance reached using RF classifier.

Nb bands	FS score	$\kappa$ (%)	AA (%)	score (%)	score.TP (%)	margin (%)	margin.TP (%)	entropy	entropy.TP
Pavia									
5	Proposed score	91.66	89.58	85.68	94.63	83.03	90.37	0.105	0.156
5	$\kappa$	92.19	89.81	84.91	94.49	82.21	90.06	0.103	0.157
15	Proposed score	92.67	90.52	85.46	93.65	82.13	88.70	0.136	0.189
15	$\kappa$	92.50	90.45	84.72	93.02	81.00	87.61	0.149	0.205
Salinas									
5	Proposed score	81.85	90.87	64.19	89.40	61.34	80.36	0.089	0.252
5	$\kappa$	81.80	90.81	64.02	89.28	61.13	80.20	0.090	0.255
15	Proposed score	82.77	91.72	64.78	87.86	61.13	77.82	0.120	0.295
15	$\kappa$	82.81	91.78	64.41	87.20	60.44	76.71	0.134	0.313

## 5. REFERENCES

- [1] S. B. Serpico and G. Moser, "Extraction of spectral channels from hyperspectral images for classification purposes," *IEEE TGRS*, vol. 45, no. 2, pp. 484–495, Feb. 2007.
- [2] P. A. Estévez, M. Tesmer, C. A. Perez, and J. M. Zurada, "Normalized mutual information feature selection," *IEEE Transactions on Neural Networks*, vol. 20, no. 2, pp. 189–201, Feb. 2009.
- [3] S. Li, H. Wu, D. Wan, and J. Zhu, "An effective feature selection method for hyperspectral image classification based on genetic algorithm and support vector machine," *Knowledge-based Systems*, vol. 24, pp. 40–48, 2011.
- [4] R. Díaz-Uriarte and S. A. De Andres, "Gene selection and classification of microarray data using random forest," *BMC bioinformatics*, vol. 7, no. 3, pp. 1–13, 2006.
- [5] I. Guyon, J. Weston, S. Barnhill, and V. Vapnik, "Gene selection for cancer classification using support vector machines," *Machine Learning*, vol. 46, pp. 289–422, 2002.
- [6] L. Breiman, "Random forests," *Machine Learning*, vol. 45, no. 1, pp. 5–32, 2001.
- [7] M. Pal, "Margin-based feature selection for hyperspectral data," *International Journal of Applied Earth Observation and Geoinformation*, vol. 11, pp. 121–220, 2009.
- [8] M. Pal, "Random forest classifier for remote sensing classification," *International Journal of Remote Sensing*, vol. 26, no. 1, pp. 217–222, 2005.
- [9] A. Le Bris, N. Chehata, X. Briottet, and N. Paparoditis, "Identify important spectrum bands for classification using importances of wrapper selection applied to hyperspectral," in *Proc. of the 2014 International Workshop on Computational Intelligence for Multimedia Understanding (IWCIM'14)*, Nov. 2014.
- [10] A. Joshi, F. Prikli, and N. Papanikopoulos, "Multi-class activelearning for image classification," in *Proc. of CVPR*, 2009.





# Remerciements



## Références



---

# Bibliographie

- AASEN, H., GNYP, M., MIAO, Y. et BARETH, G. (2014). Towards robust vegetation indices : the multi-correlation matrix strategy. *In Proc. of the 6th Workshop on Hyperspectral Image and Signal Processing : Evolution in Remote Sensing (WHISPERS'14)*.
- ADELIN, K., CHEN, M., BRIOTTET, X., PANG, S. et PAPARODITIS, N. (2013a). Shadow detection in very high spatial resolution aerial images : a comparative study. *ISPRS Journal of Photogrammetry and Remote Sensing*, 80:21–38.
- ADELIN, K., GOMEZ, C., GORRETTA, N. et ROGER, J. (2014). Sensitivity of soil property prediction obtained from VNIR/SWIR data to spectral configurations. *In Proc. of the 4th International Symposium on Recent Advances in Quantitative Remote Sensing : RAQRS'IV*.
- ADELIN, K., LE BRIS, A., COUBARD, F., BRIOTTET, X., PAPARODITIS, N., VIALLEFONT, F., RIVIÈRE, N., PAPELARD, J.-P., DAVID, N., DÉLIOT, P., DUFFAUT, J., POUTIER, L., FOUCHER, P., ACHARD, V., SOUCHON, J.-P., THOM, C., AIRAULT, S. et MAILLET, G. (2013b). Description de la campagne aéroportée UMBRA : étude de l'impact anthropique sur les écosystèmes urbains et naturels avec des images THR multispectrales et hyperspectrales. *Revue Française de Photogrammétrie et de Télédétection*, 202:79–92.
- ALONZO, M., BOOKHAGEN, A. et ROBERTS, D. (2014). Urban tree species mapping using hyperspectral and lidar data fusion. *Remote Sensing of Environment*, 148:70–83.
- ATKINSON, P., CUTLER, M. et LEWIS, H. (1997). Mapping sub-pixel proportional landcover with AVHRR imagery. *International Journal of Remote Sensing*, 18(4).
- BALDRIDGE, A. M., HOOK, S., GROVE, C. et RIVERA, G. (2009). The ASTER spectral library Version 2.0. *Remote Sensing of Environment*, 113:711–715.
- BASSANI, C., CAVALLI, R., CAVALCANTE, F., CUOMO, V., PALOMBO, A., PASCUCCI, S. et PIGNATTI, S. (2007). Deterioration status of asbestos-cement roofing sheets assessed by analyzing hyperspectral data. *Remote Sensing of Environment*, 109:361–378.
- BATTITI, R. (1994). Using mutual information for selecting features in supervised neural net learning. *IEEE Transactions on Neural Networks*, 5(4).
- BELOUSOV, A., VERZAKOV, S. et FRESE, J. (2002). A flexible classification approach with optimal generalisation performance : support vector machines. *Chemometrics and Intelligent Laboratory Systems*, 64(1):15–25.
- BEN-DOR, E., LEVIN, N. et SAARONI, H. (2001). A spectral based recognition of the urban environment using the visible and near-infrared spectral region (0.4-1.1  $\mu\text{m}$ ). A case study over Tel-Aviv, Israel. *International Journal of Remote Sensing*, 22(11):2193–2218.
- BIGDELI, B., SAMADZADEGAN, F. et REINARTZ, P. (2013). Band grouping versus band clustering in svm ensemble classification of hyperspectral imagery. *Photogrammetric Engineering and Remote Sensing*, 79(6):523–533.

