



HAL
open science

Développement des algorithmes pour l'automatisation de la classification des données utilisant les réseaux de neurones probabilistes (PNN). Application à l'analyse, la catégorisation et la cartographie des images de télédétection.

Jawad Iounousse

► **To cite this version:**

Jawad Iounousse. Développement des algorithmes pour l'automatisation de la classification des données utilisant les réseaux de neurones probabilistes (PNN). Application à l'analyse, la catégorisation et la cartographie des images de télédétection.. Théorie de l'information [cs.IT]. UNIVERSITÉ CADI AYYAD FACULTÉ DES SCIENCES & TECHNIQUES GUELIZ - MARRAKECH, 2015. Français. NNT : Numéro d'ordre 08/2015 . tel-01216873

HAL Id: tel-01216873

<https://theses.hal.science/tel-01216873>

Submitted on 17 Oct 2015

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.



UNIVERSITÉ CADI AYYAD
FACULTÉ DES SCIENCES & TECHNIQUES
GUELIZ - MARRAKECH

N° d'ordre :
08 / 2015

THÈSE

présentée à la Faculté des Sciences et Techniques de Marrakech

pour obtenir le grade de :

Docteur

UFR : Métrologie, Automatique et Analyse des Systèmes

Spécialité : Informatique et Traitement du signal

**Développement des algorithmes pour l'automatisation de la classification
des données utilisant les réseaux de neurones probabilistes (PNN).
Application à l'analyse, la catégorisation et la cartographie des images de
télédétection.**

par :

Jawad IOUNOUSSE

(DESA : Télécommunications et Réseaux)

soutenue le 12 Septembre 2015, devant la Commission d'Examen :

Président :	- KHABBA Said	PES à FSS Marrakech
Rapporteurs :	- TOUAHNI Raja	PES à FS Kénitra
	- HAMMOUCH Ahmed	PES à ENSET Rabat
	- RAGHAY Said	PES à FSTG Marrakech
Examineurs:	- BAKRIM M'hamed	PES à FSTG Marrakech
	- ER-RAKI Salah	PH à FSTG Marrakech
Encadrants:	- EL MOTASSADEQ Ahmed	PES à FSTG Marrakech
	- CHEHOUANI Hassan	PES à FSTG Marrakech

À mes chers Parents
À mes adorables Frères
À tous ceux qui me sont Chers

FICHE PRÉSENTATIVE DE LA THÈSE

- Nom et Prénom de l'auteur : **M. IOUNOUSSE Jawad.**
- Intitulé du travail :

Développement des algorithmes utilisant les réseaux de neurones probabilistes (PNN) pour l'automatisation de la classification des données. Application à l'analyse, la catégorisation et la cartographie des images de télédétection.

- Encadrant :
 - nom, prénom et grade : **EL MOTASSADEQ Ahmed, PES.**
 - laboratoire et institution : **LP2M2E, FSTG Marrakech.**

- Coencadrant :
 - nom, prénom et grade : **CHEHOUANI Hassan, PES.**
 - laboratoire et institution : **LP2M2E, FSTG Marrakech.**

- Lieux de réalisation des travaux (laboratoires, institution,...) :

Laboratoire de Procédés, Métrologie et Matériaux pour l'Énergie et Environnement (LP2M2E), département de physique à la Faculté des Sciences et Techniques de Marrakech.

- Période de réalisation du travail de thèse : **depuis Janvier 2008.**
- Rapporteurs autres que l'encadrant (nom, prénom, grade, institution) :
 - **TOUAHNI Raja**, PES à Faculté des Sciences de Kénitra.
 - **HAMMOUCH Ahmed**, PES à l'Ecole Normale Supérieure de l'Enseignement Technique de Rabat.
 - **RAGHAY Said**, PES à la Faculté des Sciences et Techniques de Marrakech.

- Cadres de coopération (ou de soutien) :

Bourse d'excellence de recherche du Centre National pour la Recherche Scientifique et Technique (CNRST).

- Ce travail a donné lieu aux résultats suivants (communications, publications,...) :

Publications :

1. **Iounousse, J.**, Er-Raki, S., El motassadeq, A., & Chehouani, H. (2015). Using an unsupervised approach of Probabilistic Neural Network (PNN) for land use classification from multitemporal satellite images. *Applied Soft Computing*, 30, 1–13. *Impact factor (2014) : 2.810*

2. **Iounousse, J.**, Farhi, A., El Motassadeq, A., Chehouani, H., & Er-Raki, S. (2012). Unsupervised classification of grayscale image using Probabilistic Neural Network (PNN). *Proceedings in International Conference on Multimedia Computing and Systems – ICMCS'12*, May 10-12, 2012, Tangier, Morocco. 101-105. (*indexée SCOPUS*)

Communications :

1. **Iounousse, J.**, Farhi, A., Er-Raki, S., El Motassadeq, A., & Chehouani, H. (2012). Approche de classification non supervisée par les réseaux de neurones probabilistes pour établir des cartes d'occupation du sol de la région de Tensift Al Haouz (Maroc). *Proceedings in African Association of Remote Sensing of the Environment (AARSE)*, Oct 29 – Nov 2, 2012, Eljadida, Morocco. 36-37. (*communication orale*)
2. **Iounousse, J.**, Farhi, A., El Motassadeq, A., Chehouani, H., & Er-Raki, S. (2012). Unsupervised classification of grayscale image using Probabilistic Neural Network (PNN). *Proceedings in International Conference on Multimedia Computing and Systems – ICMCS'12*, May 10-12, 2012, Tangier, Morocco. 101-105. (*communication orale*)
3. **Iounousse, J.**, Farhi, A., El Motassadeq, A., & Chehouani, H. (2011). Extraction de profils de végétation par automatisation de la technique de classification utilisant les réseaux de neurones probabilistes. *Proceeding de la Conférence Méditerranéenne sur l'Ingénierie Sûre des Systèmes Complexes MISC'11*, Mai 2011, Agadir, Maroc. 211-216. (*communication orale*)

REMERCIEMENTS

Je tiens à remercier sincèrement en premier lieu mes directeurs de thèse, Monsieur **Ahmed El Motassadeq** et Monsieur **Hassan Chehouani**, professeurs à la Faculté des Sciences et Techniques de Marrakech, tout d'abord pour m'avoir accepté au sein de l'équipe du **LP2M2E** (Laboratoire de Procédés, Métrologie et Matériaux pour l'Énergie et Environnement) et pour leurs patiences, leurs disponibilités, leurs suivis attentifs et leurs conseils avisés tout au long des travaux de cette thèse.

Je remercie les personnes qui m'ont fait l'honneur de participer au jury de thèse, pour l'intérêt qu'ils ont porté à mon travail: professeur **Said Khabba**, pour en avoir accepté la présidence; les rapporteurs: professeur **Raja Touahni**, professeur **Ahmed Hammouch** pour leurs remarques pertinentes et l'effort qu'ils ont fait pour se déplacer à Marrakech, et mon professeur **Said Raghay** pour ses recommandations et critiques ; les examinateurs: professeur **M'hamed Bakrim** pour les remarques enrichissantes qu'il m'a apportées. Je remercie aussi professeur **Salah Er-Raki** pour son soutien scientifique, technique et moral durant cette thèse et de m'honorer comme un examinateur qui a enrichi le débat par ses ses remarques pratiques.

J'adresse aussi mes remerciements à toutes les personnes qui, de près comme de loin, ont contribué à ce travail que ce soit par leur participation ou leur encouragement. Merci à **Ahmed Farhi, Mahfoud El fagrigh, Abdessadeq Ait Haj Said, Omar Abounachit, Fouad, Faiçal Aitlahbib, Mohamed Belaqziz, Noureddine Aouzale, Issam Salhi, Abdessalam Lokriti, Sanae Kabil, Mostapha Habiballah, Mourad Karaoui, Zakaria Rachid, Adil Chelhaoui, Amine Hatim** pour leur disponibilité et leur bonne humeur.

Enfin, j'exprime toute mon affection et ma gratitude à **ma famille** (mes parents, mes frères, ma fiancée...) pour leur patience et leur soutien indéfectible. Un énorme merci pour **mes amis** pour m'avoir soutenu et supporté pendant ces années de thèse.

Résumé de la thèse

Développement des algorithmes utilisant les réseaux de neurones probabilistes (PNN) pour l'automatisation de la classification des données.

Application à l'analyse, la catégorisation et la cartographie des images de télédétection.

Cette recherche rentre dans le cadre général du domaine des technologies de l'information et de la communication (TIC). Le thème principal de cette thèse est la modélisation et la classification pour l'analyse et le traitement de l'information contenue dans les données numériques. Notre contribution est la réalisation d'un ensemble d'algorithmes pour l'automatisation de la classification des données en utilisant les réseaux de neurones probabilistes (PNN). Les données considérées sont les images de télédétection. Cette thèse s'adresse non seulement aux numériciens et spécialistes du traitement des images, mais aussi aux chercheurs et praticiens dans plusieurs domaines tels que la télédétection qui utilisent la classification des données en général et l'analyse de l'information pour la modélisation en particulier. Nous proposons une nouvelle procédure de classification automatique fondée sur les PNN. Nous avons utilisé des méthodes non supervisées pour la recherche des classes à la phase de l'apprentissage. Nous avons construit une fonction pour la validité des classes en s'inspirant des techniques de classification automatique floue. Nous avons aussi adapté notre procédure pour l'application sur des données multidimensionnelles telles que les images satellitaires. Avant d'appliquer cette approche sur des images de télédétection, nous avons mené une série de tests sur plusieurs types de données synthétiques et réelles. Ces tests ont abouti à des résultats très convaincants en comparaison avec les méthodes non supervisées usuelles, ce qui a conduit à valider la performance de nos algorithmes.

Dans la partie application à la télédétection, l'objectif est d'élaborer des cartes d'occupation du sol à partir des images satellitaires. Nous avons analysé les images à haute résolution spatiale représentant la région étudiée pour identifier tous les profils de végétation existants. La classification est menée en se basant sur les images de l'indice de végétation NDVI extraites des images satellitaires SPOT. L'objet à classifier est une série temporelle de sept scènes NDVI. Le but est de tester l'ensemble des algorithmes développés sur des cas réels pour mettre en évidence leur performance. Ces tests ont démontré encore une fois de plus que les approches proposées sont tout à fait aptes à produire une classification performante.

Nous avons classifié et analysé les images satellitaires d'une région semi-aride de Marrakech Tensift El Haouz. Le résultat obtenu est une cartographie précise de l'occupation du sol. Ce résultat contribuera d'une façon importante dans le dressage des cartes du flux d'évapotranspiration pour établir un bilan hydrique de la région.

Mots clés: TIC, Informatique, Classification de données, non supervisé, PNN, traitement des images, télédétection.

Abstract

*Implementation of an automatic procedure for data classification based on probabilistic neural networks (PNN).
Application in analysis, categorization and mapping of remote sensing images.*

This research falls within the general context of the domain of information and communications technology (ICT). The main topic of this thesis is modeling and classification for analyzing and processing digital data. Our objective is the realization of a set of algorithms to automate data classification using probabilistic neural networks (PNN). The considered data are remote sensing images.

We propose a novel procedure for automatic classification based on PNN. We used unsupervised methods to search for classes in the learning phase; we built a function to validate classes inspired from fuzzy clustering techniques and we adapted our procedure to be applied on multidimensional data such as satellite images. Before applying this approach to remote sensing images, we conducted a series of tests on various types of synthetic and real data. These tests have produced very convincing results in comparison to usual unsupervised methods.

We applied our algorithm in order to build land cover maps from satellite images. So, we have to analyze high spatial resolution images representing the study area for identifying all existing vegetation patterns. The classification is applied on sequence of NDVI time series data derived from satellite images. The aim is to test all of the developed algorithms on real cases to highlight their performance. These tests have demonstrated once again that the proposed approaches are entirely capable to produce successful classification.

In semi-arid regions such as the region of Marrakech Tensift El Haouz, mapping land cover contributes extremely in evapotranspiration flow estimation used for water management.

Keywords: ICT, Computer science, Data classification, Unsupervised, PNN, Image processing, remote sensing.

ملخص الرسالة

تطوير برامج باستخدام الشبكات العصبية الاحتمالية من أجل تحليل، تصنيف ورسم خرائط عبر صور الاستشعار عن بعد.

تطبيق في تحليل، تصنيف ورسم خرائط صور الاستشعار عن بعد عبر الأقمار الصناعية.

الموضوع الرئيسي لهذه الأطروحة هو النمذجة والتصنيف لتحليل ومعالجة البيانات الرقمية. الهدف الرئيسي من هذه الرسالة هو تطوير مجموعة من البرامج لتصنيف تلقائي للبيانات باستخدام الشبكات العصبية الاحتمالية.

نقترح طريقة جديدة للتصنيف التلقائي للمعلومات تستخدم نموذج حساب يعتمد على الشبكات العصبية الاحتمالية (PNN). للقيام بذلك، استخدمنا أساليب بدون إشراف للبحث عن الفئات في مرحلة تهيئة الشبكات. قمنا بإنشاء دالة لتقييم صلاحية الفئات بالاعتماد على تقنيات التصنيف التلقائي المستعملة في المنطق الضبابي وكيفنا نظامنا من أجل استخدامه مع البيانات متعددة الأبعاد من قبيل صور الأقمار الصناعية.

قبل تطبيق هذا النهج على صور الاستشعار عن بعد، قمنا بإجراء سلسلة من الاختبارات على أنواع مختلفة من البيانات ولا سيما على صور اصطناعية و أخرى حقيقية ذات ألوان مختلفة التوزيع. هذه الاختبارات حققت نتائج جد مقنعة بالمقارنة مع الطرق الاعتيادية دون إشراف والتي أدت إلى التحقق من صحة أداء البرامج المقدمة.

في الجزء التطبيقي، يتمثل الهدف في وضع خرائط للغطاء النباتي من خلال صور الأقمار الصناعية. للقيام بذلك، كان يجب علينا أن نحلل صور الساتل ذات الدقة العالية التي تمثل منطقة الدراسة و ذلك للتعرف على كافة أنماط الغطاء النباتي الموجودة. و يتم التصنيف استنادا إلى صور مؤشر الغطاء النباتي NDVI المأخوذة من صور الاستشعار عن بعد عبر الأقمار الصناعية. والمرجو من ذلك هو اختبار كافة البرامج المقدمة في خضم هذه الأطروحة على حالات حقيقية لإبراز قدراتها و أدائها. وقد أثبتت هذه الاختبارات مرة أخرى أن النهج المقترح قادر تماما على القيام بتصنيف ناجح.

هذه الدراسة يمكن أن تُستخدم في عدة مجالات و أغراض. نُعطي مثلاً في هذه الاطروحة، فائدتها الكبيرة و المهمة في إدارة الموارد المائية وذلك بإنتاج خرائط الاحتياجات المائية من خلال الجمع بين نتائجها و البيانات المناخية وبالتالي تُمكن من قياس كمية المياه المفقودة. مما يزيد من أهمية القيام بتصنيف دقيق.

الكلمات المفتاحية: تكنولوجيا المعلومات والاتصالات، الإعلاميات، تصنيف البيانات، بدون إشراف، الشبكات العصبية الاحتمالية، معالجة الصور، الاستشعار عن بعد.

Table des matières

Introduction générale	1
Chapitre 1 : Synthèse bibliographique et état de l'art sur les méthodes de classification.....	5
1.1. Introduction	6
1.2. La classification supervisée	6
1.2.1. La classification par maximum de vraisemblance (Maximum Likelihood).....	7
1.2.2. La classification hypercube (Parallelepipèd).....	8
1.2.3. La classification utilisant les réseaux de neurones.....	10
1.2.4. La classification utilisant les machines à vecteurs de support (SVM).....	12
1.3. La classification non supervisée (automatique).....	16
1.3.1. La classification hiérarchique	17
❖ La classification ascendante hiérarchique	17
❖ Les indices de dissimilarité.....	18
❖ Les critères d'agrégation.....	19
1.3.2. La classification par partitionnement.....	22
❖ La méthode des centres mobiles.....	22
❖ La classification par K-means	22
❖ La classification par ISODATA	23
❖ La classification par c-moyennes floues (FCM : Fuzzy C-Means)	24
1.4. Bilan bibliographique.....	26
Chapitre 2 : La classification et l'analyse des images en télédétection.....	27
2.1. Introduction.....	28
2.2. Définition de la télédétection	28
2.3. L'application de l'imagerie en télédétection.....	29
2.3.1. L'intérêt de la télédétection dans l'agriculture	29
2.3.2. L'acquisition des images de télédétection	30
❖ La résolution spectrale.....	31
❖ La résolution spatiale.....	31
❖ La résolution temporelle.....	32

2.4. L'information dans les images de télédétection	33
2.4.1. Les descripteurs spectraux	33
❖ Les compositions colorées.....	33
❖ Les indices de végétation.....	34
❖ Les modèles colorimétriques	35
❖ L'histogramme.....	38
2.4.2. Les descripteurs texturaux	41
2.4.3. Les descripteurs géométriques.....	43
2.5. Conclusion	44
Chapitre 3 : Développement et validation d'une procédure pour automatiser la classification par	
PNN	45
3.1. Introduction.....	46
3.2. Les techniques utilisées.....	46
3.2.1. Le réseau de neurones probabiliste (PNN)	46
3.2.2. La classification ascendante hiérarchique (CAH)	49
3.2.3. La fonction ou l'indice de validité des clusters.....	50
❖ Quelques indices de validité.....	50
3.3. Description de la méthodologie proposée.....	53
3.3.1. Calcul des classes (vecteurs cibles)	55
❖ Segmentation utilisant l'histogramme.....	55
❖ Segmentation utilisant la CAH	56
3.3.2. L'indice de validité des classes V proposé pour PNN.....	57
3.4. Programmation et déploiement d'algorithmes.....	57
3.4.1. Petite vision sur MATLAB.....	57
3.4.2. Schéma général de la procédure d'automatisation.....	58
3.4.3. Les algorithmes développés et techniques adoptées	59
❖ L'élimination des redondances.....	59
❖ Le calcul des classes.....	59
❖ L'utilisation de la couche RBF et la classification PNN.....	59
3.4.4. Les fonctions MATLAB utilisées	60
3.5. Validation et comparaison	60