- BOLDO, D. (2001). *Fabrication conjointe de Modèles Numériques de Surface et d'ortho-images pour la visualisation perspective de scènes urbaines*. Thèse de doctorat, Université René Descartes – Paris V.
- BOSER, E., GUYON, I. et VAPNIK, V. (1992). A training algorithm for optimal margin classifiers. *In Fifth Annual Workshop on Computational Learning Theory*, pages 144–152.
- BOUYER, J. (2009). *Modélisation et simulation des microclimats urbains - Étude de l'impact de l'aménagement urbain sur les consommations énergétiques des bâtiments*. Thèse de doctorat, Ecole Polytechnique de l'Université de Nantes, Ecole Nationale Supérieure d'Architecture de Nantes.
- BRADSKI, G. (2000). OpenCV library. *Dr. Dobb's Journal of Software Tools*.
- BRAUN, A., WEIDNER, U. et HINZ, S. (2012). Classification in high-dimensional feature spaces - assessment using SVM, IVM and RVM with focus on simulated EnMap data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(2):436–443.
- BREIMAN, L. (2001). Random forests. *Machine Learning*, 45(1):5–32.
- BREIMAN, L., FRIEDMAN, J., STONE, C. et OLSHEN, R. (1984). *Classification and regression trees*. CRC press.
- BRIOTTET, X. et CARRÈRE, V. (2012). Prétraitements : étalonnage, correction du bruit, compensation des effets atmosphériques. Cours de l'école d'été en traitement des images hyperspectrales de la SFTH.
- BRIOTTET, X., LACHÉRADE, S., PALLOTTA, S., MIESCH, C., TANGUY, B. et LE MEN, H. (2006). Acquisition and analysis of a spectral and bidirectional database of urban materials over Toulouse (France). *SPIE Proceedings*, 6239.
- BRUCE, L. (2014). Game theory models for spectral band grouping and classifier ensembles for hyperspectral image classification. *In Proc. of the 6th Workshop on Hyperspectral Image and Signal Processing : Evolution in Remote Sensing (WHISPERS'14)*.
- BRUZZONE, L. et SERPICO, S. B. (2000). A technique for feature selection in multiclass problem. *International Journal of Remote Sensing*, 21(3):549–563.
- CAMPEDEL, M., MAÎTRE, H. et MOULINES, E. (2004). Indexation des images satellitaires - comparaison et évaluation des caractéristiques pour la classification. Rapport technique, Télécom Paris.
- CAMPS-VALLS, G., BANDOS MARSHEVA, T. et ZHOU, D. (2007). Semi-supervised graph-based hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 45(10):3044–3054.
- CAMPS-VALLS, G. et BRUZZONE, L. (2005). Kernel-based methods for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 43(6):1351–1362.
- CANG, S. et HONGNIAN, Y. (2012). Mutual information based input feature selection for classification problems. *Decision Support Systems*, 54:691–698.
- CANNELLE-MARTINELLI, C. (2005). Flux de métaux dans les bassins versants urbains et modèle de caractérisation des toitures : cas de Paris. Mémoire de D.E.A., Ecole des Mines de Paris.
- CARIOU, C., CHEHDI, K. et LE MOAN, S. (2011). BandClust : an unsupervised band reduction method for hyperspectral remote sensing. *IEEE Geoscience and Remote Sensing Letters*, 8(3):565–569.

- 
- CARRILERO, A.-C., MAÎTRE, H. et ROUX, M. (2001). Material determination from reflectance properties in aerial urban images. *In Proc. of the 11th International Conference on Image Analysis and Processing (ICIP'01)*, Palerme, Italie.
- CAVALLI, R., FUSILLI, L., PASCUCCI, S., PIGNATTI, S. et SANTINI, F. (2008). Hyperspectral sensor data capability for retrieving complex urban land cover in comparison with multispectral data : Venice city case study (Italy). *Sensors*, 8:3299–3320.
- CHANG, C. (2000). An information-theoretic approach to spectral variability, similarity and discrimination for hyperspectral image analysis. *IEEE Transactions on Information Theory*, 46(15):1927–1932.
- CHANG, C.-C. et LIN, C.-J. (2011). LIBSVM : a library for Support Vector Machines. *ACM Transactions on Intelligent Systems and Technology*, 2:27 :1–27 :27. Software available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm>.
- CHANG, C.-I., DU, Q., SUN, T.-L. et ALTHOUSE, M. (1999). A joint band prioritization and band-decorrelation approach to band selection for hyperspectral image classification. *IEEE Transactions on Geoscience and Remote Sensing*, 37(6):2631–2641.
- CHANG, C.-I. et WANG, S. (2006). Constrained band selection for hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 44(6):1575–1585.
- CHANG, Y.-L., CHEN, K.-S., HUANG, B., CHANG, W.-Y., BENEDIKTSSON, J. et CHANG, L. (2011). A parallel simulated annealing approach to band selection for high-dimensional remote sensing images. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 4(3):579–590.
- CHEBBO, G., GROMAIRE, M., AHYERRE, M. et GARNAUD, S. (2001). Production and transport of urban wet weather pollution in combined sewer systems : the Marais experimental catchment in paris. *Urban Water*, 3(1-2):3–15.
- CHEHATA, N., LE BRIS, A. et NAJJAR, S. (2014). Contribution of band selection and fusion for hyperspectral classification. *In Proc. of the 6th Workshop on Hyperspectral Image and Signal Processing : Evolution in Remote Sensing (WHISPERS'14)*.
- CHEUNG-WAI CHAN, J. et PAELINCKX, D. (2008). Evaluation of Random Forest and Adaboost tree-based ensemble classification and spectral band selection for ecotope mapping using airborne hyperspectral imagery. *Remote Sensing of Environment*, 112:2999–3011.
- CHISENSE, C. (2012). Classification of roof materials using hyperpsectral data. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 39(B7):103–107.
- CHUNG, K.-L., LIN, Y.-R. et HUANG, Y.-H. (2009). Efficient shadow detection of color aerial images based on successive thresholding scheme. *IEEE Transactions on Geoscience and Remote Sensing*, 47(2):671–682.
- CLARK, R., KING, T., KLEJWA, M. et SWAYZE, G. (1990). High spectral resolution spectroscopy of minerals. *Journal of Geophysical Research*, 95(B8):12653–12680.
- CLARK, R., SWAYZE, G., GALLAGHER, A., GORELICK, N. et KRUSE, F. (1992). Mapping with imaging spectrometer data using the complete band shape least-squares algorithm simultaneously fit to multiple spectral features from multiple materials. *In Summaries of the Third Annual JPL Airborne Geoscience Workshop : JPL Publication 92-14, Vol 1*, pages 11–13.



- CLARK, R. N., SWAYZE, G. A., LIVO, K. E., KOKALY, R. F., SUTLEY, S. J. ., DALTON, J. B., MCDUGAL, R. R. et GENT, C. A. (2003). Imaging spectroscopy : Earth and planetary remote sensing with the USGS Tetracorder and expert systems. *Journal of Geophysical Research*, 108(E12):5-1-5-44.
- COHEN, J. (1960). A coefficient of agreement for nominal scales. *Educational and Psychological Measurement*, 20:27-46.
- CORTES, C. et VAPNIK, V. (1995). Support-vector networks. *Machine learning*, 20(3):273-297.
- CRIMINISI, A. et SHOTTON, J. (2013). *Decision forests for computer vision and medical image analysis*. Springer-Verlag, Londres, Royaume-Uni.
- DARE, P. (2005). Shadow analysis in high-resolution satellite imagery of urban areas. *Photogrammetric Engineering and Remote Sensing*, 71(2):169-177.
- DE BACKER, S., KEMPENEERS, P., DEBRUYN, W. et SCHEUNDERS, P. (2005). A band selection technique for spectral classification. *IEEE Geoscience and Remote Sensing Letters*, 2(3):319-232.
- DEMARCHI, L., CHEUNG-WAI CHAN, J., MA, J. et CANTERS, F. (2012). Mapping impervious surfaces from superresolution enhanced CHRIS/Proba imagery using multiple endmember unmixing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 72(8):99 - 112.
- DEMIR, B., CELEBI, A. et ERTÜRK, S. (2009). A low-complexity approach for the color display of hyperspectral remote-sensing images using one-bit-transform-based band selection. *IEEE Transactions on Geoscience and Remote Sensing*, 47(1):97-105.
- DÍAZ-URIARTE, R. et DE ANDRES, S. A. (2006). Gene selection and classification of microarray data using Random Forest. *BMC bioinformatics*, 7(3):1-13.
- DOZ, S. (2011). *Méthode de simulation d'images urbaines à partir d'acquisitions aéroportées multi-angulaires à très hautes résolutions spatiale et spectrale*. Thèse de doctorat, Université de Toulouse.
- DU, H., QI, H., WANG, X., RAMANATH, R. et SNYDER, W. (2003). Band selection using independent component analysis for hyperspectral image processing. *In Proceedings of the 32nd Applied Imagery Pattern Recognition Workshop*, pages 93-98.
- DU, Q. et YANG, H. (2008). Similarity-based unsupervised band selection for hyperspectral image analysis. *IEEE Geoscience and Remote Sensing Letters*, 5(4):564-568.
- DU, Y., CHANG, C.-I., REN, H., CHANG, C.-C., JENSEN, J. O. et D'AMICO, F. M. (2004). New hyperspectral discrimination measure for spectral characterization. *Optical Engineering*, 43(8):1777-1786.
- ESTÉVEZ, P. A., TESMER, M., PEREZ, C. A. et ZURADA, J. M. (2009). Normalized mutual information feature selection. *IEEE Transactions on Neural Networks*, 20(2):189-201.
- EUROPEAN ENVIRONMENT AGENCY (2008). Mapping guide for a european urban atlas. Rapport technique, European Environment Agency. available at <http://www.eea.europa.eu/data-and-maps/data/urban-atlas/>.
- EUROPEAN ENVIRONMENT AGENCY (2012). CORINE Land Cover. Rapport technique, European Environment Agency. available at [http://www.eea.europa.eu/publications/COR0-landcover/land\\_cover.pdf](http://www.eea.europa.eu/publications/COR0-landcover/land_cover.pdf).

- 
- FAUVEL, M. (2007). *Spectral and spatial methods for the classification of urban remote sensing data*. Thèse de doctorat, Institut National Polytechnique de Grenoble.
- FAUVEL, M. (2012). Kernel matrix approximation for learning the kernel hyperparameters. *In Proc. of the 2012 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, pages 5418–5421.
- FAUVEL, M., CHANUSSOT, J. et BENEDIKTSSON, J. (2006). Evaluation of kernels for multiclass classification of hyperspectral remote sensing data. *In Proc. of the 2006 IEEE International Conference on Acoustics, Speech and Signal Processing, 2006 (ICASSP 2006)*, volume 2.
- FAUVEL, M., CHANUSSOT, J. et BENEDIKTSSON, J. A. (2012). A spatial-spectral kernel based approach for the classification of remote sensing images. *Pattern Recognition*, 45(4):281–392.
- FAUVEL, M., ZULLO, A. et FERRATY, F. (2014). Nonlinear parsimonious feature selection for the classification of hyperspectral images. *In Proc. of the 6th Workshop on Hyperspectral Image and Signal Processing : Evolution in Remote Sensing (WHISPERS'14)*.
- FISHER, R. (1936). The use of multiple measurements in taxonomic problems. *Annals of Eugenics*, 7(2):179–188.
- FLEISS, J. L. et COHEN, J. (1973). The equivalence of weighted Kappa and the intraclass correlation coefficient as measures of reliability. *Educational and Psychological Measurement*, 33:613–619.
- FORSTER, J. (1996). Heavy metal and ion pollution patterns in roof runoff. *In 7th International Conference on Urban Storm Drainage*, Hanovre, Allemagne.
- FRANKE, J., ROBERTS, D., HALLIGAN, K. et MENZ, G. (2009). Hierarchical Multiple Endmember Spectral Mixture Analysis (MESMA) of hyperspectral imagery for urban environments. *Remote Sensing of Environment*, 113(8):1712 – 1723.
- FRASSY, F., CANDIANI, G., RUSMINI, M., MAIANTI, P., MARCHESI, A., ROTA NODARI, F., DALLA VIA, F., ALBONICO, C. et GIANINETTO, M. (2014). Monitoring asbestos-cement roofing with hyperspectral remote sensing over a large mountain region of the Italian Western Alps. *Sensors*, 14:15900–15913.
- FRÖHLICH, H., CHAPELLE, O. et SCHÖLKOPF, B. (2003). Feature selection for Support Vector Machines by means of genetic algorithms. *In Proc. of the 15th IEEE International Conference on Tools with Artificial Intelligence*, pages 142–148.
- GENUER, R. (2010). *Forêts aléatoires : aspects théoriques, sélection de variables et applications*. Thèse de doctorat, Université Paris-Sud 11, France.
- GENUER, R., POGGI, J.-M. et TULEAU-MALOT, C. (2010). Variable selection using Random Forests. *Pattern Recognition Letters*, 31:2225–2236.
- GRIMMOND, C. et OKE, T. (2002). Turbulent heat fluxes in urban areas : observations and a Local-scale Urban Meteorological Parametrization Scheme (LUMPS). *Journal of Applied Meteorology*, 41(7):792–810.
- GROMAIRE-MERTZ, M., GARNAUD, S., GONZALEZ, A. et CHEBBO, G. (1999). Characterisation of urban runoff pollution in Paris. *Water, Science and Technology*, 39(2):1–8.
- GU, Y., WANG, C., YOU, D., ZHANG, Y., WANG, S. et ZHANG, Y. (2012). Representative multiple kernel learning for classification in hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 50(7):2852–2865.