3.5.1. Application sur les données des iris de Fisher	60
3.5.2. Application sur des images en niveaux de gris	62
❖ Test sur une image synthétique	62
❖ Test sur une image réelle.....	64
3.5.3. Application sur des images RVB numériques	66
❖ Test sur une image RVB à couleurs limitées	67
❖ Test sur une image RVB réelle	68
3.6. Conclusion	69
Chapitre 4 : Application de la procédure proposée sur une série multitemporelle d'images	
satellitaires pour l'identification de la végétation	71
4.1. Introduction.....	72
4.2. Matériels	72
4.2.1. La zone d'étude.....	72
4.2.2. Les données satellitaires	74
4.3. Les premiers travaux de classification	75
4.3.1. La classification spatiale non supervisée des scènes NDVI.....	76
4.3.2. La classification temporelle supervisée des scènes NDVI spatialement classifiées	78
❖ Utilisation du modèle de critères sur les profils NDVI.....	78
❖ Utilisation du PNN avec apprentissage supervisé.....	79
4.4. Application de la procédure complètement automatique.....	81
4.4.1. La carte d'occupation du sol	81
4.4.2. La validation des résultats obtenus	85
4.4.3. Comparaison des résultats avec d'autres méthodes	87
4.5. Conclusion	91
4.6. L'estimation du flux d'évapotranspiration.....	92
Conclusion générale	94
Références bibliographiques.....	98

Liste des figures

Figure 1.1.	Exemple de contours d'équiprobabilité dans un histogramme bidimensionnel.....	7
Figure 1.2.	Exemple de parallélépipèdes rectangles par approche unidimensionnelle	9
Figure 1.3.	Exemple de parallélépipèdes rectangles par approche multidimensionnelle	9
Figure 1.4.	Mise en correspondance neurone biologique / neurone artificiel	10
Figure 1.5.	Structure d'un neurone artificiel	11
Figure 1.6.	Exemple de Perceptron multicouche	11
Figure 1.7.	Illustration de la marge maximale et des vecteurs supports qui leur sont associés.....	12
Figure 1.8.	Illustration du traitement des nuages de points correspondant à chaque classe qui ne sont pas linéairement séparables.....	13
Figure 1.9.	Construction des $N_C = 3$ hyperplans pour la classification par la méthode " <i>one-versus-all</i> " ..	14
Figure 1.10.	Assignation du score selon la position du point-image par rapport à l'hyperplan distinguant la classe C_1	14
Figure 1.11.	Classification par la méthode " <i>one-versus-all</i> "	15
Figure 1.12.	Construction des $N_C(N_C - 1) / 2 = 3$ hyperplans pour la classification par la méthode " <i>one-versus-one</i> "	15
Figure 1.13.	Critère du saut minimal.....	19
Figure 1.14.	Critère du diamètre.	19
Figure 1.15.	Critère de la moyenne des distances	20
Figure 1.16.	Critère du centroïde.....	20
Figure 1.17.	Critère de Ward.....	21
Figure 1.18.	Dendrogramme de la CAH et les coupes des partitions.....	21
Figure 1.19.	L'initialisation et la variation du centre de gravité des classes au cours des itérations de l'ISODATA.....	24
Figure 2.1.	Schématisation du processus de télédétection passive.....	31
Figure 2.2.	Spectres typiques de réflectances de la neige, de l'eau, du sable et de la végétation.	32
Figure 2.3.	(a) Exemple d'une image SPOT à 20m de résolution en fausses couleurs TM 432. (b) l'image NDVI correspondante.....	35
Figure 2.4.	Représentation du modèle RVB.....	36
Figure 2.5.	(a) Double cône inversé du modèle TSL. (b) représentation en simple cône du modèle colorimétrique TSV	38
Figure 2.6.	Exemple de diagramme bidimensionnel	39
Figure 2.7.	Exemple d'analyse d'un histogramme unidimensionnel	40
Figure 2.8.	Exemples d'images texturées, extraites de scènes SPOT5: (a) forêt, (b) ville, (c) mer et (d) champs.....	41

Figure 3.1.	Architecture de PNN.....	47
Figure 3.2.	Fonction gaussienne et son FWHM.....	48
Figure 3.3.	La procédure d'automatisation.....	55
Figure 3.4.	Répartition linéaire des niveaux de gris de l'image.....	55
Figure 3.5.	Déplacement des classes en utilisant un exemple d'histogramme.....	56
Figure 3.6.	Calcul de l'indice de validité pour chaque nombre de classe C choisi.....	58
Figure 3.7.	Classification par les C^* classes optimales.....	58
Figure 3.8.	Le graphique des nuages de points selon les mesures des espèces d'iris : Setosa en rouge, Versicolor en vert et Virginica en bleu.....	61
Figure 3.9.	Exemple d'image synthétique en niveaux de gris et son histogramme.....	63
Figure 3.10.	Image classifiée par : (a) PNN automatisé, (b) FCM automatisée.....	64
Figure 3.11.	Exemple d'image réelle de carrelage en niveaux de gris.....	65
Figure 3.12.	L'histogramme de l'exemple d'image réelle de carrelage en niveaux de gris.....	65
Figure 3.13.	Image de carrelage classifiée par : (a) PNN automatisé, (b) FCM automatisé.....	66
Figure 3.14.	Exemple d'image RVB de zelij à couleurs limitées et son histogramme 3D.....	67
Figure 3.15.	Image de zelij classifiée par : (a) PNN automatisé, (b) FCM automatisé.....	68
Figure 3.16.	Exemple d'image RVB réelle et son histogramme 3D.....	68
Figure 3.17.	Image RVB classifiée par : (a) PNN automatisé, (b) FCM automatisé.....	69
Figure 4.1.	La zone d'étude et les principaux secteurs irrigués, barrages et ressources en eaux gérés par l'ORMVAH, la plaine du Tensift est délimitée en noir.....	73
Figure 4.2.	Organisation de la zone irriguée de Sidi Rahal.....	74
Figure 4.3.	La série temporelle de 7 scènes NDVI d'images Landsat ETM+.....	75
Figure 4.4.	Les histogrammes des sept scènes.....	77
Figure 4.5.	Application du modèle par critères sur les scènes classifiées par: (a) FCM automatisé, (b) PNN automatisé.....	79
Figure 4.6.	Evolution temporelle de NDVI des six profils créés.....	80
Figure 4.7.	Classification par PNN supervisé sur les scènes classifiées par: (a) FCM automatisé, (b) PNN automatisé.....	80
Figure 4.8.	Les courbes temporelles des quinze profils NDVI obtenus par PNN non supervisé.....	82
Figure 4.9.	La carte d'occupation du sol obtenue par la classification et après la fusion des classes.....	84
Figure 4.10.	La carte d'occupation du sol réelle obtenue par échantillonnage sur terrain pour la saison 2002-2003.....	85
Figure 4.11.	Les courbes temporelles des cinq profils NDVI obtenus par FCM automatique.....	87
Figure 4.12.	Les courbes temporelles des sept profils NDVI obtenus par k-means automatique.....	88
Figure 4.13.	La carte d'occupation du sol obtenue par la classification automatique utilisant FCM.....	89
Figure 4.14.	La carte d'occupation du sol obtenue par la classification automatique utilisant k-means....	90

Liste des tableaux

Tableau 3.1. Variabilité de l'indice de validité selon le nombre de classes C pour les données des iris de Fisher	62
Tableau 3.2. Les espèces détectées correctement et la précision de la classification pour chaque méthode	62
Tableau 3.3. Variabilité de l'indice de validité selon le nombre de classes C pour l'image synthétique en niveaux de gris	63
Tableau 3.4. Variabilité de l'indice de validité selon le nombre de classes C pour l'image réelle de carrelage en niveaux de gris.....	65
Tableau 3.5. Variabilité de l'indice de validité selon le nombre de classes C pour l'image RVB à couleurs limitées	67
Tableau 3.6. Variabilité de l'indice de validité selon le nombre de classes C pour une image RVB réelle.....	69
Tableau 4.1. Variabilité de l'indice de validité selon le nombre de classes C pour chaque scène NDVI	76
Tableau 4.2. Effet de la classification spatiale sur le nombre de niveaux NDVI.....	76
Tableau 4.3. Critères utilisés pour une classification supervisée des profils NDVI.....	78
Tableau 4.4. Pourcentages d'erreur sur chaque classe et sur la totalité des classes après la classification temporelle par le modèle des critères sur NDVI	79
Tableau 4.5. Pourcentages d'erreur sur chaque classe et sur la totalité des classes après la classification temporelle par PNN supervisé.....	81
Tableau 4.6. Variabilité de l'indice de validité V selon le nombre de classes C utilisant PNN automatique	81
Tableau 4.7. La fusion des profils obtenus et leur interprétation	84
Tableau 4.8. Résultats par échantillonnage de l'occupation du sol en 2002-2003.....	86
Tableau 4.9. Comparaison des résultats de l'occupation du sol et calcul de la précision totale	86
Tableau 4.10. Variabilité de V_{MPC} selon le nombre de classes C utilisant FCM automatique	87
Tableau 4.11. Variabilité de V_{MPC} selon le nombre de classes C utilisant k-means automatique.....	88
Tableau 4.12. Comparaison des résultats des trois méthodes utilisées	90

Introduction générale

L'image joue un rôle très important dans la vie quotidienne de l'être humain depuis son apparition. Grâce à l'informatique et au grand développement technologique des médias, l'image est devenue totalement omniprésente dans tous les domaines (internet, médias, science,...etc.). Dans le secteur scientifique par exemple, l'image touche plusieurs disciplines d'application et de recherche telles que la biologie, la médecine, la physique, la géographie, l'urbanisme, la géomatique, le paysage,...etc. L'exploitation de l'information contenue dans les images nécessite une reconnaissance et une analyse thématique. Cela est effectué par la classification des contenus qui caractérisent ces images. Dans ce travail, nous nous intéressons à la classification dans l'imagerie de la télédétection.

La multiplication des satellites de télédétection et l'utilisation de plusieurs capteurs pour l'observation de la terre ont permis l'acquisition d'une multitude d'images présentant des caractéristiques spatiales, spectrales et temporelles différentes. L'extraction des informations utiles, liées à la nature physique des surfaces observées, fait appel à différentes techniques et approches de traitements d'images numériques. Parmi ces procédures figure l'exploration des données ou ce que l'on appelle la classification. C'est une étape qui permet d'exploiter le caractère redondant et complémentaire contenu dans les données satellitaires. Elle doit prendre en compte des sources d'information de plus en plus nombreuses et variées pour partitionner l'image en régions connexes et homogènes au sens d'un critère d'homogénéité. En effet, il faut choisir une technique de classification qui donne des résultats convaincants dans un panorama d'algorithmes de discrimination qui diffèrent selon leur apprentissage (méthodes descriptives ou prédictives) et selon le type des attributs tirés des données de l'image.

Dans un ensemble de techniques de classification, l'utilisation des réseaux de neurones présente une nouvelle stratégie de classification fondée sur des motifs d'apprentissage et un principe de compétition et de coopération. En effet, les réseaux de neurones ont une capacité à découvrir automatiquement des catégories dans un ensemble de données faisant d'eux des techniques très efficaces pour la classification. L'un des réseaux les plus utilisés pour la classification est le réseau de neurones probabiliste connu sous le sigle PNN (de l'anglais *Probabilistic Neural Networks*) (Specht, 1988). PNN dérive des réseaux de neurones RBF (de l'anglais *Radial Basis Function*) dont l'avantage réside dans leur simplicité et leur rapidité. Comme son nom l'indique, PNN génère des probabilités d'appartenance d'un élément donné à l'ensemble des motifs ciblés (classes) (Specht, 1990). Le grand inconvénient de ce réseau vient du fait que son apprentissage est supervisé. Incorporer une classification automatique

dans la phase d'apprentissage constitue l'idée principale que nous développons tout le long de ce travail pour s'assurer de sa performance. Cependant, le défi majeur dans la classification automatique dite non supervisée est de déterminer le nombre optimal de classes qui convient à un ensemble de données. Dans la plupart des méthodes de classification, des évaluations expérimentales des données 2D-3D sont utilisées afin de vérifier visuellement la validité des résultats (c'est à dire la façon dont l'algorithme de classification découvre les classes dans un ensemble de données). Mais dans le cas des données volumineuses et multidimensionnelles (plus de trois dimensions) comme les images de télédétection, la visualisation de l'ensemble de ces données est difficile voire impossible. En outre, la perception des classes à l'aide des outils de visualisation disponibles est une tâche difficile pour les humains qui ne sont pas habitués à des espaces de grande dimension et des ensembles complexes de données. Pour surmonter ce problème, de nombreuses techniques basées sur l'analyse de cluster ont été développées visant à associer ces données à des classes. Ces techniques sont en fait des fonctions qui indiquent le degré de séparabilité et de compacité des groupes issus de la classification. Autrement dit, elles présentent un indice sur la qualité de cette classification.

Notre contribution dans ce travail de recherche est de proposer une méthodologie de classification par le PNN qui est complètement automatique sans connaître préalablement la répartition des données à traiter. Pour atteindre cet objectif, nous combinons plusieurs techniques qui sont :

- L'apprentissage du réseau de neurones en utilisant des techniques non supervisées mais hiérarchiques.
- La validation des classes par un indice de validité inspiré des techniques de la classification floue (Wang & Zhang, 2007).
- L'adaptation de la technique pour des images multicouches (données multidimensionnelles).

Cette procédure de classification va servir pour élaborer des cartes d'occupation du sol à partir des images satellitaires. Pour ce faire, il faut analyser les images à haute résolution spatiale représentant la région étudiée afin d'extraire les profils de végétation qui s'y trouvent.

Ce manuscrit est articulé selon quatre chapitres. Nous présentons dans le chapitre 1 une description des techniques de classification les plus utilisées dans le domaine de l'imagerie en général et en télédétection en particulier.

Le chapitre 2 est un inventaire d'outils permettant de se familiariser avec l'imagerie en télédétection, ses caractéristiques et ses attributs, son intérêt et l'exploitation de l'information qu'elle contient.

Les algorithmes proposés et les techniques adoptées pour réaliser notre méthodologie font l'objet du chapitre 3. Nous présentons aussi dans ce chapitre des séries de tests sur différents types de données et d'images dans le but de valider l'efficacité et la performance de notre approche de classification automatique des données.

Le chapitre 4 présente une application de notre méthodologie automatique sur une série multitemporelle d'images satellitaires pour l'identification de la végétation dans une région semi-aride. Sa dernière partie illustre une application de la classification des images de télédétection pour l'estimation du flux de l'évapotranspiration. Ce flux constitue une jauge sur l'utilisation des eaux dans la région et permet aux spécialistes d'établir des plans de décision et d'actions à mener concernant la gestion des ressources en eau.

Chapitre 1 :

**Synthèse bibliographique
et état de l'art sur les
méthodes de classification**

1.1 Introduction

La classification a un rôle à jouer dans toutes les sciences et techniques qui font appel à la statistique multidimensionnelle. Citons tout d'abord les sciences biologiques : botanique, zoologie, écologie, ... Ces sciences utilisent également le terme de "taxinomie" pour désigner l'art de la classification. De même, les sciences de la terre et de l'environnement : géologie, pédologie, géographie, étude des pollutions, font grand usage des classifications. Elle est fort utile également dans les sciences humaines et dans les techniques dérivées comme les enquêtes d'opinion, le marketing, etc... Ces dernières emploient parfois les mots de "typologie" et "segmentation" pour désigner la classification. On s'intéresse à la classification des images en général et les images multicouches en particulier telles que les images utilisées dans le domaine de télédétection.

La classification est un problème souvent étudié en imagerie de télédétection. La classification d'image est une étape très courante dans tout processus d'analyse d'image. C'est un traitement de bas niveau qui précède l'étape de mesure, de compréhension et de décision. Son objectif consiste à partitionner l'image en régions connexes et homogènes au sens d'un critère d'homogénéité. Pour pouvoir utiliser les images satellitaires pour la cartographie ou pour des analyses complémentaires, il est souvent important de traduire l'information de fréquence contenue dans les images en information thématique portant sur l'occupation du sol, notamment la couverture végétale.

On peut distinguer selon le type d'apprentissage entre deux types : la classification supervisée et la classification non supervisée. Dans ce chapitre, nous allons présenter un panorama des techniques de classification (supervisées et non supervisées) les plus utilisées dans l'imagerie de télédétection, la cartographie et la géomatique. Enfin, nous allons donner un bilan bibliographique et présenter les éléments et les raisons qui nous ont poussés à proposer notre procédure.

1.2 La classification supervisée

On l'appelle aussi la classification prédictive ou par l'archétype : le scoring. Les classes ou les variables cibles sont définies à partir des besoins de l'utilisateur et correspondent à des unités sémantiques de l'image, ce qui nécessite une étape d'apprentissage préalable à la classification. La classification supervisée consiste à déterminer les classes par un apprentissage qui peut être effectué soit sur chaque scène traitée, soit pour chaque type d'application (agriculture, forêt, littoral, géologie, ...) ou encore à chaque type de capteur utilisé (optique : Landsat, Spot, Ikonos, Noaa, ou radar : ERS, JERS1, Radarsat...). Cette

étape influence fortement les résultats de la classification. Les techniques de la classification supervisée produisent des modèles de prédiction. Dans le domaine de la télédétection, les techniques les plus utilisées sont :

1.2.1. La classification par maximum de vraisemblance (Maximum Likelihood)

Sans doute la plus utilisée, l'estimation par maximum de vraisemblance a été proposée en 1912 par Fisher qu'il l'appellait à l'époque le critère absolu (Fisher, 1912). C'est une classification statistique supervisée (Mather, 2004) basée sur des méthodes probabilistes: pour chaque pixel on détermine sa probabilité d'appartenir à une classe plutôt qu'à une autre. On

s'appuie sur la règle de Bayes :
$$P(C_i / p) = \frac{P(p / C_i).P(C_i)}{P(p)} \quad (1 - 1)$$

avec $P(C_i/p)$ = probabilité d'être dans la classe i sachant qu'on est le pixel p , $P(p/C_i)$ = probabilité d'être le pixel p sachant qu'on se trouve dans la classe i , $P(C_i)$ = probabilité d'appartenir à la classe i et $P(p)$ = probabilité d'être le pixel p .

La totalité de l'image est ensuite classée sur la base de ces statistiques. On affecte donc le pixel p à la classe i si : $P(p / C_i).P(C_i) > P(p / C_j).P(C_j)$ pour toute classe j .

Un seuil de probabilité en dessous duquel un pixel est jugé comme mal classé peut être fixé, le pixel est alors placé dans une classe de rejet. La plupart du temps, l'appartenance générale à une classe est estimée comme équiprobable (figure 1.1).

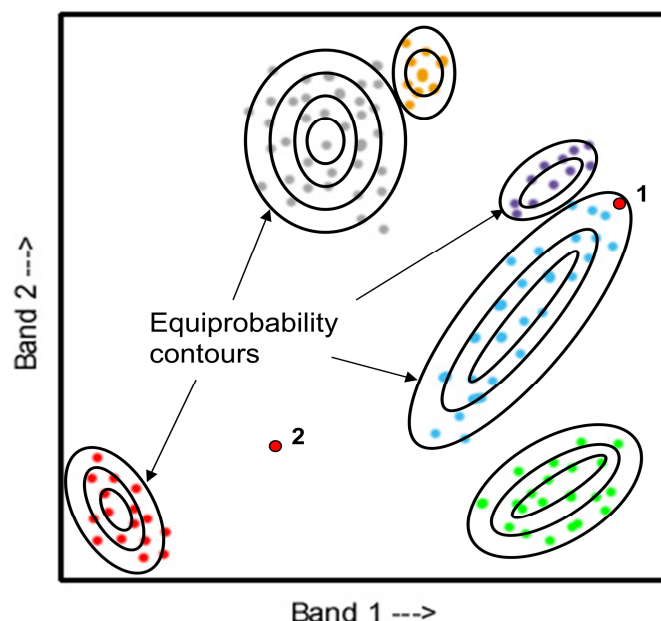


Figure 1.1 : Exemple de contours d'équiprobabilité dans un histogramme bidimensionnel.

Pour réaliser la classification, on commence par choisir des échantillons, dont on vérifie la qualité en s'appuyant sur l'analyse statistique des valeurs caractéristiques des histogrammes monodimensionnel (voir le chapitre 2), puis on applique la méthode de classification et on étudie ensuite la qualité du résultat en observant le comportement spectral des échantillons, le taux de rejet et la table de performance (= tableau révélant le nombre de pixels bien classés, mal classés et rejetés selon différents seuils de rejet).

L'interprétation de la classification obtenue se fera plutôt en termes de structure spatiale comme pour la méthode et sera plus ou moins difficile selon le choix des couleurs.

Cette technique de classification est tout à fait satisfaisante d'un point de vue mathématique car les pixels sont classés en fonction d'une probabilité ce qui est souhaitable en traitement de l'image, en particulier en télédétection où un même objet peut contenir des pixels aux valeurs radiométriques très différentes. Elle présente aussi l'avantage de donner facilement une mesure de la qualité de la classification, et de permettre l'amélioration de la classification par itération. Par contre, la qualité de la classification est fortement liée à la valeur du spécialiste : son expérience et sa connaissance du sujet de l'image.

1.2.2. La classification hypercube (Parallépipèd)

Cette classification s'appuie uniquement sur le modèle radiométrique (pas de calculs de distance ou de probabilités), il s'agit en quelque sorte d'un seuillage multidimensionnel. On part des échantillons définis, par un utilisateur expert, grâce à des mesures sur le terrain ou à une localisation géographique d'objets connus (Perumal & Bhaskaran, 2010). L'ordinateur calcule pour chaque classe les intervalles radiométriques concernés sur chaque canal : ceux-ci servent de référence et permettent la création de « cubes » (= en réalité, ce sont plus des parallépipèdes rectangles) dans l'hyperplan radiométrique en effectuant l'intersection des intervalles repérés sur les histogrammes de chacun des canaux. Si les cubes ne se chevauchent pas dans l'espace radiométrique, la segmentation est correcte. Deux types d'approche sont possibles : l'approche unidimensionnelle ou multidimensionnelle.

Avec la première approche, les découpages sont effectués sur chaque canal individuellement, et ensuite croisés pour obtenir des parallépipèdes rectangles (figure 1.2).

Malheureusement, on obtient beaucoup de classes vides ou quasi vides ainsi que de classes centrales importantes représentant plusieurs objets difficilement dissociables par le biais d'un seul canal.




Figure 1.2 : Exemple de parallélépipèdes rectangles par approche unidimensionnelle.

Avec l'approche multidimensionnelle, les parallélépipèdes rectangles sont créés directement sur l'histogramme (Figure 1.3).

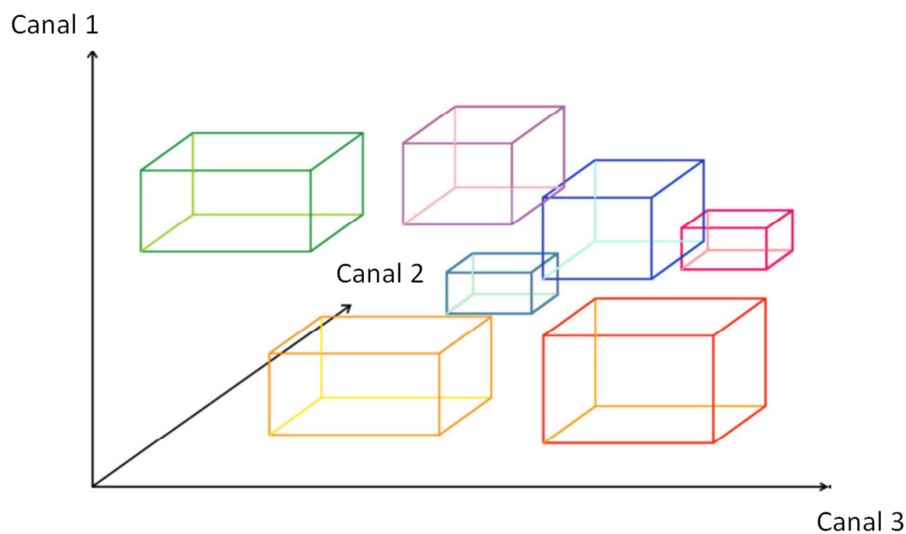


Figure 1.3 : Exemple de parallélépipèdes rectangles par approche multidimensionnelle.

L'interprétation de l'image est ensuite plus facile, si on a choisi des couleurs significatives pour représenter les différentes classes d'objets, et concerne surtout la structure spatiale des éléments dans l'image. Cette méthode est totalement assistée, car l'analyste détermine tout pas à pas. La qualité de la classification repose donc entièrement sur la qualité du spécialiste et l'exactitude des modèles radiométriques choisis. Il est préférable de choisir une approche multicanale, mais cela dépend des limites imposées par la puissance de

l'ordinateur. Avec cette méthode, tous les pixels n'appartenant à aucune classe prédéfinie sont regroupés dans une même classe souvent représentée en noir, pour montrer son absence de signification : il s'agit des pixels non classés.

1.2.3. La classification utilisant les réseaux de neurones

Au cours de ces dernières décennies est apparu un ensemble de disciplines fortement interdépendantes, portant sur le traitement de l'information, la théorie de la décision et les méthodes de reconnaissances des formes en l'occurrence les réseaux de neurones. Ces modèles constituent une méthode connexionniste intéressante pour l'analyse et la synthèse des systèmes demandant un traitement parallèle et un processus d'adaptation à un environnement changeant. Leurs champs d'applications est beaucoup élargi et étendu à plusieurs domaines, en particulier dans: la reconnaissance des formes, l'approximation des fonctions, le traitement d'image, la reconnaissance de la parole, la classification... Ainsi ils représentent des outils de calcul très puissants, mais avec quelques inconvénients à aviser comme: la mauvaise maîtrise de leur fonctionnement en particulier au niveau de l'initialisation où il n'existe pas de méthodologie pour le choix d'une topologie de réseau adéquate au problème donné.

Les réseaux de neurones, fortement inspirés du système nerveux biologique, sont composés d'éléments simples, appelés neurones, répartis sous forme de couches (Rojas, 1996). Ces éléments sont connectés entre eux par des liaisons affectées de poids (les synapses). La figure 1.4 présente l'analogie entre le neurone biologique et le modèle artificiel.

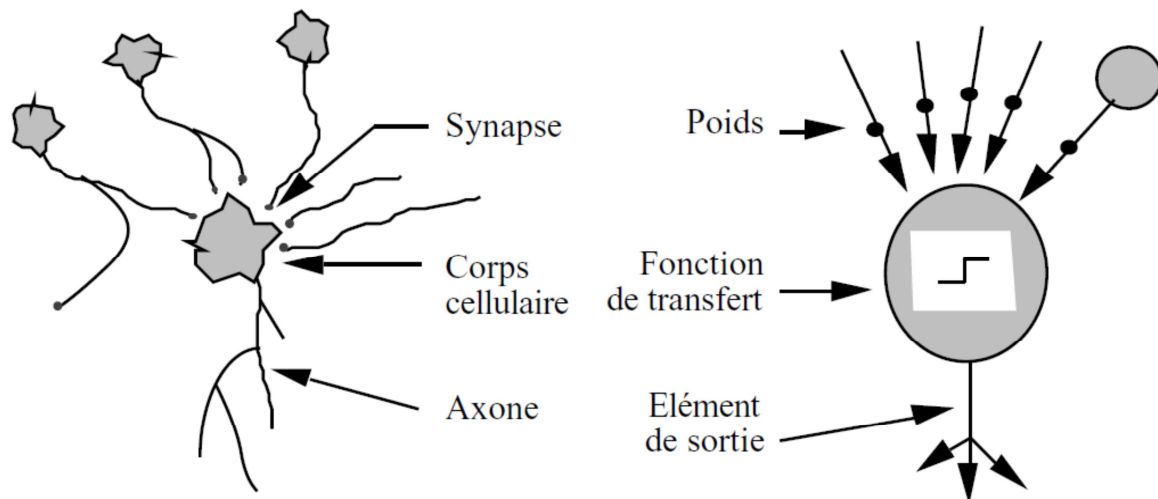


Figure 1.4 : Mise en correspondance neurone biologique / neurone artificiel.

L'apprentissage de ces poids est effectué de sorte qu'à chaque vecteur d'attributs sélectionné $Y^{i,j}$ présenté à l'entrée du réseau, corresponde en sortie la classe C_j à laquelle le prototype $w_{i,j}$ correspondant appartient. La figure 1.5 illustre la structure d'un neurone artificiel. Chaque neurone reçoit des valeurs provenant des neurones en amont via ses

connexions synaptiques et traite ces valeurs via une fonction de combinaison. Le résultat de la combinaison est alors transformé par la fonction d'activation pour produire sa sortie. Cette fonction permet de seuiller le résultat pour obtenir une sortie binaire.

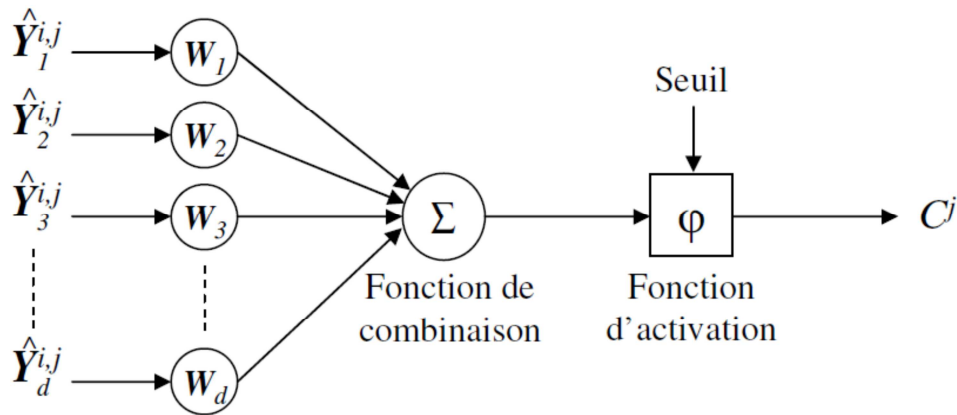


Figure 1.5 : Structure d'un neurone artificiel.

Le réseau de neurones le plus populaire est le perceptron multicouche (Multi-Layer Perceptron: MLP). Sa structure est simple. Dans ce réseau, chaque sous-groupe fait un traitement indépendant des autres et transmet le résultat de son analyse au sous-groupe suivant. L'information donnée au réseau va donc se propager couche par couche, de la couche d'entrée à la couche de sortie, en passant par une ou plusieurs couches intermédiaires (couches cachées) (figure 1.6). Pour ce type de réseau, la fonction de combinaison renvoie le produit scalaire entre le vecteur des entrées et le vecteur des poids $W = [W_1, \dots, W_d]^T$.




Figure 1.6 : Exemple de Perceptron multicouche.

Il existe de nombreux autres types de réseaux de neurones disponibles à ce jour qu'on utilise pour la classification, comme par exemple les réseaux à fonction radiale (Radial Basic Functions Neural Networks : RBFNN), qui ont pour architecture celle des MLP et pour

fonction d'activation une gaussienne (Broomhead & Lowe, 1988; Moody & Darken, 1989; Poggio & Girosi, 1990), ou encore les réseaux de Hopfield qui permettent un feed-back (retour en arrière) dans le but de corriger l'apprentissage initial (Rojas, 1996).

Dans les parties suivantes (chapitre 3 et 4), nous allons présenter et utiliser le réseau de neurones probabiliste (Probabilistic Neural Network : PNN) (Specht, 1988) qui fait partie des RBF. Très utilisé pour des problèmes de classification, ce réseau constitue la structure de base dans notre approche de classification totalement automatique.

1.2.4. La classification par les machines à vecteurs supports (SVM)

La classification par (SVM : Support Vector Machines) est une autre méthode non paramétrique récente. Elle consiste à résoudre un problème de classification binaire en plaçant un hyperplan dans l'espace des données comme frontière de décision de manière à ce que :

- Cet hyperplan maximise le taux de bonne classification des échantillons d'apprentissage,
- La distance entre le plan et le pixel le plus proche est maximisée.

La méthode "Machines à vecteurs supports" (SVM), proposée par Vapnik (Vapnik, 1995; Vapnik, 1998), a initialement été définie pour un problème de discrimination à deux classes. De manière simple, il s'agit de construire, dans l'espace des attributs, un hyperplan séparant les points-images représentatifs des prototypes de chacune des deux classes. Cette technique, également appelée méthode des séparateurs à vastes marges, repose sur deux idées clés : la notion de marge maximale et la notion de noyau (Rajpoot & Rajpoot, 2004). La marge est la distance entre la frontière de séparation (l'hyperplan) et les prototypes les plus proches de cette frontière. Ces prototypes sont appelés vecteurs supports. Dans les SVM, la frontière de séparation est choisie comme étant celle qui maximise la marge (figure 1.7) (Rajpoot & Rajpoot, 2004).

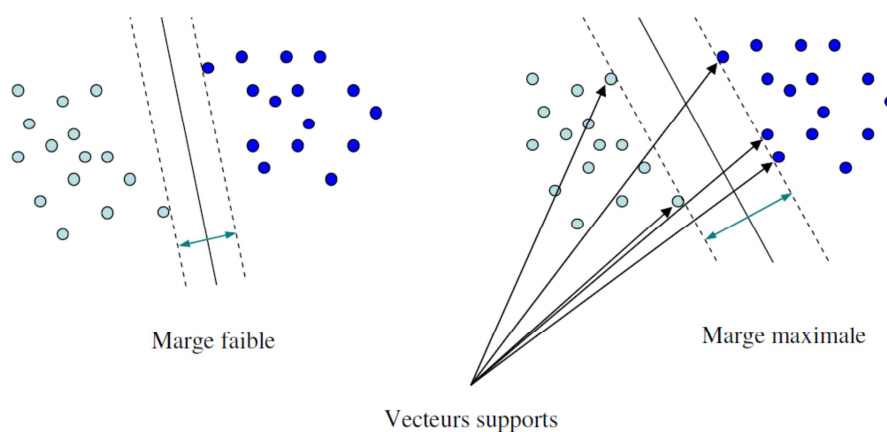


Figure 1.7 : Illustration de la marge maximale et des vecteurs supports qui leur sont associés.

Afin de pouvoir traiter les cas où les nuages de points correspondant à chaque classe ne sont pas linéairement séparables, la deuxième idée clé des SVM est de transformer l'espace des attributs en un espace de dimension plus grande (éventuellement de dimension infinie), dans lequel il est probable qu'une frontière séparatrice linéaire existe (Rajpoot & Rajpoot, 2004). Cette transformation non linéaire est réalisée via une fonction dite noyau. La figure 1.8 montre l'exemple de la répartition des points-image représentatifs de deux classes, dans l'espace d'attributs initial et dans l'espace d'attributs de plus grande dimension. On remarque que lorsque la dimension de l'espace est faible, il est impossible de déterminer l'hyperplan de séparation qui discrimine les deux classes en présence. Par contre, lorsque les points-prototypes sont représentés dans un espace de dimension supérieure, la construction de la frontière séparatrice linéaire est alors possible.

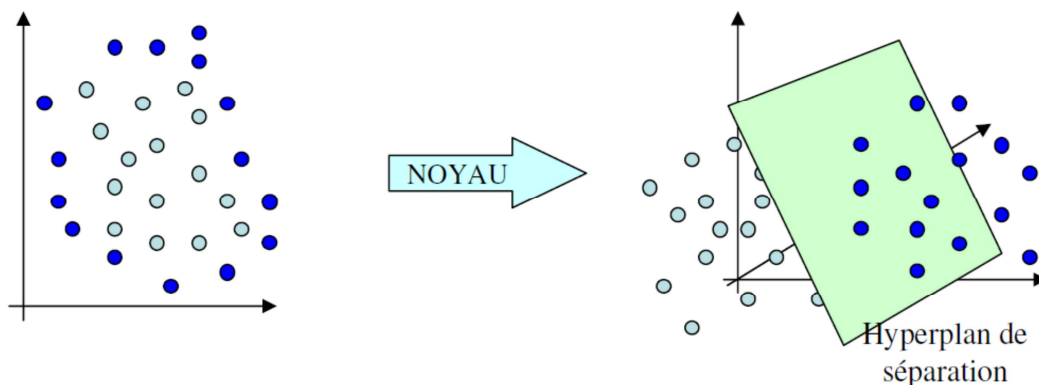


Figure 1.8 : Illustration du traitement des nuages de points correspondant à chaque classe qui ne sont pas linéairement séparables.

Une fois cette frontière déterminée, la classification d'une image se fait en comparant la position du point représentatif de cette image avec la position de l'hyperplan, dans l'espace des attributs (Rajpoot & Rajpoot, 2004). La méthode des SVM a ensuite été étendue à la classification d'images avec un nombre de classes supérieur à 2 (multi-classes) (Weston & Watkins, 1999) en s'appuyant sur deux méthodes :

- La méthode "*one-versus-all*" consiste à construire N_C classifieurs binaires, chacun d'entre eux permettant de distinguer l'une des N_C classes. La figure 1.9 illustre cette méthode: dans cet exemple, les points-prototypes représentatifs de $N_C = 3$ classes sont projetés dans un espace d'attributs de dimension $d = 2$. $N_C = 3$ "hyperplans" sont tout d'abord déterminés, chacun d'entre eux permettant la distinction d'une des classes. N_C scores positifs ou négatifs sont alors assignés au point-image test selon sa position par rapport aux N_C hyperplans. Si le point-image test se situe du côté des prototypes caractérisant la classe C_j , le score qui lui sera

assigné sera positif, tandis que s'il se situe de l'autre côté de l'hyperplan distinguant la classe C_j , le score assigné sera négatif. La figure 1.10 illustre ce propos pour la classe 1.