- GUO, B., DAMPER, R., GUNN, S. et NELSON, J. (2008a). A fast separability-based feature-selection method for high-dimensional remotely sensed image classification. *Pattern Recognition*, 41:1653–1662.
- GUO, H.-T., YAN, Z., JUN, L. et GUO-WANG, J. (2008b). Research on the building shadow extraction and elimination method. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 37(B3b):569–574.
- GUYON, I., WESTON, J., BARNHILL, S. et VAPNIK, V. (2002). Gene selection for cancer classification using Support Vector Machines. *Machine Learning*, 46:289–422.
- HALL, M. A. et HOLMES, G. (2003). Benchmarking attribute selection techniques for discrete class data mining. *IEEE Transactions on Knowledge and Data Engineering*, 15(6):1437–1447.
- HASANLOU, M. et SAMADZADEGAN, F. (2010). ICA/PCA based genetic band selection for classification of hyperspectral images. In *Proc. of the Asian Conference on Remote Sensing (ACRS)*.
- HEIDEN, U., HELDENS, W., ROESSNER, S., SEGL, K., ESCH, T. et MUELLER, A. (2012). Urban structure type characterization using hyperspectral remote sensing and height information. *Landscape and Urban Planning*, 105:361–375.
- HEIDEN, U., SEGL, K., ROESSNER, S. et KAUFMANN, H. (2007). Determination of robust spectral features for identification of urban surface materials in hyperspectral remote sensing data. *Remote Sensing of Environment*, 111(4):537 – 552.
- HEIJERICK, D., JANSSEN, J., KARLEN, C., ODNEVALL WALLINDER, I. et LEYGRAF, C. (2002). Bioavailability of zinc in runoff water from roofing materials. *Chemosphere*, 47:1073–1080.
- HELDENS, W., ESCH, T., HEIDEN, U., MÜLLER, A. et DECH, S. (2009). Exploring the demands on hyperspectral data products for urban planning : a case study in the Munich region. In *Proc. of 6th EARSeL SIG-IS Workshop*.
- HELDENS, W., HEIDEN, U., ESCH, T. et DECH, S. (2010). Potential of hyperspectral data for urban micro climate analysis. In *Proc. of the Hyperspectral 2010 Workshop*.
- HELDENS, W., HEIDEN, U., ESCH, T., STEIN, E. et MULLER, A. (2011). Can the future EnMAP mission contribute to urban applications? A literature survey. *Remote Sensing*, 3:1817–1846.
- HEROLD, M. (2004). Santa Barbara urban spectral library. [http://www.ncgia.ucsb.edu/ncrst/research/pavementhealth/urban/sburbspec\\_main.htm](http://www.ncgia.ucsb.edu/ncrst/research/pavementhealth/urban/sburbspec_main.htm).
- HEROLD, M., GARDNER, M. E. et ROBERTS, D. A. (2003). Spectral resolution requirements for mapping urban areas. *IEEE Transactions on Geoscience and Remote Sensing*, 41(9):1907–1919.
- HEROLD, M., ROBERTS, D., GARDNER, M. et DENNISON, P. (2004a). Spectrometry for urban area remote sensing—development and analysis of a spectral library from 350 to 2400 nm. *Remote Sensing of Environment*, 91(3-4):304 – 319.
- HEROLD, M., ROBERTS, D., SMADI, O. et NORONHA, V. (2004b). Road condition mapping using hyperspectral remote sensing. In *Proceedings of the AVIRIS Workshop*, Pasadena, USA.
- HO, T. (1998). The random subspace method for constructing decision forests. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 20(8):832–844.