Figure 1.9 : Construction des $N_c=3$ hyperplans pour la classification par la méthode "one-versus-all". (a) pour la classe C_1 , (b) pour la classe C_2 et (c) pour la classe C_3 .




Figure 1.10 : Assignment du score selon la position du point-image par rapport à l'hyperplan distinguant la classe C_1 .

En phase de test, la classe d'assignation est donnée par le classifieur renvoyant le plus grand score. La figure 1.11 illustre cette classification : la position du point-image test (étiqueté avec un carré rouge) est comparée, dans l'espace d'attributs, à la position des N_c hyperplans. Un score négatif est assigné à cette image par les classifieurs caractérisant les classes 1 et 2, contrairement au score relatif à la classe 3 qui est positif. Cette image est donc

assignée à la troisième classe.

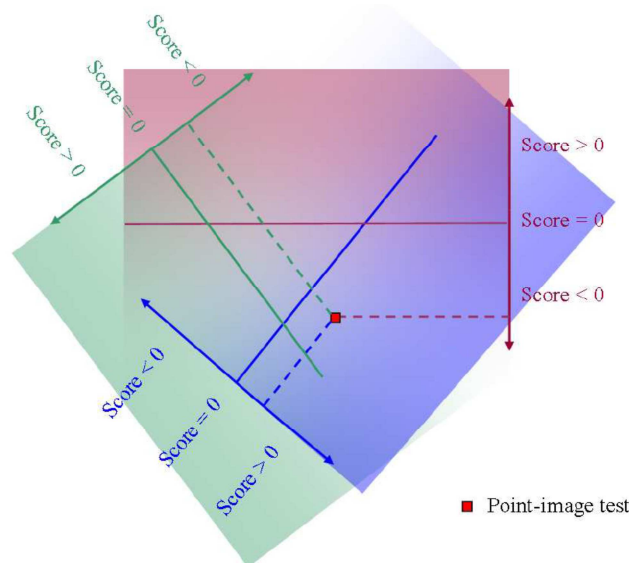


Figure 1.11 : Classification par la méthode "one-versus-all".

– La deuxième méthode « *one-versus-one* » consiste à construire $N_C (N_C - 1) / 2$ classifieurs binaires afin de confronter les N_C classes deux à deux. La figure 1.12 reprend l'exemple précédent et illustre cette fois-ci la construction des $N_C (N_C - 1) / 2 = 3$ hyperplans destinés à la classification par la méthode « *one-versus-one* ».

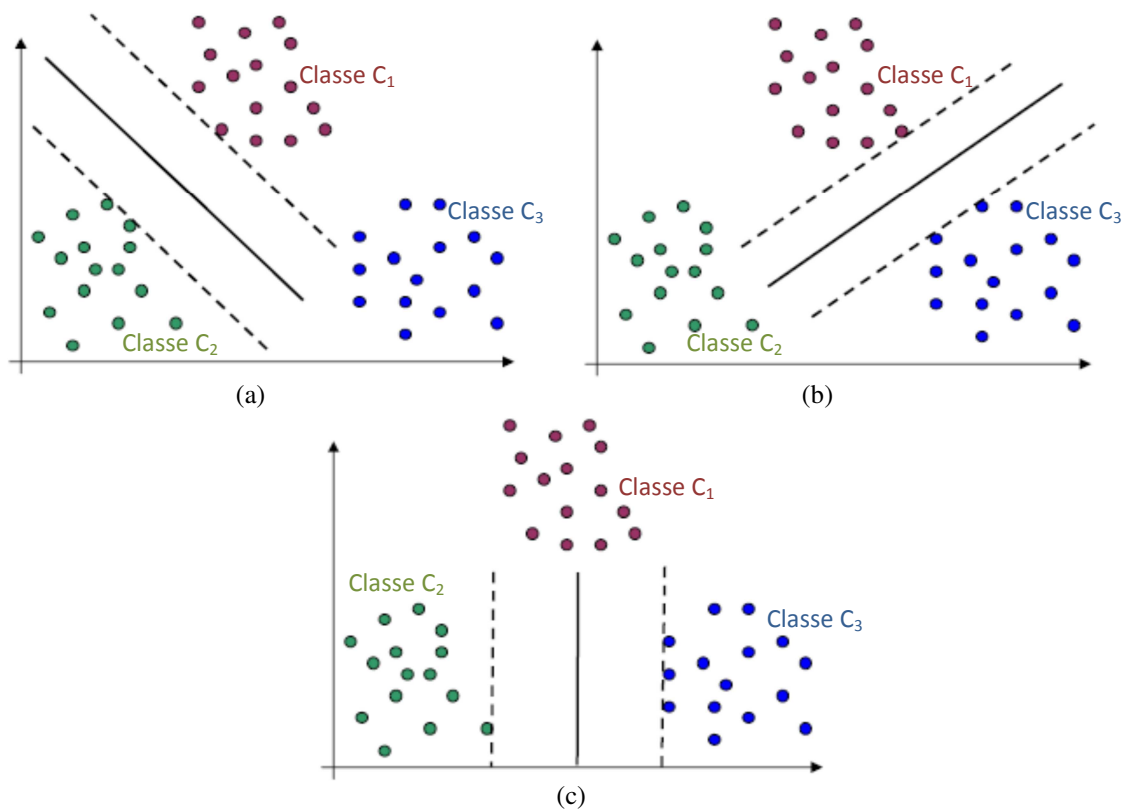


Figure 1.12 : Construction des $N_C (N_C - 1) / 2 = 3$ hyperplans pour la classification par la méthode "one-versus-one". (a) classes C_1 et C_2 , (b) classes C_1 et C_3 , et (c) classes C_2 et C_3 .

En phase de test, le point-image à classer est analysé par chaque classifieur et un vote majoritaire permet de déterminer la classe correspondante. En cas d'égalité, la classe de l'image test est déterminée de manière aléatoire (Xu et al., 2008).

La méthode des SVM est utilisée pour la classification de données biologiques / physiques (Rumpf et al., 2010; Kavzoglu & Colkesen, 2009), de documents numériques, de textures, d'expressions faciales dans le E-learning (Chen et al., 2012), la détection d'intrusion, la reconnaissance de la parole et la recherche d'images par le contenu (CBIR : Content Based Image Retrieval). Elle est aussi utilisée en télédétection dans sa forme multi-classe (Foody & Mathur, 2004; Massa et al., 2005).

1.3 La classification non supervisée (automatique)

On l'appelle aussi la classification descriptive ou par l'archétype : le clustering. La classification non supervisée ou non dirigée détermine automatiquement les classes. La classification automatique a été utilisée depuis longue date dans des contextes variés par des chercheurs de différentes disciplines, en tant que processus d'analyse exploratoire de données. Elle fut l'objet d'innombrables travaux théoriques et applicatifs et est encore le foyer de journaux spécialisés et de communautés spécialistes actives à travers le monde. Les études actuelles démontrent encore le vif intérêt de la classification automatique, tant dans les façons possibles de l'appliquer que pour l'améliorer. Les méthodes de classification non supervisée d'un ensemble d'individus peuvent être divisées en deux grandes familles : les approches hiérarchiques et les approches par partitionnement (Berkhin, 2002; Jain et al., 1999).

Les approches hiérarchiques, qui produisent une séquence de partitions emboîtées d'hétérogénéités croissantes de la plus fine à la plus grossière, conduisent à des résultats sous forme d'arbre hiérarchique indicé connu aussi sous le nom de dendrogramme, qui visualise ce système de classes organisées par inclusion.

Contrairement aux approches hiérarchiques, les approches par partitionnement cherchent la meilleure partition en k classes disjointes des données, le nombre de classes (clusters ou groupes) k étant fixé a priori. Les approches par partitionnement utilisent un processus itératif en fonction du nombre k qui consiste à affecter chaque individu à la classe la plus proche au sens d'une distance ou d'un indice de similarité en optimisant une certaine fonction objective. Les fonctions discriminantes dépendent, soit des paramètres des densités de probabilité, soit d'un jeu de coefficients qui peuvent être évalués théoriquement par des études physiques, la classification est alors totalement non supervisée. Elle peut être semi-supervisée quand certains paramètres sont fixés par l'utilisateur en fonction du type d'image

et de scène, ou que certains objets sont reconnus par l'utilisateur qui peut ainsi initialiser le processus de recherche des classes pour certaines d'entre elles.

1.3.1. La classification hiérarchique

La construction d'une classification hiérarchique peut se faire de deux façons. La première se fait à partir d'une matrice symétrique des similarités entre les individus, un algorithme agglomératif forme initialement de petites classes ne comprenant que des individus très semblables, puis, à partir de celles-ci, il construit des classes de moins en moins homogènes, jusqu'à obtenir la classe entière. Ce mode de construction est appelé la Classification Ascendante Hiérarchique (CAH). Le second mode de construction inverse le processus précédent. Il repose sur un algorithme divisif muni d'un critère de division d'un sous-ensemble de variables, et qui procède par dichotomies successives de l'ensemble des individus tout entier, jusqu'à un niveau qui vérifie certaines règles d'arrêt et dont les éléments constituent une partition de l'ensemble des individus à classer. Ce mode de construction s'appelle la Classification Descendante Hiérarchique (CDH). Un autre mode de construction des classes a été proposé par (Diday, 1986), comme une généralisation des modèles hiérarchiques, est appelé la classification pyramidale. Comme les hiérarchies, les représentations pyramidales sont des ensembles de parties appelées aussi classes ou paliers de l'ensemble des individus à classer. Cependant, la représentation pyramidale constitue une structure plus complexe des données. En effet, contrairement au cas hiérarchique classique, deux classes de la pyramide peuvent avoir une intersection non vide et ainsi certains individus à classer, peuvent appartenir à deux classes qui ne sont pas emboîtées l'une dans l'autre (classes empiétantes). La hiérarchie obtenue dans ce cas est dite hiérarchie de recouvrement (ou pyramide). Dans le cadre de cette thèse, nous nous intéressons seulement aux cas où les individus appartiennent à une seule classe (partition). Ainsi, nous détaillons dans la suite de ce paragraphe les approches hiérarchiques classiques conduisant à une hiérarchie de partitions et en particulier la CAH qui est la plus courante.

❖ La classification ascendante hiérarchique

Le but du modèle de CAH est d'obtenir une classification automatique de l'ensemble d'individus. Elle commence par déterminer parmi les n individus, quels sont les 2 individus qui se ressemblent le plus par rapport à l'ensemble des p variables spécifiés. Elle va alors regrouper ces 2 individus pour former une classe. Il existe donc à ce niveau $(n - 1)$ classes, une étant formées des individus regroupés précédemment, les autres ne contenant qu'un unique individu. Le processus se poursuit en déterminant quelles sont les 2 classes qui se

ressemblent le plus, et en les regroupant. Cette opération est répétée jusqu'à l'obtention d'une unique classe regroupant l'ensemble des individus.

Cette procédure est basée sur deux choix :

- La détermination d'un critère de ressemblance entre les individus. La méthode laisse à l'utilisateur le choix de la dissimilarité.
- La détermination d'une dissimilarité entre classes : procédé appelé un critère d'agrégation. La méthode laisse à l'utilisateur le choix de ce critère.

❖ Les indices de dissimilarité

De nombreuses mesures de la "distance" entre individus (I_i et I_j) ont été proposées (Kersten, Lee, & Ainsworth, 2005).

N.B : On parle de dissimilarité lorsque l'on a seulement :

- $d(I_i, I_j) = d(I_j, I_i)$,
- $d(I_i, I_j) \geq 0$,
- $d(I_i, I_i) = 0$.

Le choix d'une (ou plusieurs) d'entre elles dépend des données étudiées. Pour les données de type quantitatives continues ou discrètes on trouve:

- La distance de Minkowski d'ordre α : $d(I_i, I_j) = \left(\sum_k |x_{ik} - x_{jk}|^\alpha \right)^{1/\alpha}$ (1-2)

- $\alpha = 1$, la distance de City-block ou Manhattan.

$$d(I_i, I_j) = \sum_k |x_{ik} - x_{jk}| \quad (1-3)$$

- $\alpha = 2$, la distance Euclidienne classique. C'est probablement le type de distance le plus couramment utilisé. Il s'agit simplement d'une distance géométrique dans un espace multidimensionnel.

$$d(I_i, I_j) = \sqrt{\sum_k (x_{ik} - x_{jk})^2} \quad (1-4)$$

- $\alpha = +\infty$, la distance de Chebyshev définie comme suit :

$$d(I_i, I_j) = \max |x_{ik} - x_{jk}| \quad (1-5)$$

- La distance Euclidienne au carré. On peut élever la distance euclidienne standard au carré

afin de "surpondérer" les objets atypiques (éloignés).

$$d(I_i, I_j) = \sum_k (x_{ik} - x_{jk})^2 \quad (1-6)$$

❖ Les critères d'agrégation

On suppose ici qu'on connaît un indice de dissimilarité d entre deux parties A et B d'un ensemble E . Différentes solutions existent et conduisent chacune à une stratégie d'agrégation particulière. Parmi les diverses formules de dissimilarité, les plus utilisées sont les suivantes :

- Le critère du saut minimal (« single linkage » en anglais) :

Cette méthode consiste à prendre la plus petite distance entre les éléments des deux parties

(Sneath, 1957) (figure 1.13), soit : $d(A, B) = \inf_{I \in A, J \in B} d(I, J) \quad (1-7)$




Figure 1.13 : Critère du saut minimal.

Cette méthode tend à favoriser le regroupement de deux classes dès qu'elles possèdent des individus proches. Le risque est alors de trouver des individus très éloignés dans une même classe.

- Le critère du diamètre (« complete linkage » en anglais) :

On prend ici comme distance entre parties la plus grande distance entre les éléments des deux parties (McQuitty, 1960; Sokal & Sneath, 1963) (figure 1.14), soit :

$$d(A, B) = \sup_{I \in A, J \in B} d(I, J) \quad (1-8)$$




Figure 1.14 : Critère du diamètre.

Cette distance remédie un peu brutalement au défaut de la méthode du saut minimal. En effet, elle exige que les points les plus éloignés (donc tous les points) soient proches.

- Le critère de la moyenne (« average linkage » en anglais) :

La distance correspondante est la moyenne arithmétique des distances (Sokal and Michener, 1958) (figure 1.15) définie par :

$$d(A, B) = \frac{1}{n_A n_B} \sum_{I \in A, J \in B} d(I, J) \quad (1-9)$$

Avec n_A et n_B sont respectivement les cardinaux de A et B.




Figure 1.15 : Critère de la moyenne des distances.

- Le critère du centroïde (« centroid linkage » en anglais) :

La distance correspondante est la la distance entre les barycentres des parties A et B (figure 1.16) définie par :

$$d(A, B) = d(g_A, g_B) \quad (1-10)$$

avec g_A et g_B sont respectivement les centres de gravité de A et B.




Figure 1.16 : Critère du centroïde.

- le critère de Ward (ou critère d'agrégation selon l'inertie ou somme des carrés incrémentale):

La méthode de Ward consiste à choisir le regroupement de clusters qui induit la plus faible augmentation de l'inertie (ou de la variance) intraclasse (Ward, 1963) (figure 1.17), soit :

$$d(A, B) = \frac{n_A n_B}{n_A + n_B} d^2(g_A, g_B) \quad (1-11)$$

Avec n_A et n_B sont respectivement les cardinaux de A et B ; g_A et g_B sont respectivement les centres de gravité de A et B.

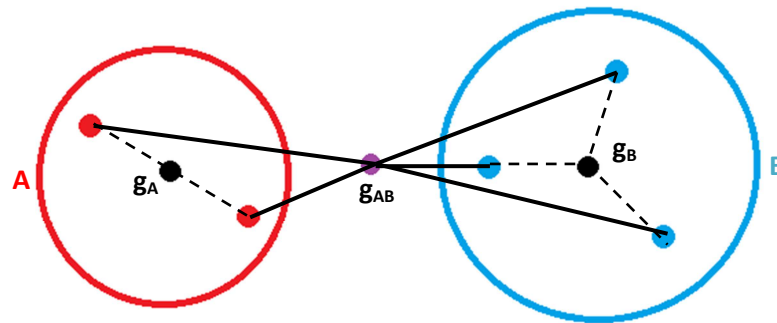


Figure 1.17 : Critère de Ward.

Ce critère utilise la distance euclidienne et donne la meilleure classification par rapport aux autres critères d'agrégation (Dillner et al., 2005; Picard et al., 2010; Carteron et al., 2012; Hands & Everitt, 1987).

Pour visualiser une classification hiérarchique, on utilise un dendrogramme (arbre hiérarchique indicé). Un dendrogramme (figure 1.18) représente la hiérarchie sous la forme d'un arbre binaire, où les données sont contenues dans les feuilles. La hauteur des nœuds de l'arbre indique généralement la distance entre les clusters. Cette forme de représentation facilite la visualisation de la hiérarchie. Pour obtenir une partition à partir de l'arbre hiérarchique, on peut faire le choix de couper horizontalement le dendrogramme. La partition obtenue est composée des clusters restant sous la coupe.

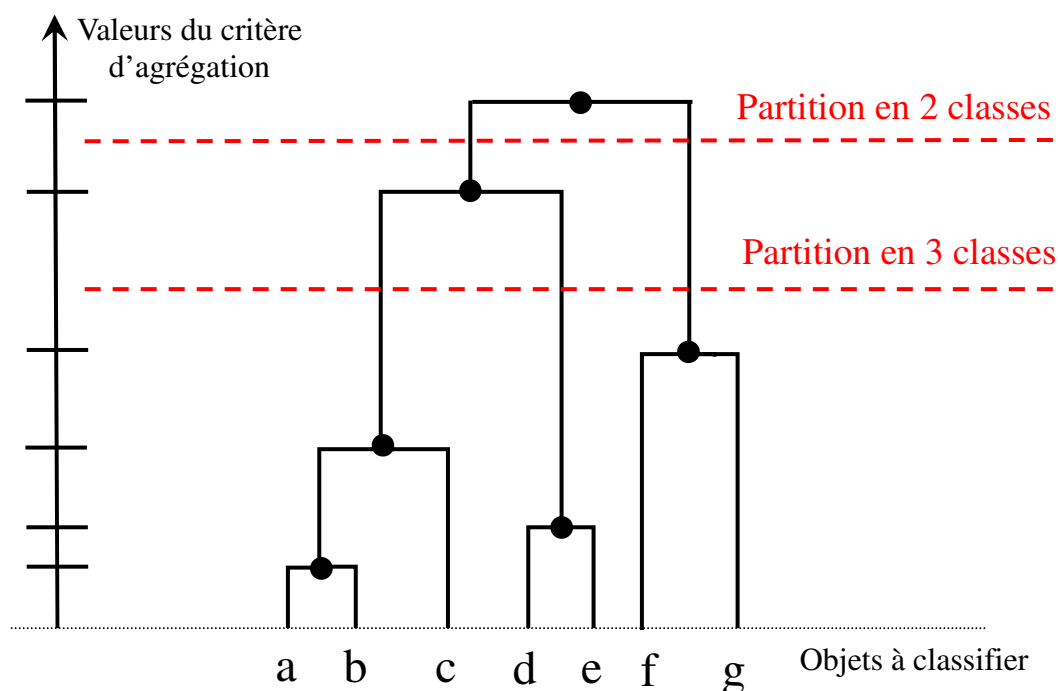


Figure 1.18 : Dendrogramme de la CAH et les coupes des partitions.

1.3.2. La classification par partitionnement

Nous présentons ici les algorithmes les plus utilisés dans les logiciels de traitement d'images de télédétection, connus sous les noms de K-means (ou K moyennes) (Mac-Queen, 1967), ISODATA (Ball & Hall, 1965) ainsi que les c-moyennes floues (FCM) (Bezdek ^a, 1974). Ces algorithmes sont des variantes des méthodes de « centres mobiles ».

❖ La méthode des centres mobiles

Cette méthode, développée par Forgy (1965), consiste à construire une partition en k classes en sélectionnant k individus comme centres des classes tirées au hasard de l'ensemble d'individus. Après cette sélection, on affecte chaque individu au centre le plus proche en créant k classes. Les centres des classes seront remplacés par les centres de gravités. Ainsi, des nouvelles classes seront créées par ce principe. Son algorithme s'écrit comme suit :

Données : k le nombre maximum de classes désiré.
Début
1) Choisir k individus au hasard (comme centres des classes initiales)
2) Affecter chaque individu au centre le plus proche. Ce qui donne une partition en k classes $\{C_1, \dots, C_k\}$.
3) On calcule le centre de gravité de chacune des k classes. Ce qui donne k nouveaux centres de classes.
4) Répéter l'étape 2) et 3) jusqu'à deux itérations successives qui donnent la même partition.
5) Editer la partition obtenue.
Fin

❖ La classification par k-means

La méthode des centres mobiles a connu des améliorations pour concevoir la méthode des k-moyennes (k-means) par Mac-Queen (1967) appelée aussi algorithme des nuées dynamiques (Hartigan & Wong, 1979). Avec l'approche k-means, les centres sont recalculés après chaque affectation d'un individu dans une classe, plutôt que d'attendre l'affectation de tous les individus avant de mettre à jour les centres. Cette approche conduit généralement à de meilleurs résultats que la méthode des centres mobiles et la convergence est également plus rapide. La méthode des k-moyennes construit k classes à partir de N individus, tout en minimisant la distance intraclasse d_{intra} et en maximisant la distance interclasse d_{inter} :

$$d_{intra} = \frac{1}{N} \sum_k \sum_{x \in E_j} \|x - c_j\|^2 \quad (1-12)$$

$$d_{inter} = \min \left(\|c_i - c_j\|^2 \right) \quad (1-13)$$

où x est un individu non classifié; N : le nombre des éléments (pixels) et c_i : le centre de

gravité ou la moyenne du $i^{\text{ème}}$ groupe calculé comme suit: $c_i = \frac{1}{N_i} \sum_{q=1}^{N_i} x_q \quad (1-14)$

avec N_i le nombre d'instances (pixels) appartenant au $i^{\text{ème}}$ centroïde.

❖ La classification par ISODATA

C'est une version améliorée de l'algorithme K-means, cet algorithme, nommé "Iterative Self-Organizing Data Analysis Technics" : ISODATA (Ball & Hall, 1965), autorise, au cours des itérations, la fusion entre des nuages proches, la division d'un nuage à variance élevée et la suppression de nuage de petite taille. Le nombre de classes peut être modifié au cours de la classification, et sa valeur optimale est obtenue à l'aide d'heuristiques.

L'utilisateur doit spécifier donc les paramètres suivants :

- Le nombre minimum de membres dans un segment n_{min} . Si un segment contient moins de membres que le minimum spécifié, il est supprimé et ses membres sont affectés à un autre segment (le plus proche).
- L'écart type maximum σ_{max} . Lorsque l'écart type d'un segment dépasse le maximum spécifié, et que le nombre de membres dans le segment est deux fois supérieur au minimum de membres spécifiés dans une classe, le segment est éclaté en deux segments.
- La distance minimum entre les segments d_{min} . Des segments ayant une distance pondérée inférieure à cette valeur sont fusionnés.

Après l'initialisation, le nouveau vecteur moyen de chaque segment est calculé sur la base des valeurs spectrales actuelles des pixels affectés à chaque segment. Ceci implique l'analyse des paramètres suivants : n_{min} , σ_{max} et d_{min} . Ensuite, le processus complet est réitéré avec chaque pixel candidat, une fois de plus comparé aux nouveaux vecteurs moyens de segments et affecté au segment le plus proche. Ce processus itératif continue jusqu'à ce que l'on ait un petit changement dans l'affectation des classes entre les itérations, ou que le nombre maximum d'itérations soit atteint (figure 1.19).

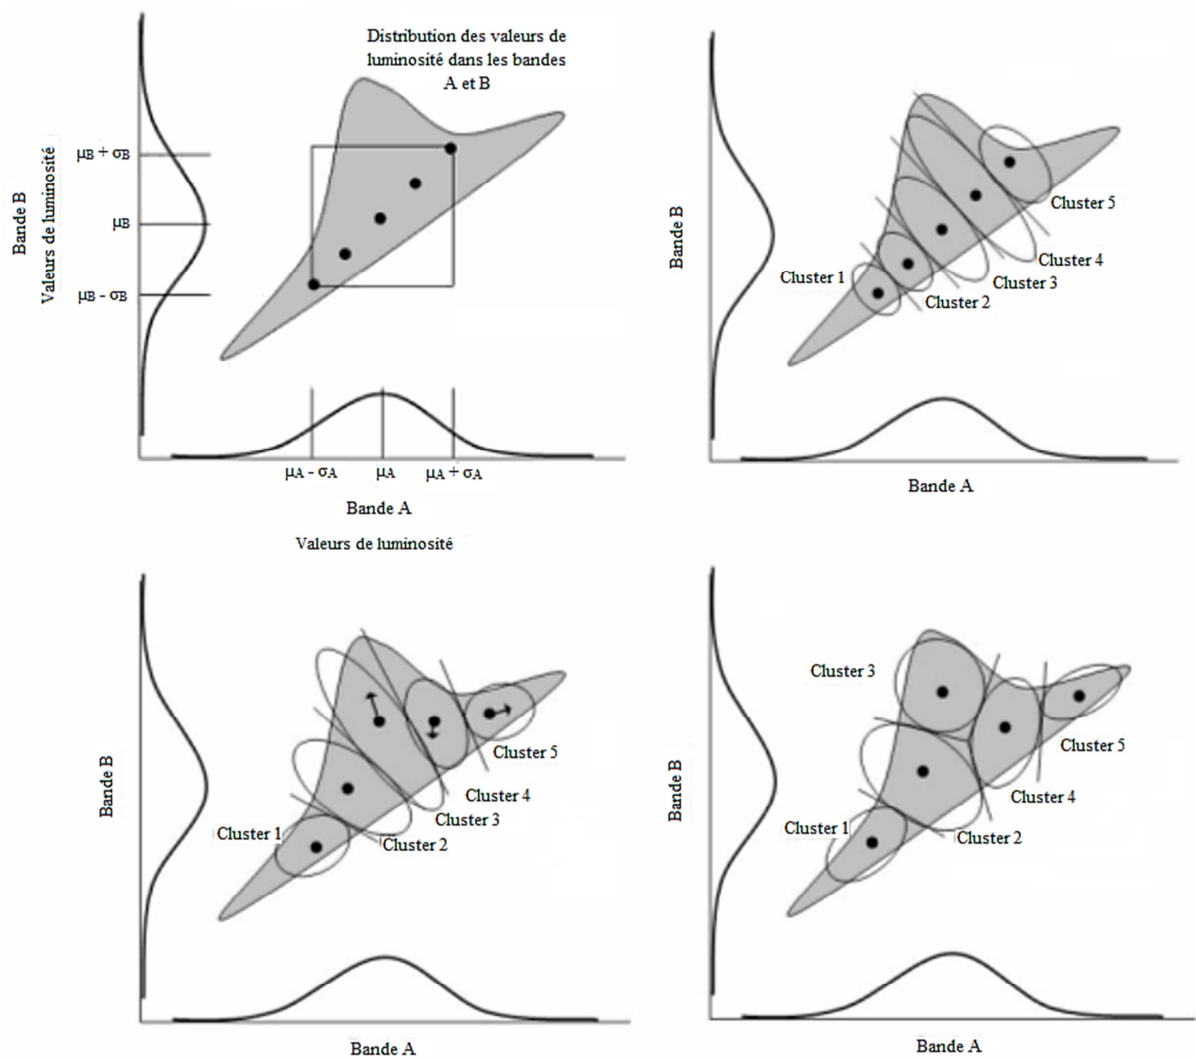


Figure 1.19 : L'initialisation et la variation du centre de gravité des classes au cours des itérations de l'ISODATA.

❖ La classification par c-moyennes floues (FCM: Fuzzy C-Means)

Ces deux algorithmes (k-moyennes et ISODATA) sont à la base des premiers travaux de Dunn (1973) et de Bezdek^a (1974). Ils représentent le point de départ d'une multitude de travaux ne cessant, jusqu'aujourd'hui, de s'enrichir et de se diversifier. L'algorithme des c-moyennes floues (FCM) est, donc, un descendant de la méthode des k-moyennes, ou centres mobiles. C'est une méthode de classification itérative qui permet de classer les individus selon C classes. Elle calcule à chaque fois les centres des classes et génère la matrice d'appartenance U des individus à ces classes.

Soient V_j le centroïde ou prototype de la classe j , U la matrice des coefficients μ_{ij} et X_c celle des coordonnées des centres. Etant donné le nombre de classe C , le nombre d'individus

n et l'exposant flou m ($m > 1$), l'objectif de la méthode est de trouver U et X_c qui minimisent la fonction objective donnée par la relation :

$$J(U, V, m) = \sum_{i=1}^n \sum_{j=1}^C \mu_{ij}^m D_{ij}^2 \quad \text{où} \quad \sum_{j=1}^C \mu_{ij} = 1 \quad \forall i = 1, \dots, n \quad (1-15)$$

avec D_{ij} est une métrique choisie au sens d'une norme. Généralement, il s'agit de la norme euclidienne. Ainsi, $D_{ij} = \|X_i - V_j\|_2$ est la distance entre le vecteur X_i et le prototype V_j .

Soit $x_i = (x_{i1}, x_{i2}, \dots)$ les vecteurs représentant les individus à classer. La technique de classification par FCM repose sur l'algorithme suivant :

Données : m le coefficient flou, C le nombre de classes et ε le critère d'arrêt
<p>Début</p> <p>1) Initialiser le vecteur V par C centres aléatoirement choisis.</p> <p>2) Calculer la matrice U de taille (C x n) par les équations :</p> $\mu_{ij} = \left(\sum_{k=1}^C (D_{ij}/D_{ik})^{\frac{2}{m-1}} \right)^{-1} \quad (1-16)$ <p>D_{jk} est la distance entre l'individu k et le centre V_j</p> <p>3) le nouveau centre de chaque classe à l'aide de l'équation :</p> $V_j = \left(\sum_{i=1}^n (\mu_{ij})^m x_i \right) / \left(\sum_{i=1}^n (\mu_{ij})^m \right) \quad (1-17)$ <p>4) Mettre à jour la matrice U et incrémenter le compteur t.</p> <p>5) Calculer la distance entre les nouveaux et les anciens centres :</p> $h = \ V^{t-1} - V^t\ \quad (1-18)$ <p>6) Répéter les étapes de 3 à 6 tant que $h > \varepsilon$.</p> <p>Fin</p>

L'exposant flou m est un réel > 1 qui influence sur la classification. Plus m tend vers 1, plus la classification devient dure et u_{ij} se rapproche de 0 ou de 1. Inversement quand m devient trop grand, il y a moins de tolérance au bruit, et la distribution des degrés d'appartenance tend à se concentrer autour de $1/C$.

Pour l'algorithme des c-moyennes floues, la décision d'appartenance d'un pixel à une classe n'est prise qu'à la fin de la convergence, contrairement aux k-moyennes qui affectent un pixel à une classe à chaque itération.

1.4 Bilan bibliographique

A l'issue de cette synthèse bibliographique, nous constatons qu'il existe plusieurs techniques de classification réparties en deux grandes familles. La première est la classification supervisée qui nécessite un apprentissage préalable. Ce dernier joue un rôle très important sur la qualité des résultats, car un praticien doit avoir une bonne connaissance préalable sur les objets pour en réaliser une classification adéquate. Au contraire, la deuxième famille est la classification non supervisée qui s'appuie sur des caractéristiques et des critères propres aux objets à classer. Ces critères sont issus des théories des groupes et du calcul des probabilités d'appartenance de chaque objet à une classe. Néanmoins, cette classification aussi bien hiérarchique ou par partitionnement, reste semi-automatique. En effet, l'utilisateur doit procéder par l'approche dite *Trial and Error* qui consiste à initier la classification par un nombre donné de classes et l'ajuster en triant les résultats obtenus. Cette démarche est longue et fastidieuse et n'aboutit pas forcément à de bons résultats que dans les cas rares où l'on possède une bonne connaissance sur le contenu des données. Ces inconvénients ont poussé les recherches à trouver des solutions selon deux axes :

- La mise en place des techniques hybrides qui associent la classification supervisée à une autre non supervisée (Jiang et al., 2013; Fujino et al., 2005; Pradhan et al., 2010). Cette alternative donne des résultats satisfaisants, mais l'analyse des résultats reste la partie la plus lourde, car la technique reste et demeure semi-supervisée. L'intervention du praticien est nécessaire et l'analyse prend des délais prohibitifs.
- L'utilisation d'algorithmes qui analysent les groupes pour parvenir à des fonctions qui définissent la performance de la classification (Wang & Zhang, 2007). On l'appelle l'étude de la validité d'une répartition. La difficulté provient du fait qu'il n'existe aucun critère universel pour déterminer si un algorithme donné est bien adapté à tout ensemble quelconque de données.

En se basant sur ces deux alternatives, nous avons eu l'idée de combiner la classification supervisée utilisant le PNN avec la classification hiérarchique non supervisée. Le rôle de cette dernière est de procéder à l'apprentissage du PNN. Pour obtenir les meilleurs résultats possibles, nous proposons également une fonction qui analyse la partition des classes (Iounousse et al., 2015).

Chapitre 2 :

La classification et l'analyse des images en télédétection

2.1. Introduction

La classification est l'une des tâches les plus utilisées dans notre comportement humain. Elle vise à identifier des groupes d'objets similaires dans le sens d'un critère d'homogénéité et donc, permet de découvrir la distribution des modèles et des corrélations intéressantes dans un grand ensemble de données. Son application a un rôle important pour résoudre de nombreux problèmes tels que la reconnaissance de formes et des régularités dans les données (Pattern recognition) (Zheng & He, 2005), le traitement d'images, la segmentation de la couleur (Mohan & Kannan, 2010), l'exploration de données (Data Mining) (Phyu, 2009). Elle est appliquée aussi dans plusieurs domaines tels que la médecine (El Harchaoui et al., 2013; Wang et al., 2013), la biologie (Arribas et al., 2011; Raghuraj & Lakshminarayanan, 2008), le marketing (Kaefer et al., 2005), l'énergie (Huang et al., 2012), la télédétection en particulier l'occupation du sol (Idrissi et al., 2004; Geerken et al., 2005; Ait Kerroum et al., 2010; Julien et al., 2011;; Halder et al., 2011; El Merabet et al., 2014), ...etc.

On s'intéresse dans ce travail à classifier un type de données fréquemment utilisé qui est l'image. Une donnée image peut être une simple matrice représentant un signal bidimensionnel limité (par exemple une image en gris). Elle peut être aussi plus complexe et multidimensionnelle représentant une pile de scènes dans un espace donné (par exemple une séquence temporelle d'images de télédétection).

L'objectif de ce chapitre est de donner l'ensemble d'outils permettant de caractériser qualitativement et quantitativement l'imagerie en télédétection. Une attention particulière est attribuée à la présentation des différents descripteurs qui permettent l'extraction de l'information de l'image.

2.2. Définition de la télédétection

La télédétection désigne l'ensemble des techniques qui permettent d'obtenir des informations sur des objets ou des phénomènes, en analysant des données collectées par l'intermédiaire d'instruments de mesure (un satellite par exemple), n'étant pas en contact direct avec ces objets.

De nombreux domaines utilisent la télédétection : la cartographie, la géologie, l'océanographie, l'agriculture, la sylviculture (foresterie), l'environnement, l'écologie, la météorologie...etc. Nous présentons dans la section suivante un exemple d'application de la classification par l'intermédiaire de la télédétection optique dans le but de déterminer l'occupation du sol et la cartographie des régions agricoles.

2.3. L'application de l'imagerie en télédétection

De nos jours la compréhension de notre environnement est une préoccupation de nos sociétés. Réchauffement climatique, déforestation intensive, pollution des sols, ressources et usages des eaux... sont quelques exemples concrets des questions actuelles. Dans ce contexte général, l'étude de la végétation tient une place primordiale. L'étude du fonctionnement de la végétation a généralement recours à des modèles numériques en analysant les images de télédétection. Or, c'est la classification de ces images qui permet l'analyse des indices de végétation tout en se basant sur des techniques d'extraction et des algorithmes de classification de l'information. On s'accorde à considérer que la classification des données images en télédétection a apporté une véritable révolution pour la connaissance et le suivi de la surface du sol. Au cours de la dernière décennie, le besoin en cartes fiables et actualisées a exponentiellement grandi. Le flux des images de télédétection a crû et les systèmes d'information géographique (SIG) ont extrêmement évolué. Ainsi, il devient nécessaire de développer des outils automatiques performants qui analysent toutes ces données, et particulièrement les images. Avant, la cartographie ou l'interprétation des images de télédétection est effectuée par identification des thèmes d'intérêt, la détermination de leur contour et ainsi la reproduction des résultats sur une carte sous forme d'unités spatiales ponctuelles, linéaires ou zonales. Ce processus était lent, fastidieux et coûteux et ne répondait pas à la demande. Un besoin urgent d'automatiser cette opération sollicitant des techniques de compréhension d'images par ordinateur s'est avéré indispensable pour optimiser le temps et améliorer d'une façon très sensible la précision du document cartographique final. D'où l'utilisation de techniques purement numériques développées pour répondre aux différents problèmes d'interprétation et d'extraction de l'information à partir des images satellitaires et aériennes, notamment dans les cas particuliers de l'occupation du sol et de la détection et l'extraction de profils de végétation.