- HOUET, T. et PIGEON, G. (2011). Mapping urban climate zones and quantifying climate behaviors - an application on Toulouse urban area (France). *Environmental Pollution*, 159:2180–2192.
- HSU, C., CHANG, C. et LIN, C. (2003). A practical guide to support vector classification. Rapport technique, Department of Computer Science, National Taiwan University, Taiwan.
- HUANG, C., DAVIS, L. et TOWNSHEND, J. (2002). An assessment of Support Vector Machines for land cover classification. *International Journal of Remote Sensing*, 23(4):725–749.
- HUGHES, G. (1968). On the mean accuracy of statistical pattern recognizers. *IEEE Transactions on Information Theory*, 14(1):55–63.
- IDCZAK, M., GROLEAU, D., MESTAYER, P. G., ROSANT, J.-M. et SINI, J.-F. (2010). An application of the thermo-radiative model SOLENE for the evaluation of street canyon energy balance. *Building and Environment*, 45:1262–1275.
- IFSTTAR (2013). Eaux et sols urbains : nouvel enjeu environnemental. *Trajectoire (le magazine de la recherche, de l'expertise et des métiers de l'IFSTTAR)*, 5:7–10.
- IGN (2012). La cartographie forestière version 2 de l'Inventaire Forestier National - Guide technique.
- IOVAN, C. (2009). *Détection et caractérisation de la végétation en milieu urbain à partir d'images aériennes haute résolution*. Thèse de doctorat, Université Pierre et Marie Curie - Paris 6.
- JENSEN, A.-C. et SOLBERG, A.-S. (2007). Fast hyperspectral feature reduction using piecewise constant function approximations. *IEEE Geoscience and Remote Sensing Letters*, 4(4):547–551.
- JIA, S., JI, Z., QIAN, Y. et SHEN, L. (2012). Unsupervised band selection for hyperspectral imagery classification without manual band removal. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(2):531–543.
- JOCHER, A., HÖFLE, B., RUTZINGER, M. et PFEIFER, N. (2009). Automatic roof plane detection and analysis in airborne lidar point clouds for solar potential assessment. *Sensors*, 9:5241–5262.
- KANDASAMY, S., MINGHELLI-ROMAN, A., TAVIN, F., MATHIEU, S., BARET, F. et GOUTON, P. (2009a). Optimal band selection for future satellite sensor dedicated to soil science. In *Hyperspectral Image and Signal Processing : Evolution in Remote Sensing, 2009. WHISPERS '09. First Workshop on*, pages 1–4.
- KANDASAMY, S., TAVIN, F., MINGHELLI-ROMAN, A., MATHIEU, S., WEIDONG, L., BARET, F. et GOUTON, P. (2009b). Optimization of image parameters using a hyperspectral library application to soil identification and moisture estimation. In *Geoscience and Remote Sensing Symposium, 2009 IEEE International, IGARSS 2009*, volume 3, pages III–141–III–144.
- KAUFMANN, H., SEGL, K., ITZEROTT, S., BACH, H., WAGNER, A., HILL, J., HEIM, B., OPPERMANN, K., HELDENS, W., STEIN, E., MÜLLER, A., Van der LINDEN, S., LEITÃO, P., RABE, A. et HOSTERT, P. (2010). Hyperspectral algorithms : report in the frame of EnMAP preparation activities (Scientific Technical Report STR10/08). Rapport technique, Deutsches GeoForschungsZentrum (GFZ).
- KERMADI, S., RENARD, F., JACQUEMINET, C. et MICHEL, K. (2010). Inondations et occupation du sol dans un bassin versant périurbain : l'Yzeron (Ouest Lyonnais). In *Risques et changement climatique : actes du 23ième Colloque de l'Association Internationale de Climatologie*, pages 313–318, Rennes.

- KESHA, N. (2002). Distance metrics and band selection in hyperspectral processing with applications to material identification and spectral libraries. Rapport technique, Lincoln Laboratory - Massachusetts Institute of Technology.
- KIRA, K. et RENDELL, L. (1992). A practical approach to feature selection. *In Proceedings of the 9th International Workshop on Machine Learning*, pages 249–256.
- KONONENKO, I., SIMEC, E. et ROBNIK-SIKONJA, M. (1997). Overcoming the myopia of inductive learning algorithms with RELIEFF. *Applied Intelligence*, 7(1):39–55.
- KOTTHAUS, S., SMITH, T., WOOSTER, M. J. et GRIMMOND, C. (2014). Derivation of an urban materials spectral library through emittance and reflectance spectroscopy. *ISPRS Journal of Photogrammetry and Remote Sensing*, 94:194–212.
- KUMAR, S., GHOSH, J. et CRAWFORD, M. (2001). Best-bases feature extraction algorithms for classification of hyperspectral data. *IEEE Transactions on Geoscience and Remote Sensing*, 39(7):1368–1379.
- LACHERADE, S. (2006). *Caractérisation des propriétés optiques des matériaux urbains à partir d’images de télédétection à très hautes résolutions spatiale et spectrale*. Thèse de doctorat, Ecole Nationale Supérieure de L’Aéronautique et de l’Espace.
- LACHERADE, S., MIESCH, C., BRIOTTET, X. et LE MEN, H. (2005). Spectral variability and bidirectional reflectance behaviour of urban materials at a 20 cm spatial resolution in the visible and near-infrared wavelengths. A case study over Toulouse (France). *International Journal of Remote Sensing*, 26(17):3859–3866.
- LE BRIS, A. et CHEHATA, N. (2011). Change detection in a topographic building database using submetric satellite images. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 38(3/W22):25–30.
- LE BRIS, A., CHEHATA, N., BRIOTTET, X. et PAPANODITIS, N. (2015). A Random Forest class memberships based wrapper band selection criterion : application to hyperspectral. *In Proc. of the 2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS’2015)*.
- LE BRIS, A. et ROBERT-SAINTE, P. (2009). Classification of roof materials for rainwater pollution modelization. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 38(1-4-7/W5):CD–Rom.
- LE CUN, Y., BOTTOU, L., ORR, G. B. et MULLER, K.-R. (1998). *Neural networks—tricks of the trade*, Springer Lecture Notes in Computer Sciences, volume 1524, chapitre Efficient backprop, pages 5–50. Springer.
- LE MOAN, S., MANSOURI, A., VOISIN, Y. et HARDEBERG, J. (2011). A constrained band selection method based on information measures for spectral image color visualization. *IEEE Transactions on Geoscience and Remote Sensing*, 49(12):5104–5115.
- LE NOUVEAU, N., DEROUBAIX, J.-F., DIOU, G. et TARDIVO, B. (2013). La taxe pour la gestion des eaux pluviales urbaines, un révélateur de l’action publique : analyse des premières expériences en France - Urban stormwater management fee revealing public action : analysis of the first French experiences. *In Proc. of NOVATECH 2013*, pages 1–12.
- LEMP, D. et WEIDNER, U. (2004). Use of hyperspectral and laser scanning data for the characterization of surfaces in urban areas. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 35(B7):CD–Rom.