2.3.1. L'intérêt de la télédétection dans l'agriculture

L'agriculture joue un rôle primordial dans l'économie des pays développés et en voie de développement comme le Maroc. Tout producteur agricole a besoin d'information pour gérer efficacement ses récoltes. Il doit disposer des outils d'information qui lui permettent de planifier ses opérations et de faire face aux multiples aléas pouvant menacer sa production et affecter les conditions de sa terre et ainsi le potentiel de sa récolte et. Parmi les applications qui utilisent les images de télédétection (images satellitaires et aériennes) dans le secteur d'agriculture mentionnons :

- La classification des types de cultures.
- L'évaluation de l'état des cultures.
- L'estimation de la production agricole.
- La cartographie des caractéristiques du sol.
- La cartographie des pratiques de gestion du sol.
- La surveillance des ressources en eau.
- La surveillance de conformité aux lois et traités.

La classification des images de télédétection offre une méthode sûre et efficace de cueillette d'information dans le but de cartographier le type des cultures et de calculer leur superficie. En plus d'offrir une vue synoptique, cette classification peut fournir de l'information sur la structure et la santé de la végétation. En effet, la réflectance spectrale d'un champ varie selon le stade phénologique (stade de croissance) de la végétation, le type de plantes et leur état de santé. Aussi, les micro-ondes sont sensibles à l'alignement, la structure et la quantité d'eau présente dans les plantes et dans le sol, et peuvent fournir de l'information complémentaire aux données optiques. L'intégration de ces deux types de données augmente l'information disponible pour distinguer la signature spectrale de chaque classe et permet donc une classification plus juste. Ce qui donne naissance à plusieurs formules que les spécialistes appellent des indices de végétation (Bannari et al., 1995) (voir la section 2.4.1). Ces derniers servent à faciliter l'identification de la végétation en utilisant les mesures radiométriques prises à partir des images de télédétection.

Les résultats de l'interprétation des données de télédétection peuvent être intégrés dans un SIG ou un système de gestion des cultures. Ils peuvent aussi être combinés à des données auxiliaires pour fournir de l'information sur les droits de propriété, les pratiques de gestion, etc.

2.3.2. L'acquisition des images de télédétection

De nombreux moyens d'acquisition (optiques, lasers, radars, sismographes, gravimètres, etc.) peuvent être utilisés. Les méthodes d'acquisitions dites optiques utilisent la mesure des rayonnements émis ou réfléchis par les objets étudiés dans un certain domaine de fréquences (infrarouge, visible, etc.). Ceci est rendu possible par le fait que les objets étudiés (végétation, habitations, surfaces d'eau ou masses d'air) émettent et/ou réfléchissent des rayonnements à différentes longueurs d'onde et intensités selon leur état. Certains instruments de télédétection, comme les sonars, utilisent des ondes sonores de façon similaire, tandis que d'autres mesurent des variations dans des champs magnétiques ou gravitaires.

On se focalise dans cette thèse uniquement sur la télédétection optique où la donnée captée par le système de détection est une réponse radiométrique (réflectance) des surfaces. Ces données capturées à partir de plateformes aériennes (ballons, drones avions) ou de satellites, se présentent sous la forme d'une matrice de pixels formant une image pouvant être de natures différentes en fonction, principalement, de la résolution spectrale, de la résolution spatiale et de la résolution temporelle des capteurs. La (figure 2.1) schématise ce processus.




Figure 2.1 : Schématisation du processus de télédétection passive.

❖ La résolution spectrale

C'est-à-dire la largeur de l'intervalle de chaque bande spectrale, varie de 0,2 μm à 10 μm suivant les capteurs. Le nombre de bandes peut aller de trois ou quatre (SPOT, Quickbird) jusqu'à une centaine (DAIS) ce qui correspond à la Très Haute Résolution spectrale. On distingue généralement quatre régions spectrales :

- le visible (VIS) : 0,4 μm à 0,7 μm ;
- le proche infrarouge (NEAR-IR) : 0,7 μm à 1,3 μm ;
- le moyen infrarouge (MID-IR) : 1,3 μm à 3 μm ;
- l'infrarouge lointain (FAR-IR) : 3 μm à 15 μm .

Ces informations captées sont bien évidemment liées à la nature du paysage observé. La (figure 2.2) montre quatre exemples de spectres de réflectance très contrastés.

❖ La résolution spatiale

Elle présente la distance qu'occupe un coté d'un pixel carré. Elle varie de plusieurs dizaines de mètres (Landsat-1 (1972) : 80 m, Landsat-4 (1982) : 30 m, SPOT 3 (1993) : 20 m en mode multispectral, 10 m en panchromatique) à une résolution proche du mètre

(QuickBird (2001) : 2,8 m en couleur, 0,7 m en panchromatique). On distingue généralement, dans le domaine civil, quatre catégories de résolution :

- la basse résolution (> 100 m),
- la moyenne résolution MR (80 m),
- la haute résolution HR (10 à 30 m),
- la très haute résolution spatiale THR (inférieure à 5 m).

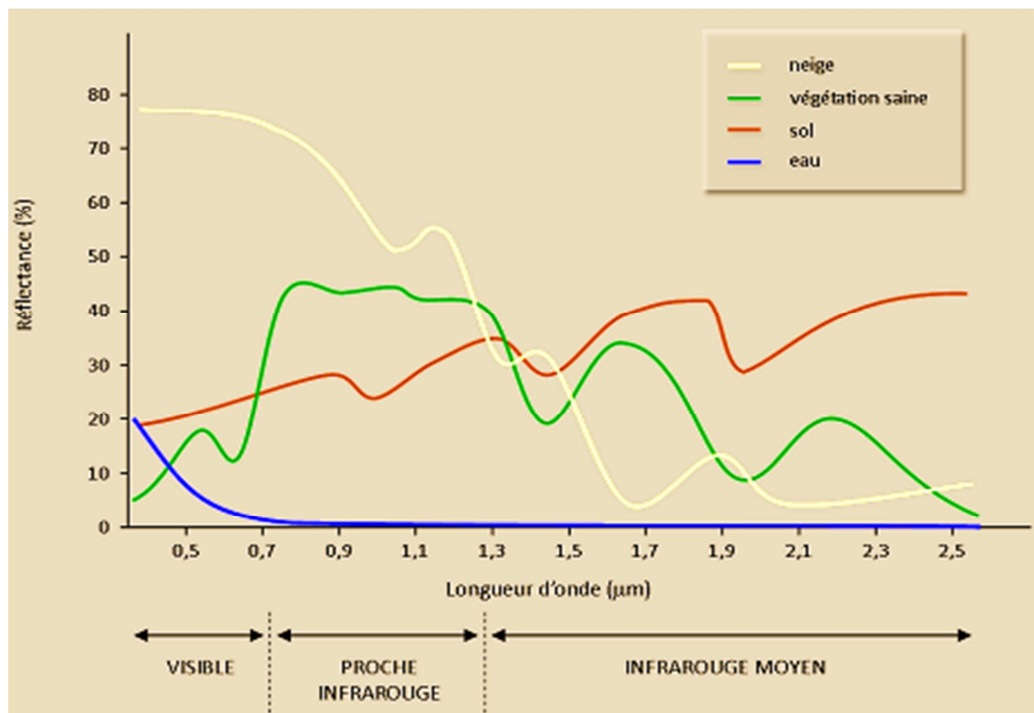


Figure 2.2 : Spectres typiques de réflectances de la neige, de l'eau, du sol et de la végétation.

❖ La résolution temporelle

Les observations issues de la télédétection spatiale sont également caractérisées par leur résolution temporelle ou encore la répétitivité des observations, notion qu'il est plus difficile d'appréhender, car plusieurs composantes interviennent dans sa définition. La résolution temporelle dépend du cycle orbital d'un capteur satellitaire. Ce cycle définit la période de revisite, à savoir le temps que met un capteur pour observer un même point de la surface de la terre dans les mêmes conditions de visée. Pour les satellites polaires sur orbite héliosynchrone, ce cycle est généralement d'une durée de 15 jours à un mois; il est par exemple de 16 jours pour Landsat et de 26 jours pour SPOT.

L'identification et la cartographie des récoltes s'effectuent par l'utilisation des images multitemporelles en tenant compte les changements dans la réflectance des plantes durant leur croissance. La résolution temporelle est un paramètre qui y joue un rôle important.

2.4. L'information dans les images de télédétection

Après la phase d'acquisition des images de télédétection à partir des capteurs vient la phase de l'analyse et de l'interprétation visuelle et/ou numérique de l'image traitée qui est nécessaire pour extraire l'information que l'on désire obtenir sur la cible. Pour ce faire, il est essentiel d'exploiter des éléments qui caractérisent et discriminent au mieux les différentes classes, car le succès des opérations ultérieures dépend de cette information de bas niveau extraite de l'image. On les appelle des descripteurs, attributs, caractéristiques ou bien primitives et peuvent être classés en trois catégories : spectrales, texturales et géométriques. Le choix de ces descripteurs dépend de la résolution spatiale et spectrale des images.

2.4.1. Les descripteurs spectraux

❖ Les compositions colorées

Dans les systèmes de télédétection, nous avons vu qu'il est possible de détecter et d'enregistrer des parties du spectre électromagnétique qui ne sont pas décelables à l'œil nu, comme l'infrarouge par exemple. Pour pouvoir visualiser cette information, on associe aux bandes spectrales du système d'observation des couleurs d'affichage (rouge-vert-bleu), qui ne leur correspondent pas nécessairement. Ainsi, on crée des compositions colorées.

Les compositions colorées permettent de produire des images en couleurs en tenant compte de la signature spectrale des objets. Elles sont fréquemment utilisées pour faire ressortir les différents types de surface sur les images multispectrales ou mettre en évidence certains phénomènes environnementaux, comme les feux de forêts, les vents de sable, les glaces de mer, ...etc. Selon les applications, on peut être amené à effectuer différentes compositions colorées:

- Soit des compositions que l'on appelle « *vraies couleurs* » si l'on veut rendre les images réalistes. C'est ce que nous observerions si nos yeux étaient à la place du capteur satellitaire.
- Soit des compositions « *fausses couleurs* » (figure 2.3(a)), qui ne représentent pas les couleurs réelles, mais qui ont pour but de mettre en avant certains objets dans une image, à l'instar des images infrarouges fausses couleurs très utilisées pour l'étude de la végétation.

❖ Les indices de végétation

Les indices de végétation sont des formules empiriques conçues pour fournir des mesures quantitatives qui sont souvent en rapport avec la biomasse et l'état de la végétation. Il en existe plusieurs, séparables en 3 catégories : les indices intrinsèques (NDVI : Normalized Difference Vegetation Index), les indices liés aux variations du sol (PVI: Perpendicular Vegetation Index, WdVI: Weighted Difference Vegetation Index) et les indices liés aux propriétés de l'atmosphère tels que ARVI: Atmospherically Resistant Vegetation Index et GEMI: Global Environmental Monitoring Index (Rondeaux et al., 1996). Ces indices diffèrent par leurs capacités à bien estimer le LAI: Leaf Area Index, et par leur sensibilité à la brillance des sols ou aux effets de l'atmosphère (Bannari et al., 1997). L'indice le plus communément utilisé est NDVI (Normalized Difference Vegetation Index) (Rouse et al., 1973; Rouse et al., 1974):

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (2 - 1)$$

où NIR est la réflexion mesurée dans le canal proche infrarouge (near infrared) et RED est celle mesurée dans le canal rouge.

La valeur de NDVI peut être :

- Négative pour les surfaces dont la réflexion est plus élevée dans le visible que dans le proche infrarouge comme les nuages, l'eau et la neige.
- Proche de zéro pour la roche et le sol nu qui ont des réflexions similaires dans ces deux bandes.
- Positive entre 0.15 et 0.9 pour la végétation. Plus elle est élevée, plus la densité de verdure est importante.

En effet, la réponse spectrale d'un couvert végétal dense est forte dans les longueurs d'onde proche infrarouge et faible dans les longueurs d'onde rouges (la chlorophylle absorbe le rayonnement incident de la partie visible du spectre électromagnétique), alors que la réponse spectrale d'un couvert clairsemé est inverse.

La différence normalisée permet de rendre compte de ces deux phénomènes sur une même image qu'on appelle l'image NDVI (figure 2.3(b)).

Ce néocanal résultant présente un gradient croissant d'activité végétale allant du noir signifiant l'absence de couverture, au blanc qui rend compte d'une activité chlorophyllienne très élevée.




Figure 2.3: (a) Exemple d'une image SPOT à 20m de résolution en fausses couleurs TM 432. (b) L'image NDVI correspondante.

❖ Les modèles colorimétriques

A l'instar d'effectuer des compositions colorées, on peut être amené à réaliser des transformations permettant d'utiliser autres représentations de la couleur. Différents modèles colorimétriques permettent de quantifier et de mesurer précisément les couleurs. Ils utilisent tous des valeurs numériques pour décrire et classer les couleurs. Le point commun à tous ces modèles est qu'ils sont tridimensionnels, ils utilisent trois coordonnées pour représenter la couleur. On constate trois grandes familles :

- Les modèles dépendant d'un système matériel.
- Les modèles perceptuels.
- Les modèles de référence de la commission internationale d'éclairage (CIE).

a) Les modèles dépendant d'un système matériel : Le codage RVB

Le codage RVB a été développé en 1931 par la Commission Internationale de l'Eclairage (CIE). C'est le modèle idéal pour expliquer la synthèse additive des couleurs puisqu'il consiste à représenter l'espace des couleurs à partir des trois couleurs primaires :

- Le rouge (longueur d'onde 700 nm),
- Le vert (longueur d'onde 546,1 nm),
- Le bleu (longueur d'onde 425,8 nm).

Le modèle colorimétrique RVB est le système le plus courant et le plus utilisé, car il dérive de la technologie employée dans l'industrie du numérique. Moniteurs à tube cathodique ou à cristaux liquides, appareils photos numériques, scanners, utilisent tous un système RVB basé sur le principe additif des trois couleurs primaires (rouge, vert et bleu). En codant chacune des composantes colorées sur un octet, on obtient 256 valeurs pour chaque couleur. Il est donc possible en théorie d'obtenir 256^3 , soit 16777216 couleurs différentes, c'est-à-dire beaucoup plus que l'œil humain n'est capable d'en discerner (environ 350000). Cette valeur reste cependant théorique, car les écrans ne permettent pas d'afficher un tel nombre de couleurs.

Le modèle RVB est généralement représenté par un cube dont les axes, de longueur unitaire, portent les trois couleurs primaires. Le noir est localisé à l'origine (point de coordonnées (0,0,0)), le blanc à l'opposé, au point de coordonnées (1,1,1). La diagonale qui relie le noir au blanc correspond aux niveaux de gris, ce que l'on appelle l'axe achromatique. Les couleurs complémentaires, le cyan, le magenta et le jaune sont portées par les trois autres axes - qui ont pour origine le blanc (figure 2.4).




Figure 2.4 : Représentation du modèle RVB.

Toutes les couleurs peuvent ainsi être exprimées par la somme des vecteurs des trois composantes RVB, selon la formule : $\vec{C} = a\vec{R} + b\vec{V} + c\vec{B}$, où a, b, c sont les composantes du vecteur couleur \vec{C} dans la base RVB. Les valeurs de a, b et c sont comprises entre 0 et 1. Par exemple, le jaune est obtenu par le mélange du rouge et du vert : $\vec{J} = \vec{R} + \vec{V}$.

b) Les modèles perceptuels : Le modèle TSL (Teinte Saturation Luminosité)

Si le modèle RVB se révèle bien adapté à la représentation de la couleur en informatique, il est en revanche assez éloigné de la perception que nous avons des couleurs. En effet, nos yeux ne perçoivent pas les couleurs comme une somme de rouge, de vert et de bleu, mais plutôt comme une sensation de luminosité correspondant à l'intensité de la lumière. On définit des objets plus ou moins clairs ou plus ou moins foncés. A cette notion de luminance, il faut également rajouter une information de coloration, ce qu'on appelle la chrominance, définit à la fois par la teinte (la couleur) et la saturation (pureté de la teinte).

Le modèle TSL est un modèle colorimétrique perceptuel, car il se rapproche fortement de la perception physiologique de la couleur par l'œil humain. Dans ce système, les couleurs sont toujours caractérisées par trois dimensions, mais qui ont une signification tout autre que dans le modèle RVB, puisqu'elles représentent ici la teinte, la saturation et la luminosité. On représente généralement le modèle TSL à l'aide de deux cônes inversés placés l'un au-dessus de l'autre (figure 2.5(a)). On entend parfois parler de modèle TSV pour Teinte, Saturation et Valeur. Ce modèle colorimétrique, très proche du modèle TSL, se distingue par l'axe des luminosités dont la valeur 100% (blanc) se situe dans le même plan que celui des couleurs saturées. On obtient ainsi une représentation graphique en 'simple cône', plutôt que la représentation en 'double cône inversé' précédente. Le modèle TSV (figure 2.5(b)) est très utilisé dans l'édition graphique; il peut toutefois porter à confusion, car il est possible d'obtenir du blanc, soit par désaturation des couleurs pures, soit en augmentant la luminosité.

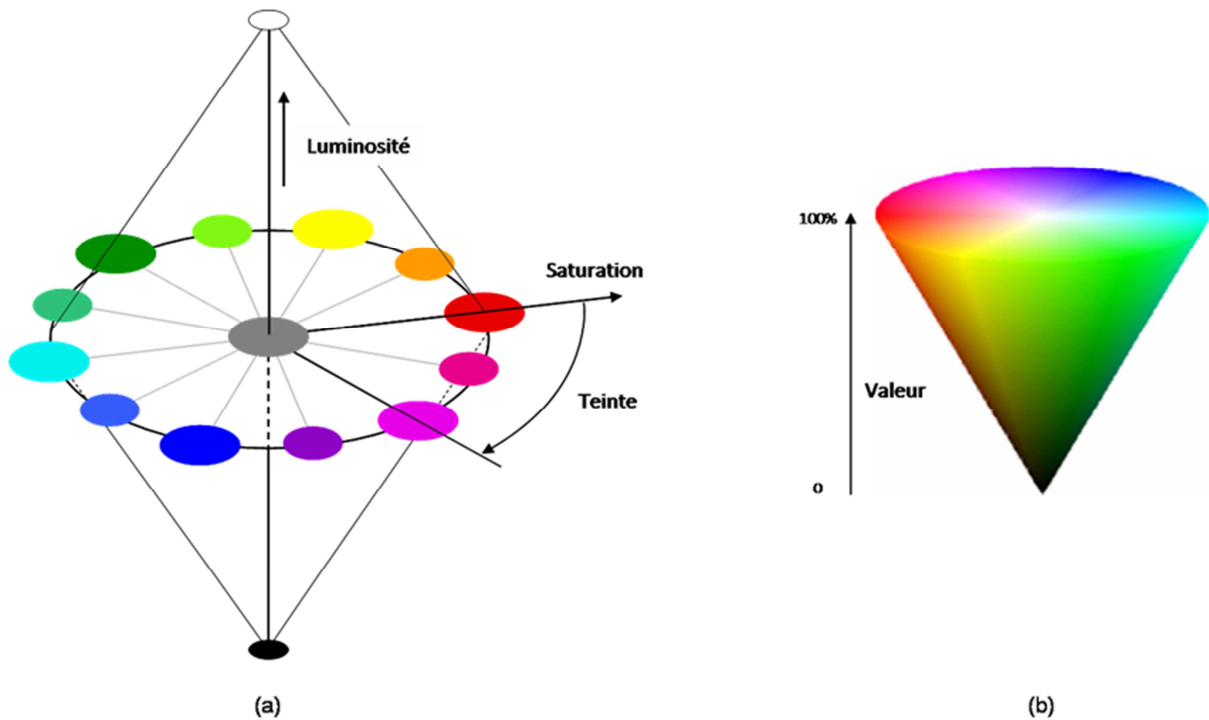


Figure 2.5 : (a) Double cône inversé du modèle TSL et (b) représentation en simple cône du modèle colorimétrique TSV.

c) Les modèles de référence de la CIE : CIE XYZ

Le modèle CIE XYZ (également appelé modèle CIE 1931) est le premier modèle colorimétrique créé par la CIE en 1931. Réalisé à partir d'une série d'expériences sur la perception des couleurs par l'œil humain, ce modèle est rarement utilisé, mais sert de référence pour définir d'autres modèles. Les trois composantes X, Y et Z du modèle représentent respectivement la teinte, la luminance (intensité lumineuse pondérée par la sensibilité spectrale de l'œil) et la saturation. Ces trois valeurs, dites valeurs tristimulus, qui sont en fonction de la réflectance de l'objet éclairé par un illuminant et la sensibilité spectrale de l'œil humain, peuvent être calculés par une transformation à partir du modèle RVB le plus connu comme suit :

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 2.7688 & 1.7517 & 1.1301 \\ 1 & 4.5907 & 0.0601 \\ 0 & 0.0565 & 5.5942 \end{bmatrix} \begin{bmatrix} R \\ V \\ B \end{bmatrix}$$

❖ L'histogramme

Un histogramme de couleurs (ou distribution de couleurs) est obtenu en comptant le nombre de pixels pour chaque couleur dans l'image. Il a été introduit en tant que descripteur par (Swain & Ballard, 1991). Etant donnée une image I , de taille $M \times N$ pixels, caractérisée pour chaque pixel (i,j) par une couleur c appartenant à l'espace de couleurs C (c'est-à-dire $c =$

$I(i,j)$), alors l'histogramme h est un vecteur à n composantes : $(h_{c1}, h_{c2}, \dots, h_{cn})$ pour lequel h_{cj} représente le nombre de pixels de couleur c_j dans l'image I .

On a :

$$\sum_{i=1}^n h_{ci} = M \times N \quad (2 - 2)$$

Ainsi, un histogramme contient, pour chaque couleur de l'espace, le nombre de pixels de l'image qui sont de cette couleur. En divisant par la surface de l'image ($M \times N$), on obtient la probabilité de chaque couleur d'être associée à un pixel donné. Cette normalisation permet d'avoir une invariance par changement d'échelle.

Une image multispectrale peut donner lieu à plusieurs types d'histogrammes. En effet, un histogramme monodimensionnel peut être calculé pour chaque canal de l'image, comme si le contenu de chacun d'eux était une image en niveaux de gris : cela constitue souvent une première analyse intéressante. Mais, on peut également étudier les histogrammes multidimensionnels de l'image (en général bi- ou tridimensionnels).

A partir de deux canaux particulièrement significatifs de l'image, la construction d'un histogramme bidimensionnel (figure 2.6) s'avère instructive. L'histogramme est alors constitué de deux axes perpendiculaires représentant chacun des canaux, et l'effectif, dans l'image, de chaque couple de valeurs radiométriques, est représenté par une couleur.

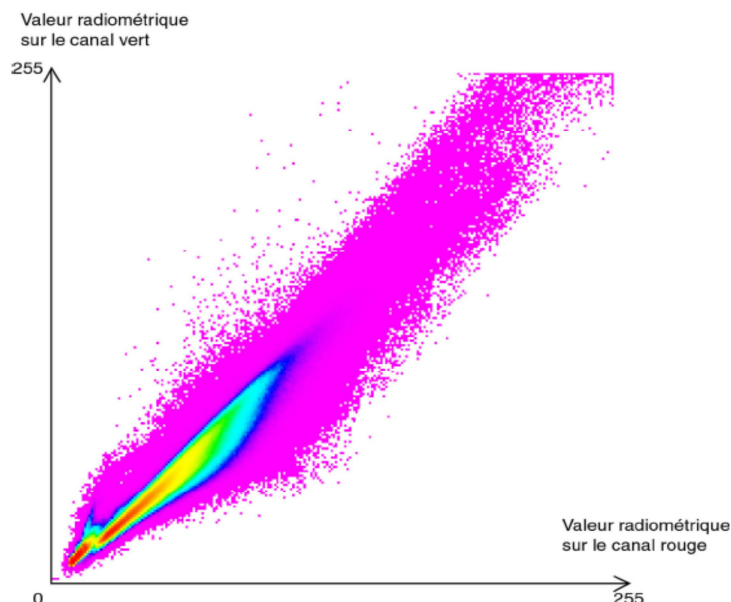


Figure 2.6 : Exemple de diagramme bidimensionnel.

Au-delà de deux à trois dimensions, les histogrammes deviennent trop compliqués à visualiser et à interpréter et perdent donc leur intérêt.

La distribution des radiométries dans une image est rarement plate ou gaussienne : les histogrammes unidimensionnels peuvent être par exemple bi- ou tri- modaux et totalement dissymétriques, il arrive même que des populations bien distinctes ressortent directement sur l'histogramme (figure 2.7).

L'analyse des histogrammes bidimensionnels peut nous apprendre énormément de choses : si les points d'effectifs importants sont plutôt alignés, on peut en déduire une corrélation entre les canaux étudiés, c'est-à-dire une redondance de l'information (par exemple, deux canaux dans le domaine du visible). En général, plus un histogramme bidimensionnel est étalé dans l'ensemble des directions, plus il est intéressant du fait de la diversité de ses valeurs.

Si on veut travailler l'information produite par l'étude de deux canaux très corrélés, il suffit d'étudier l'histogramme ayant sur un axe la somme des valeurs des pixels dans les deux canaux, et sur un autre leur différence. Cela se révèle souvent pertinent (les différences sautent plus facilement aux yeux, l'histogramme est bien plus étalé), mais malheureusement il est ensuite assez dur d'interpréter thématiquement les objets concernés à partir des comptes numériques.





Figure 2.7 : Exemple d'analyse d'un histogramme unidimensionnel.

De même que, sur l’histogramme d’un seul canal, différents modes (= ils correspondent aux « bosses » de l’histogramme) sont souvent identifiables, des noyaux ou centroïdes, représentatifs des divers types d’objets présents sur l’image, ressortent en général sur les histogrammes multidimensionnels.

2.4.2. Les descripteurs texturaux

La texture est le second attribut visuel largement utilisé dans la recherche d’images par le contenu. Elle permet de combler un vide que la couleur est incapable de faire, notamment lorsque les distributions de couleurs sont très proches. Selon (Forsyth & Ponce, 2003), la texture est un phénomène très courant dans les images, facile à reconnaître, mais difficile à définir. Il en existe d’ailleurs plusieurs définitions différentes dans la littérature, entre autres, plusieurs occurrences d’un élément de base de l’image (souvent appelé texton), organisées d’une manière particulière, ou encore une structure périodique détectable avec des outils d’analyse fréquentielle tels que la transformée de Fourier ou la transformée en ondelettes. Dans ses travaux de thèse, Coggins (1982) fournit un récapitulatif des différentes définitions de la texture dans le domaine de la vision par ordinateur.

La texture peut être utilisée pour faire la différence entre deux objets de même radiométrie. Et parce que la texture est liée aux propriétés physiques des objets, il est possible d’identifier, au moins en partie, le contenu d’une région grâce à sa texture. En effet, la texture est caractérisée par des variations dans une image, généralement causées par une variation physique fondamentale dans la scène (comme par exemple, les vagues dans l’eau). La modélisation de cette variation physique étant très difficile, la texture est souvent caractérisée par les variations bidimensionnelles des intensités de l’image. La (figure 2.8) montre des exemples de textures dans les images satellitaires.



**Figure 2.8 : Exemples d’images texturées, extraites de scènes SPOT5:
(a) forêt, (b) ville, (c) mer et (d) champs.**

Dans la littérature, il existe plusieurs comparaisons expérimentales des algorithmes d'extraction de textures (Singh & Singh, 2002; Grigorescu et al., 2000). En exploitant les propriétés des textures, (Tuceryan & Jain, 1998) proposent une taxonomie des méthodes d'extraction de textures, et les classifient en géométriques, structurales, statistiques, basées sur les modèles et basées sur le traitement du signal. Par la suite, Randen & Husoy (1999) concluent que la plupart des travaux utilisent les trois dernières techniques.

La texture implique la distribution spatiale des niveaux de gris. L'utilisation des caractéristiques statistiques est par conséquent l'une des premières méthodes proposées dans la littérature. Parmi elles, on trouve les très populaires matrices de cooccurrence (Haralick et al., 1973), utilisées par exemple dans (Steinnocher et al., 2003) pour la dérivation d'un détecteur de zones urbaines, simple et efficace, et les caractéristiques d'autocorrélation. Par ailleurs, la fonction d'autocorrélation d'une image peut être utilisée pour évaluer la quantité de régularité ainsi que la finesse ou la grossièreté de la texture présente dans l'image. Plus simplement, les textures peuvent aussi être décrites par des histogrammes (Lowitz, 1983).

Plusieurs méthodes d'analyse de texture reposent sur les techniques de traitement du signal. Dans ces approches, l'image texturée est soumise à une transformation linéaire, un filtre ou un banc de filtres. Les méthodes basées sur la transformée de Fourier permettent d'extraire l'orientation locale et la périodicité, mais ne sont pas localisées, contrairement aux approches basées sur les ondelettes (Mallat, 1989), filtres de Gabor (Dunn & Higgins, 1995; Dunn et al., 1994), et filtres miroirs en quadrature (Quadrature Mirrors Filters ou QMF) (Mallat, 2003), qui tiennent compte de la localisation dans le domaine spatial.

Les méthodes d'analyse de texture, basées sur la construction d'un modèle de l'image, regroupent entre autres les champs de Markov (Markov Random Fields ou MRF) et la dimension fractale, très utilisés pour la classification des images de télédétection. Utilisés par Cross & Jain (1983), les champs de Markov sont capables de capturer l'information contextuelle locale (spatiale) dans une image. Ces modèles supposent que l'intensité de chaque pixel de l'image dépend uniquement de l'intensité des pixels de son voisinage. Les attributs issus de la modélisation de l'image par les champs de Gauss Markov (Gauss Markov Random Field ou GMRF) sont utilisés dans le système KIM (Datcu et al., 2003). La dimension fractale (Mandelbrot, 1983), quant à elle, est souvent utilisée pour mesurer la rugosité d'une surface : plus grande est la dimension fractale, plus rugueuse est la texture.

Par ailleurs, certains travaux font une utilisation jointe de la couleur et de la texture. Greenhill et al (2003) par exemple, proposent de calculer des caractéristiques de texture, non

pas sur les données d'intensité brutes, mais sur un canal radiométrique transformé, comme le NDVI par exemple. Cependant, dans leur étude comparative des algorithmes de classification des images naturelles de textures en couleurs, Maenpaa & Pietikainen (2004) montrent que la couleur et la texture sont des phénomènes séparés qui doivent être traités séparément.

2.4.3. Les descripteurs géométriques

En ce qui concerne les régions issues d'une segmentation ou d'un processus de classification, outre la couleur et la texture, les attributs géométriques sont très souvent utilisés. La géométrie est une caractéristique visuelle importante : elle fait partie des caractéristiques de base, nécessaires pour la description du contenu d'une image. Zhang & Lu (2004) et Loncaric (1998) proposent une analyse étendue des techniques de description de la géométrie. En effet, les auteurs les classifient en descripteurs basés sur les contours et ceux basés sur les régions. L'analyse est détaillée, depuis les caractéristiques simples comme la surface, l'excentricité, la compacité, les moments, l'orientation, etc, jusqu'aux caractéristiques structurales complexes basées sur une grammaire. En outre, certains travaux utilisent des modèles de forme pour améliorer les tâches de segmentation (Fua & Hanson, 1987). Ces modèles sont définis en utilisant une grammaire de primitives de l'image (bords, pixels, ...) et de relations (lignes, coin, jonction T, parallèle, ...). Les travaux de Aksoy et al (2005) rejoignent ce type de modélisation. Dans (Jibrini, 2002) se trouve une approche plus récente de grammaires de forme pour la reconnaissance de bâtiments dans les images aériennes. Peura & Iivarinen (1997) ont examiné l'efficacité de quelques descripteurs géométriques simples (convexité, rapport des axes principaux, ...) et affirment qu'en général, il n'est pas nécessaire d'utiliser des descripteurs géométriques complexes et longs à calculer. Par ailleurs, Pesaresi & Benediktsson (2001) proposent d'utiliser des caractéristiques morphologiques (appelées Differential Morphological Profiles ou DMP) pour décrire des objets et structures d'une image à haute résolution. Ainsi, un objet ou une structure de l'image pourrait être une région de pixels avec les mêmes caractéristiques morphologiques. Il est commun d'utiliser les opérateurs morphologiques d'ouverture et de fermeture pour isoler les structures claires et sombres de l'image. Une combinaison de ces deux opérateurs peut donc aboutir à la définition des attributs morphologiques. Shyu et al (2007) utilisent une extension des DMPs, basée sur une approche multi-échelle, pour encoder l'information sur la présence d'objets à différentes échelles spatiales (taille de l'élément structurant).

2.5. Conclusion

Dans ce chapitre, nous avons mis en avant l'intérêt d'utiliser les techniques de classification dans l'imagerie en télédétection. Nous avons vu en premier lieu que les images de télédétection se différencient selon leur contenu spatial, spectral et temporel. En deuxième lieu, nous avons présenté quelques opérations usuelles, des transformations et des analyses qu'on peut appliquer à une image de télédétection pour extraire l'information et faciliter sa classification. Nous avons ciblé en particulier les éléments qui nous permettent l'identification de la végétation pour construire des cartes d'occupation du sol des régions agricoles.

Chapitre 3 :

**Développement et validation
d'une procédure pour
automatiser la classification
par PNN**

3.1. Introduction

Dans ce chapitre, nous présentons notre méthodologie de classification qui est complètement automatique. Pour ce faire, on a besoin de trois techniques : la classification hiérarchique agglomérative pour le calcul des classes cibles, le réseau de neurones probabiliste (PNN) pour la classification suivant ces classes et une fonction pour optimiser le choix du nombre de classes dans un intervalle donné. Nous présentons en premier lieu ces techniques et nous décrivons le PNN en détail. En second lieu et pour décrire la méthodologie que nous allons poursuivre, nous donnons l'état de l'art sur l'automatisation de la classification basée sur les réseaux RBF, en général, et le PNN en particulier. Ensuite, nous présentons les différentes techniques qui étudient la répartition des classes. Enfin, nous détaillons la partie algorithmique de nos procédures développées sous MATLAB et décrivons les fonctions MATLAB utilisées dans la programmation. Le chapitre comprendra l'organigramme général de la procédure de classification, des sous-programmes et leurs codes algorithmiques.

Pour valider notre méthodologie automatique, elle est appliquée et testée sur des données, des images synthétiques et des images RGB réelles. Les résultats sont comparés avec ceux produits par FCM automatique.

3.2. Les techniques utilisées

3.2.1. Le réseau de neurones probabiliste (PNN)

Comme on l'a vu au chapitre 1, les réseaux de neurones sont souvent utilisés dans la classification d'une façon supervisée puisque les classes sont citées en avance dans la phase d'apprentissage. Zhang (2000) a montré que la classification est le thème de recherche le plus fréquenté par les réseaux de neurones et que cette technique donne des résultats prometteurs. Les plus utilisés pour des problèmes de classification sont les réseaux à fonction radiale (Radial Basic Functions : RBF) qui ont pour architecture celle des (Multiple Layer Perceptron : MLP) et pour fonction d'activation une gaussienne. Le réseau de neurones probabiliste (Probabilistic Neural Network : PNN) en fait partie. Proposé par Specht en 1988, PNN est présenté comme étant une implémentation de la règle de décision de Bayes sous forme d'un réseau de neurones, basée sur des classificateurs par maximum de vraisemblance (Specht, 1988 et 1990). Son architecture est illustrée dans la (Figure 3.1). Un PNN typique se compose d'une couche d'entrée (Input Layer), une couche de motifs ou classes cibles (Hidden Layer : couche cachée) et une couche de sortie (Output Layer).