- 
- LEMP, D. et WEIDNER, U. (2005). Improvements of roof surface classification using hyperspectral and laser scanning data areas. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 36(8/W27):CD–Rom.
- LI, C.-H., HO, H.-H., LIU, Y.-L., LIN, C.-T., KUO, B.-C. et TAUR, J.-S. (2012). An automatic method for selecting the parameter of the normalized kernel function to support vector machines. *Journal of Information Science and Engineering*, 28:1–15.
- LI, S., WU, H., WAN, D. et ZHU, J. (2011). An effective feature selection method for hyperspectral image classification based on genetic algorithm and Support Vector Machine. *Knowledge-based Systems*, 24:40–48.
- LI, Y., GONG, P. et SASAGAWA, T. (2005). Integrated shadow removal based on photogrammetry and image analysis. *International Journal of Remote Sensing*, 26(18):3911–3929.
- LI, Y., SASAGAWA, T. et GONG, P. (2004). A system of the shadow detection and shadow removal for high resolution city aerial photo. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 35(B3):802–807.
- LIU, J. (2011). Shadow detection in remotely sensed images based on self-adaptive feature selection. *IEEE Transactions on Geoscience and Remote Sensing*, 49(12):5092–5103.
- MA, S. et HUANG, J. (2008). Penalized feature selection and classification in bioinformatics. *Briefings in bioinformatics*, 8(5):392–403.
- MAKARAU, A., RICHTER, R., MÜLLER, R. et REINARTZ, P. (2001). Adaptive shadow detection using a blackbody radiator model. *IEEE Transactions on Geoscience and Remote Sensing*, 49(6):2049–2059.
- MANAKOS, I. et BRAUN, M., éditeurs (2014). *Land use and land cover mapping in Europe : practices and trends*. Springer.
- MARINO, C., PANIGADA, C. et Busetto, L. (2001). Airborne hyperspectral remote sensing applications in urban areas : asbestos concrete sheeting identification and mapping. *In Proc. of the IEEE/ISPRS Joint Workshop on Remote Sensing and Data Fusion over Urban Areas*, pages 212–216.
- MARIOTTO, I., THENKABAIL, P., HUETE, A., SLONECKER, T. et PLATONOV, A. (2013). Hyperspectral versus multispectral crop-productivity modeling and type discrimination for the hyperspi mission. *Remote Sensing of Environment*, 139:291–305.
- MARTIN, C. et ROSIER, B. (2012). Status of “MEMOIRES” - a thermal and optical data base (Mean of Exchange and valorization of Measurements of thermal, Optical and InfraRED properties of Samples and scenes). *In Fraunhofer IOSB*, Ettlingen, Allemagne.
- MARTÍNEZ-USÓ, A., PLA, F., MARTÍNEZ SOTOCA, J. et GARCÍA-SEVILLA, P. (2007). Clustering-based hyperspectral band selection using information measures. *IEEE Transactions on Geoscience and Remote Sensing*, 45(12):4158–4171.
- MARTINOTY, G. (2005). *Reconnaissance de matériaux sur des images aériennes en multirecouvrement, par identification de fonctions de réflectance bidirectionnelles*. Thèse de doctorat, Université Paris 7 - Denis Diderot.
- MASSALABI, A., HE, D.-C., BÉNIÉ, G.-B. et BEAUDRY, E. (2004). Restitution of information under shadow in remote sensing high space resolution images : application to IKONOS data of Sherbrooke city. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 35:173–178.

- MELGANI, F. et BRUZZONE, L. (2004). Classification of hyperspectral remote sensing images with Support Vector Machines. *IEEE Transactions on Geoscience and Remote Sensing*, 42(8):1778–1790.
- MENDE, A., HEIDEN, U., BACHMANN, M., HOJA, D. et BUCHROITHNER, M. (2011). Development of a new spectral library classifier for airborne hyperspectral images on heterogeneous environments. In *Proceedings of the EARSeL 7th SIG-Imaging Spectroscopy Workshop*, Edinburgh, Royaume-Uni.
- MERCIER, G. et LENNON, M. (2003). Support Vector Machines for hyperspectral image classification with spectral-based kernels. In *Proc. of the 2003 IEEE International Geoscience and Remote Sensing Symposium (IGARSS'03)*, volume 1, pages 288–290. IEEE.
- MINET, J. (2011). *Imagerie multispectrale, vers une conception adaptée à la détection de cibles*. Thèse de doctorat, Université Paris 11.
- MINET, J., TABOURY, J., PEALAT, M., ROUX, N., LONNOY, J. et FERREC, Y. (2010). Adaptive band selection snapshot multispectral imaging in the VIS/NIR domain. *Proceedings of SPIE the International Society for Optical Engineering*, 7835:10.
- MINGHELLI-ROMAN, A. (2010). Simulation, analyse, fusion d'images multi/hyperspectrales et applications. Habilitation à diriger des recherches, Université du Sud Toulon Var.
- MOHAMMADI, M. (2012). Road classification and condition determination using hyperspectral imagery. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XXXIX-B7.
- NAJJAR, S. (2013). Sélection à partir de données hyperspectrales d'un ensemble de bandes spectrales utiles à l'aide des random forests. Mémoire de D.E.A., Université de la Mannouba - Ecole nationale des Sciences de l'Informatique.
- OLTRA-CARRIO, R., BRIOTTET, X. et BONHOMME, M. (2015). Impact of spatial and spectral resolutions on the classification of urban areas. In *Proc. of the Joint Urban Remote Sensing Event (JURSE 2015)*.
- PAL, M. (2005). Random Forest classifier for remote sensing classification. *International Journal of Remote Sensing*, 26(1):217–222.
- PAL, M. (2009). Margin-based feature selection for hyperspectral data. *International Journal of Applied Earth Observation and Geoinformation*, 11:121–220.
- PAL, M. et FOODY, G. (2010). Feature selection for classification of hyperspectral data by svm. *IEEE Transactions on Geoscience and Remote Sensing*, 48(5):2297–2307.
- PLATT, J. (2000). *Advances in large margin classifiers*, chapitre Probabilistic outputs for Support Vector Machines and comparisons to regularized Maximum Likelihood methods. MIT Press.
- PONTIUS, R. et MILLONES, M. (2011). Death to Kappa : birth of quantity disagreement and allocation disagreement for accuracy assessment. *International Journal of Remote Sensing*, 32(15):4407–4429.
- PRASAD, S. et BRUCE, L. M. (2008). Decision fusion with confidence-based weight assignment for hyperspectral target recognition. *IEEE Transactions on Geoscience and Remote Sensing*, 46(5):1448–1456.
- PRICE, J. (1994). How unique are spectral signatures? *Remote Sensing of Environment*, 49(3): 181–186.

- 
- PUDIL, P., NOVOCICOVA, J. et KITTLER, J. (1994). Floating search methods in feature selection. *Pattern Recognition Letters*, 15:1119–1125.
- RIEDMILLER, M. et BRAUN, H. (1993). A direct adaptive method for faster backpropagation learning : the RPROP algorithm. *In Proc. ICNN*.
- ROBERT, P., GROMAIRE, M., DE GOUELLO, B. et CHEBBO, G. (2005). Typologie des matériaux de couverture et évaluation de leur potentiel polluant. *In Novatech'2007*, Novatech'2007.
- ROBERT-SAINTE, P. (2009). *Contribution des matériaux de couverture à la contamination métallique des eaux de ruissellement*. Thèse de doctorat, Université Paris-Est.
- ROESSNER, S., SEGL, K., HEIDEN, U. et KAUFMANN, H. (2001). Automated differentiation of urban surfaces based on airborne hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 39(7):1525–1532.
- ROSCHER, R., FÖRSTNER, W. et WASKE, B. (2012a). I2VM : Incremental Import Vector Machines. *Image and Vision Computing*, 30(4-5):263–278.
- ROSCHER, R., WASKE, B. et FÖRSTNER, W. (2012b). Incremental Import Vector machines for classifying hyperspectral data. *Geoscience and Remote Sensing, IEEE Transactions on*, 50(9):3463–3473.
- ROUSSEL, G. (2012). *Développement et évaluation de nouvelles méthodes de classification spatiale-spectrale d'images hyperspectrales*. Thèse de doctorat, ISAE Institut Supérieur de l'Aéronautique et de l'Espace - Ecole doctorale GEET (Génie Electrique Electronique et Télécommunications : du système au nanosystème).
- ROY, J. (2010). The use of VHR remote sensing imagery for the identification of roofs potentially suitable for the installation of photovoltaic panels. Présentation aux Journées Thématiques Pléiades.
- SARABANDI, P., YAMAZAKI, F., MATSUOKA, M. et KIREMIDJIAN, A. (2004). Shadow detection and radiometric restoration in satellite high resolution images. *In Proc. of IGARSS'04*.
- SELLAMI-KAANICHE, E. (2014). *Conception pluridisciplinaire d'une méthode générale d'évaluation des flux de contaminants issus des ruissellements des matériaux de toitures à l'échelle urbaine - développement et illustration à partir du cas du zinc à Créteil*. Thèse de doctorat, Université Paris-Est.
- SERPICO, S. B. et BRUZZONE, L. (2001). A new search algorithm for feature selection in hyperspectral remote sensing images. *IEEE Transactions on Geoscience and Remote Sensing*, 39:1360–1367.
- SERPICO, S. B. et MOSER, G. (2007). Extraction of spectral channels from hyperspectral images for classification purposes. *IEEE Transactions on Geoscience and Remote Sensing*, 45(2):484–495.
- SHAFRI, H., TAHERZADEH, E., MANSOR, S. et ASHUROV, R. (2012). Hyperspectral remote sensing of urban areas : an overview of techniques and applications. *Research Journal of Applied Sciences, Engineering and Technology*, 4(11):1557–1565.
- SOBRINO, J., BIANCHI, R., PAGANINI, M., SÒRIA, G., JIMÉNEZ-MUNOZ, J., OLTRA-CARRIÒ, R., MATTAR, C., ROMAGUERA, M., FRANCH, B., HIDALGO, V., CUENCA, J., JULIEN, Y., ATITAR, M., FERNÁNDEZ-RENAU, A., GÒMEZ, J., de MIGUEL, E., Gutiérrez de la CÁMARA, O., JIMÉNEZ, M., PRADO, E. Rodríguez-Cantano, R., RUIZ, I., NERRY, F., NAJJAR,



- G., KASTENDEUTCH, P., PUJADAS, M., MOLERO, F., MORENO, J., ALONSO, L., FERNÁNDEZ, F., GALÁN, E., CAÑADA, R., ROMERO, J., CALPE-MARAVILLA, J., CAMPS-VALLS, G., BOSCH-MAGRANER, M., PUENTE-ROBLES, R., CORDERO-SALVADOR, J., TORRES-CARRERO, J., DUQUE-CUESTA, M., MOYA, F., LABAJO, A., LABAJO, S., HIDALGO-RODRÍGUEZ, J., ACERO, J., HERNÁNDEZ-MARTÍN, E., MARTILLI, A., SALAMANCA, F., GIMENO-PRESA, L. et PIGEON, G. (2008). DESIREX 2008 Final Report - Dual-use European Security IR Experiment 2008 (DESIREX 2008). Rapport technique, ESA.
- SOTOCA, J. et FILIBERTO, P. (2010). Supervised feature selection by clustering using conditional mutual information-based distances. *Pattern Recognition*, 43(6):2068–2081.
- SOUCHON, J.-P., THOM, C., MEYNARD, C. et MARTIN, O. (2012). A large format camera system for national mapping purposes. *Revue Française de Photogrammétrie et de Télédétection*, 200:18–53.
- SOUCHON, J.-P., THOM, C., MEYNARD, C. et MARTIN, O. (2015). Camlight, une caméra métrologique pour drone. Présentation aux Journées de la Recherche de l'IGN.
- SU, H., YANG, H., DU, Q. et SHENG, Y. (2011). Semisupervised band clustering for dimensionality reduction of hyperspectral imagery. *IEEE Geoscience and Remote Sensing Letters*, 8(6):1135–1139.
- SZABO, S., BURAI, P., KOVACS, Z., SZABO, G., KERENYI, A., FAZEKAS, I., PALADI, M., BUDAY, T. et SZABO, G. (2014). Testing of algorithms for the identification of asbestos roofing based on hyperspectral data. *Environmental Engineering and Management Journal*, 143(11):1–6.
- TAHERZADEH, E. et SHAFRI, H. Z. M. (2011). Using hyperspectral remote sensing data in urban mapping over Kuala Lumpur. *In Proc. of the Joint Urban Remote Sensing Event JURSE 2011*, pages 405–408.
- TAHERZADEH, E., SHAFRI, H. Z. M., SOLTANI, S. H. K., MANSOR, S. et ASHUROV, R. (2012). A comparison of hyperspectral data and Worldview-2 images to detect impervious surface. *In Proc. of the ASPRS 2012 Annual Conference*.
- TANG, J., ALELYANI, S. et LIU, H. (2014). *Data Classification : Algorithms and Applications*, chapitre Feature selection for classification : a review, pages 37–64. Chapman and Hall/CRC Data Mining and Knowledge Discovery Series. CRC Press.
- TARDIVO, B. (2012). *Guide d'accompagnement pour la mise en place de la taxe pour la gestion des eaux pluviales urbaines*. MEDDE.
- TAVIN, F. (2008). *Analyse et utilisation d'une bibliothèque hyperspectrale pour l'optimisation des paramètres d'acquisition d'images de télédétection : application à la pédologie*. Thèse de doctorat, Université de Bourgogne.
- TAX, D. et DUIN, R. (2004). Support vector data description. *Machine Learning*, 54:45–66.
- TEKE, M., BASESKI, E., OK, A., YUKSEL, B. et SENARAS, C. (2011). *Photogrammetric Image Analysis (Proc. of PIA '11)*, volume 6952 de LNCS, chapitre Multi-spectral false color shadow detection, pages 109–120. Springer.
- THENKABAIL, P., MARIOTTO, I., GUMMA, M., MIDDLETON, E., LANDIS, D. et HUENNRICH, K. (2013). Selection of hyperspectral narrowbands (HNBS) and composition of hyperspectral twoband vegetation indices (HVIs) for biophysical characterization and discrimination of crop types using field reflectance and Hyperion/EO-1 data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 6(2):427–439.

- 
- TIBSHIRANI, R. (1996). Regression shrinkage and selection via the lasso. *Journal of the Royal Statistical Society (Series B)*, 58:267–288.
- TOURNAIRE, O., PIGEON, G. et PAPANODITIS, N. (2010). Projet Ville Numérique : interfaçage entre BD IGN et modèles météo. Présentation interne IGN/MATIS.
- TOUZET, T. (2014). Couche occupation du sol à grande échelle de l'IGN (OCS GE) : spécifications. Rapport technique, IGN.
- TRIAS-SANZ, R. (2006). *Semi-automatic high-resolution rural land cover classification*. Thèse de doctorat, Université Paris 5, Paris, France.
- TRIAS-SANZ, R. et BOLDO, D. (2005). A high-reliability, high-resolution method for land cover classification into forest and non-forest. In KALVIAINEN, H., PARKKINEN, J. et KAARNA, A., éditeurs : *Proc. of the Scandinavian Conference on Image Analysis (SCIA)*, volume 3540 de *Lecture Notes in Computer Science*, pages 831–840, Joensuu, Finlande. Springer.
- TSAI, V. J. D. (2006). A comparative study on shadow compensation of color aerial images in invariant color models. *IEEE Transactions on Geoscience and Remote Sensing*, 44(6):1661–1671.
- TUIA, D., CAMPS-VALLS, G., MATASCI, G. et KANEVSKI, M. (2010). Learning relevant image features with multiple-kernel classification. *IEEE Transactions on Geoscience and Remote Sensing*, 48(10):3780–3791.
- TUIA, D., COURTY, N. et FLAMARY, R. (2014a). A group-lasso active set strategy for multiclass hyperspectral image classification. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, II-3:1–8.
- TUIA, D., VOLPI, M., DALLA MURA, M., RAKOTOMAMONJY, A. et FLAMARY, R. (2014b). Automatic feature learning for spatio-spectral image classification with sparse SVM. *IEEE Transactions on Geoscience and Remote Sensing*, 52(10):6062–6074.
- VAPNIK, V. (1998). *Statistical learning theory*. Wiley, Hoboken, États-Unis.
- VOOGT, J. et GRIMMOND, C. (2000). Modeling surface sensible heat flux using surface radiative temperatures in a simple urban area. *Journal of Applied Meteorology*, 39(10):1679–1699.
- WANG, Y. et WANG, S. (2008). Shadow detection of urban aerial images based on partial differential equations. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 37(2):325–328.
- WENG, Q. (2012). Remote sensing of impervious surfaces in the urban areas : requirements, methods and trends. *Remote Sensing of Environment*, 117(2):34–49.
- WIERSMA, D. et LANDGREBE, D. (1980). Analytical design of multispectral sensors. *IEEE Transactions on Geoscience and Remote Sensing*, GE-18(2):180–189.
- WU, T., LIN, C. et WENG, R. (2004). Probability estimates for multi-class classification by pairwise coupling. *The Journal of Machine Learning Research*, 184(5):975–1005.
- XU, P., DAVOINE, F. et DENOEU, T. (2014). Transformation de scores SVM en fonctions de croyance. In *Actes du 19eme congrès sur la Reconnaissance de Forme et l'Intelligence Artificielle (RFIA'2014)*.
- YANG, H., DU, Q. et CHEN, G. (2012). Particle swarm optimization-based hyperspectral dimensionality reduction for urban land cover classification. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(2):544–554.

- YANG, H., ZHANG, S., DENG, K. et DU, P. (2007). Research into a feature selection method for hyperspectral imagery using PSO and SVM. *Journal of China University of Mining and Technology*, 17(4):473–478.
- ZARE, A. et GADER, P. (2007). Hyperspectral band selection and endmember detection using sparsity promoting priors. *IEEE Geoscience and Remote Sensing Letters*, 5(2):256–260.
- ZHANG, L., ZHONG, Y., HUANG, B., GONG, J. et LI, P. (2007). Dimensionality reduction based on clonal selection for hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 45(12):4172–4186.
- ZHOU, S., ZHANG, J. et SU, B. (2009). Feature selection and classification based on ant colony algorithm for hyperspectral remote sensing images. *In Proc. of the 2nd International Congress on Image and Signal Processing (CISP'09)*, pages 1–4.
- ZHU, J. et HASTIE, T. (2005). Kernel logistic regression and the import vector machine. *Journal of Computational and Graphical Statistics*, 14:185–205.
- ZHU, J., ROSSET, S., HASTIE, T. et TIBSHIRANI, R. (2004). 1-norm support vector machines. *Advances in neural information processing systems*, 16(1):49–56.
- ZHUO, L., ZHENG, J., WANG, F., LI, X., BIN, A. et QIAN, J. (2008). A genetic algorithm based wrapper feature selection method for classification of hyperspectral images using support vector machine. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 37(B7):397–402.