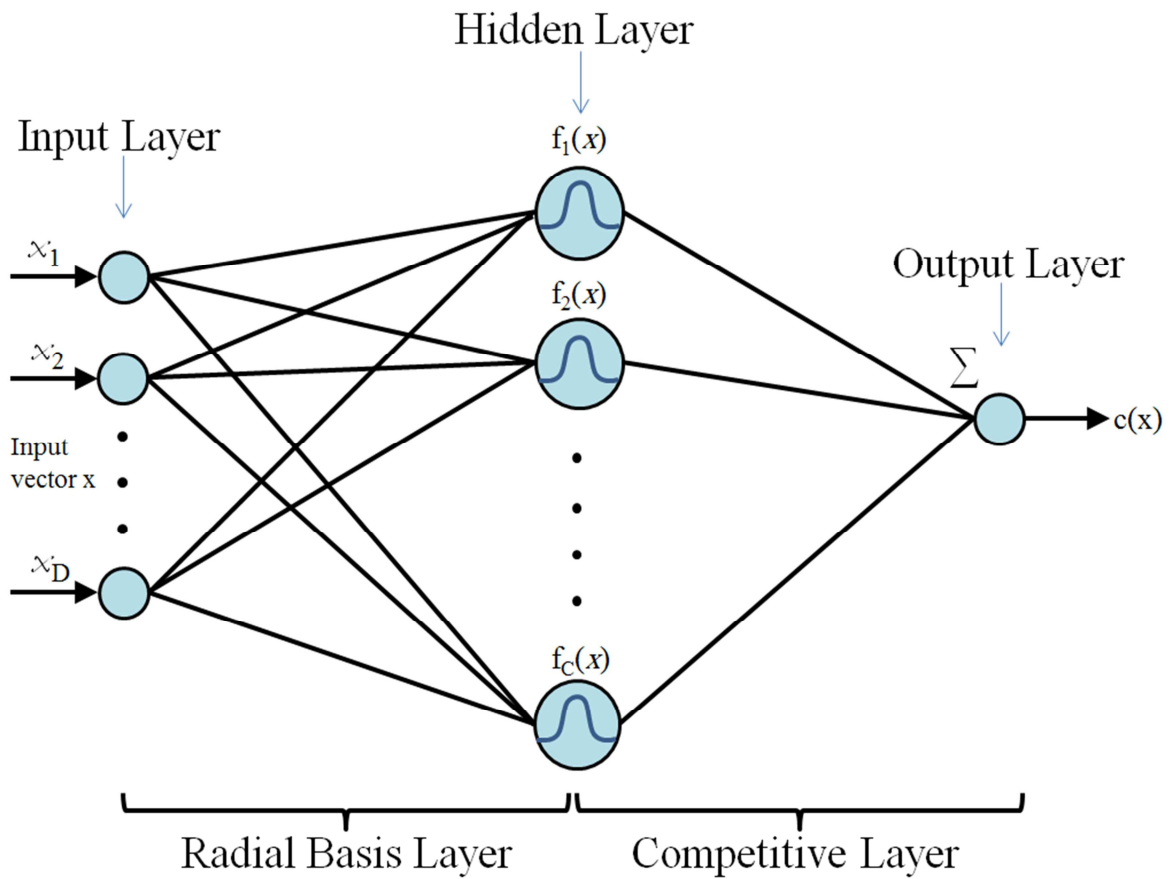


Figure 3.1 : Architecture de PNN.

Contrairement à d'autres réseaux de neurones, le PNN ne nécessite pas un calcul dans la phase d'apprentissage (Pas de processus itératif entre ses couches), l'apprentissage se fait directement et instantanément. Similaire aux réseaux RBFNN, le PNN reçoit à ses neurones d'entrée (*Input neurons*) un vecteur d'entrée $x = (x_1, \dots, x_D)$ qu'on veut classifier de dimension D . Ce vecteur est transmis aux neurones de la couche cachée (*Hidden layer neurons*). Ici, les nœuds cachés sont rassemblés en groupes, un groupe pour chacune des C classes. A chaque nœud caché dans le groupe de la $k^{\text{ème}}$ classe ($1 \leq k \leq C$) correspond une fonction gaussienne comme fonction d'activation centrée sur le vecteur constituant cette $k^{\text{ème}}$ classe. Ce qui fait apparaître la notion de probabilité à ce type de réseaux de neurones. Cette fonction est dite fonction de densité de probabilité (PDF : *Probability Density Function*). Elle est définie pour une classe cible ($k^{\text{ème}}$ classe) comme suit (Specht, 1988):

$$f_k(x) = \frac{1}{(2\pi)^{D/2} \sigma^D} e^{-\frac{\|x-c_k\|^2}{2\sigma^2}} \quad (3-1)$$

où, σ est le paramètre de lissage (variance standard), D la dimension du vecteur d'entrée x , et $\|x - c_k\| = \sqrt{\sum_i (x_i - c_{k,i})^2}$ la distance euclidienne entre x (le vecteur d'entrée) et c_k (le vecteur cible) de la $k^{\text{ème}}$ neurone (le vecteur cible). La fonction d'activation d'un PNN se caractérise par sa propagation $2sp = 2\sqrt{2 \ln 2} \sigma$ (sp pour spread : élargissement) qui présente la largeur de la gaussienne à mi-hauteur (*FWHM, full width at half maximum*) et son pic qui est toujours à son centre (Figure 3.2).

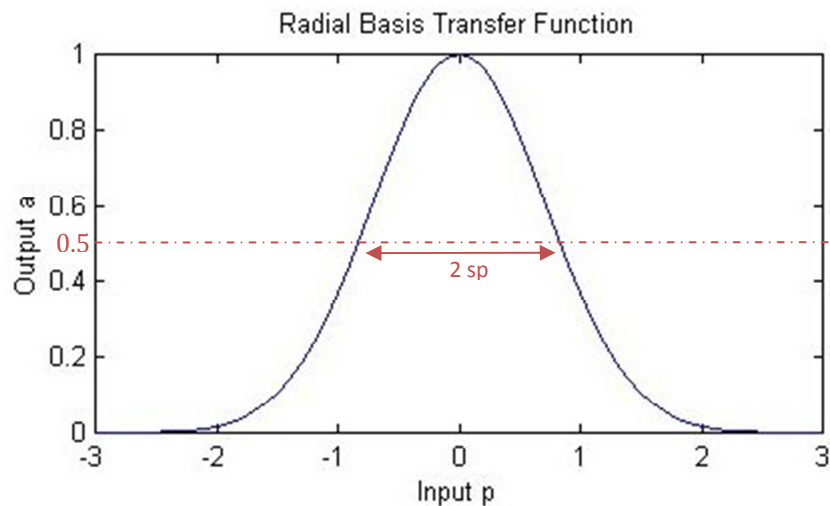


Figure 3.2 : Fonction gaussienne et son FWHM.

Lors de la sommation dans la couche de sortie, il y a risque d'influence mutuelle entre les points éloignés suite aux chevauchements. Donc, la largeur de la fonction d'activation doit être choisie en tenant compte la distance interclasse entre les vecteurs cibles. Pour éviter tout problème de chevauchement et ainsi une mauvaise classification, ce paramètre (sp) est choisi généralement égal au demi du minimum des distances interclasses.

La sommation pondérée des différentes fonctions de densité de probabilité autour des C classes produit un vecteur de probabilité de population s'écrivant sous la forme suivante :

$$p(x) = \frac{1}{(2\pi)^{D/2} \sigma^D C} \sum_{k=1}^C e^{-\frac{\|x - c_k\|^2}{2\sigma^2}} \quad (3-2)$$

Ce vecteur décrit le degré de vraisemblance d'une entrée x avec chaque vecteur cible c_k .

Finalement, une fonction de transfert compétitive donne la valeur 1 à la classe dont la densité de probabilité est maximale et une valeur 0 aux autres classes. Une entrée inconnue x correspond à la $k^{\text{ème}}$ classe si : $p_k(x) > p_{k'}(x)$ pour tout $k' \neq k$. Or, le neurone dans la dernière

couche de décision détermine la classe d'appartenance du motif x conformément à la décision de la règle de Bayes sous l'hypothèse suivante:

$$s(x) = \operatorname{argmax} \{p_k(x)\}, \quad k = \{1, 2, \dots, C\} \quad (3-3)$$

Dans la même optique, Wasserman (1993) voit qu'un PNN est fonctionnellement constitué de deux couches (Figure 3.1):

- La 1^{ère} couche « *Radial Basis Layer* » : Quand une entrée x_i est présentée, cette couche calcule les distances entre les vecteurs cibles qui représentent les classes définies et la formation des vecteurs d'entrée (l'image dans notre cas) et produit un vecteur dont les éléments indiquent la proximité de chaque classe à une entrée de cette formation. Ce vecteur est multiplié élément par élément par un biais et ensuite appliqué par une fonction de transfert à base radiale. Un vecteur d'entrée proche d'un vecteur cible est représenté par un nombre proche de 1 en sortie. La sortie est donc un vecteur de probabilité qui marque le degré d'appartenance de chaque classe à une entrée.
- La 2^{ème} couche « *Competitive Layer* » : cette couche somme ces contributions pour chaque classe pour produire comme résultat un vecteur de probabilité normalisé. Enfin, une fonction de transfert en concurrence sur la sortie de la deuxième couche capte le maximum de ces probabilités, et produit un 1 pour la classe associée à ce maximum et un 0 pour les autres.

3.2.2. La classification ascendante hiérarchique (CAH)

Décrite dans le chapitre 1, nous utilisons la CAH pour l'apprentissage du PNN. La distance euclidienne et le critère de Ward (Ward, 1963). sont utilisés respectivement comme indice de dissimilarité et critère d'agrégation. La CAH calcule les classes d'une façon non supervisée. Elle produit une hiérarchie (dendrogramme) qui est facile à exploiter car elle permet de récupérer aisément les classes selon leur nombre.

Nous utilisons la classification hiérarchique avec le critère Ward, car c'est le critère le plus utilisé. Il est aussi le plus performant comme le prouvent plusieurs études (Dillner et al., 2005; Picard et al., 2010; Carteron et al., 2012; Hands & Everitt, 1987) surtout quand les proportions des groupes constituant les classes sont égales. L'avantage de cette classification par rapport aux autres techniques non supervisées c'est qu'elle construit une hiérarchie et qu'elle est réalisée une seule fois pour plusieurs nombres de classes. Tandis que pour d'autres techniques comme k-means et FCM, nous aurons besoin de refaire la classification pour chaque nombre de classe C .

3.2.3. La fonction ou l'indice de validité des clusters

Lorsqu'on est confronté à un problème de classification non supervisée, on est amené à faire des suppositions sur le nombre de classes présentes dans l'ensemble des données. Cependant, on ne dispose pas toujours d'informations a priori sur la structure interne de ces données, ou encore, sur le nombre optimal de classes correspondant. Dans ce cas, l'utilisateur doit appliquer un algorithme de classification non supervisée avec les différentes valeurs de C qu'il estime plausibles (il est toujours possible de limiter le domaine des valeurs éventuelles que peut prendre ce paramètre), et de choisir la partition optimale correspondant à son problème. On est alors obligé de définir un critère, ou une fonction de validité, mesurant la performance de la classification pour choisir la partition optimale parmi toutes celles obtenues avec les différentes valeurs plausibles, et testées, du nombre de classes recherché.

Bien que cette étape de validation puisse manifestement paraître cruciale, le problème de la validité des partitions obtenues par des méthodes de classification non supervisées n'a toutefois été qu'assez rarement abordé. La difficulté provient du fait qu'il n'existe aucun critère universel qui puisse décider de ce qu'un algorithme donné soit adapté à un ensemble de données quelconque, et c'est souvent sur la base de constatations empiriques qu'on se fait une idée sur la distribution réelle des données traitées.

L'étude de la validité d'une répartition présente deux aspects :

- d'une part, il s'agit d'étudier l'existence ou non d'une structure quelconque au sein des données, c'est-à-dire, voir si les données sont distribuées d'une façon aléatoire ou peuvent être regroupées dans des groupes bien définis,
- il faudrait, d'autre part, étudier si les classes identifiées sont bien réelles, en ce sens qu'elles doivent être liées aux propriétés intrinsèques des données, et non pas être juste un artefact de calcul ou un pur produit de l'algorithme utilisé.

❖ Quelques indices de validité

Le problème de validation est spécialement très abordé dans la classification floue non supervisée, surtout la classification c -moyennes floues (FCM) et ses dérivées. Plusieurs études et recherches ont été déployées dans ce sens. Wang & Zhang (2007) ont décrit la majorité de ces études et ont présenté un panorama d'indices de validité des centroides flous résultant de la FCM. Or, le calcul de ces indices implique l'utilisation des valeurs d'appartenance de chaque élément (pixel) à une classe et ainsi l'utilisation de la matrice d'appartenance $U =$

$[u_{ij}]_{C \times N}$ avec C le nombre de classes et N le nombre d'individus (pixels). Pour ce faire, il faut respecter quelques conditions afin de garantir la séparabilité et la compacité des groupes qui résultent de la classification. Ces conditions sont :

- Les données doivent être classifiables et que les classes ne soient pas nulles :

$$0 < \sum_{j=1}^N u_{ij} < N, \quad i = 1, \dots, C \quad (3-4)$$

- La complémentarité des probabilités :

$$\sum_{i=1}^C u_{ij} = 1, \quad j = 1, \dots, N \quad (3-5)$$

- Les données présentent l'union des partitions :

$$\sum_{i=1}^C \sum_{j=1}^N u_{ij} = N \quad (3-6)$$

Une fonction de validité a pour but d'attribuer, à une partition donnée, un coefficient qui reflète la qualité de la classification obtenue à l'aide de l'algorithme utilisé. Dans le cas des FCM, par exemple, en évaluant cette fonction pour différents choix de valeurs de C et du degré flou m , on peut espérer identifier les valeurs optimales de ces deux paramètres qui correspondent à une partition reproduisant au mieux la structure des données traitées. Dans le cas général, une partition est d'autant meilleure que les éléments attribués à une classe donnée sont plus proches du centre de cette classe. Or, les degrés de similitude entre ces points et un centre quelconque sont mesurés par leurs degrés d'appartenance à la classe correspondant à ce centre. Si, pour un élément donné x_j , l'un des C degrés d'appartenance, u_{ij} , est très largement supérieur aux $(C - 1)$ autres degrés, alors ce point a toutes les chances d'être un bon représentant de la classe i correspondante. Si, au contraire, tous ses C degrés d'appartenance ont des valeurs voisines, alors la classe de ce point est indéterminée.

Différentes approches ont été proposées pour résumer dans un seul coefficient, pour un point x_j donné, et à partir de ses C degrés d'appartenance u_{ij} , la qualité de la classification pour ce point. Parmi ces coefficients, on peut citer :

La somme :

$$s_j = \sum_{i=1}^C (u_{ij})^m \quad (3-7)$$

L'entropie :

$$e_j = - \sum_{i=1}^C u_{ij} \cdot \log_a(u_{ij}) \quad (3-8)$$

Le maximum :

$$g_j = \max_i u_{ij} \quad (3-9)$$

Le rapport :

$$r_j = \frac{\min_i u_{ij}}{\max_i u_{ij}} \quad (3-10)$$

Une mesure globale, possible, de la validité de la partition est le coefficient de partition (en anglais, *partition coefficient*, ou PC) qui n'est autre que la moyenne, sur tous les vecteurs x_j , des quantités s_j (Bezdek^b, 1974) :

$$V_{PC} = \frac{1}{N} \sum_{j=1}^N \sum_{i=1}^C (u_{ij})^m \quad (3-11)$$

Les valeurs de l'indice V_{PC} pour chaque valeur de C sont dans l'intervalle $[1/C, 1]$ et le nombre optimal de clusters (C^*) est obtenu lorsque V_{PC} atteint sa valeur maximale en faisant varier le nombre de classe C dans un intervalle donné.

Une autre mesure globale, possible, est l'entropie moyenne de la partition (Bezdek, 1975) :

$$V_{PE} = -\frac{1}{N} \sum_{j=1}^N \sum_{i=1}^C u_{ij} \cdot \log_a(u_{ij}) \quad (3-12)$$

L'indice V_{PE} est une mesure scalaire de la quantité du flou dans une matrice U donnée. La plage de ses valeurs est dans l'intervalle $[0, \log_a C]$. Le nombre optimal de clusters (C^*) est obtenu lorsque V_{PE} atteint sa valeur minimale en faisant varier le nombre de classe C dans un intervalle donné.

Les deux indices V_{PC} et V_{PE} possèdent une évolution à tendance monotone suivant C . Une modification de l'indice V_{PC} a été proposée par (Dave, 1996) pour réduire cette monotonie et a été définie comme suit :

$$V_{MPC} = 1 - \frac{C}{C-1} (1 - V_{PC}) \quad (3-13)$$

$$V_{MPC} = (C \cdot \sum_{j=1}^N \sum_{i=1}^C (u_{ij})^m - N) / (N \cdot (C-1)) \quad (3-14)$$

Les valeurs de l'indice V_{MPC} pour chaque valeur de C sont dans l'intervalle $[0,1]$ et le nombre optimal de clusters (C^*) est obtenu lorsque V_{MPC} atteint sa valeur maximale en faisant varier le nombre de classe C dans un intervalle donné.

C'est à partir de cet indice de validité qu'on va construire un nouvel indice pour notre approche automatique utilisant PNN.

3.3. Description de la méthodologie proposée

Plusieurs études récentes (Wang et al., 2013; Huang et al., 2012; Gancheva et al., 2007; Timung & Mandal, 2013) utilisent PNN pour des problèmes de classification et montrent que cette méthode donne des résultats satisfaisants si les classes cibles initiales sont correctement définies. Dans cette optique, le fait de trouver les centres (classes) de la fonction à base radiale avec le nombre approprié est une étape importante pour réaliser une classification correcte. Ceci est prouvé par plusieurs raisons citées par Tsekouras & Tsimikas (2013) : Premièrement, l'activation de chaque nœud caché dépend exclusivement de la distance entre le centre et le vecteur d'entrée. Deuxièmement, dans la construction de neurone, la répartition des champs récepteurs des neurones de la couche compétitive est fortement liée à l'emplacement des centres respectifs. En troisième lieu, la structure cachée de données est révélée par ces centres (Fonction de densité de probabilités). Les centres affectent directement la sortie du réseau de neurones. Quatrièmement, l'estimation des largeurs des gaussiennes (fonctions d'activation) dépend directement de l'emplacement des centres. La performance de la classification dépend fortement de la sélection de valeurs appropriées de propagation. En effet, des petites valeurs de propagation donnent des fonctions de densité de probabilités très pointues alors que de trop grandes valeurs de propagation entraînent un lissage des détails. L'idée d'utiliser des algorithmes de clustering dans l'apprentissage des réseaux de neurone de type RBFNN a été proposée par plusieurs auteurs (Tsekouras & Tsimikas, 2013; González et al., 2002; Park et al., 2009; Pedrycz, 1998; Pedrycz et al., 2008; Park et al., 2011; Roh et al., 2010) (Staiano et al., 2006; Uykan et al., 2000). Pedrycz (1998) a appliqué la classification floue conditionnelle (la méthode FCM modifiée) dans l'espace d'entrée. Cette méthode a intégré les données de sortie en utilisant les clusters pondérés calculés comme information de retour dans le mécanisme d'entrée. Uykan et al. (2000) ont employé la méthode K-means et ont montré que l'impact principal sur le clustering entre l'entrée et la sortie est dû à la minimisation de la limite supérieure de la moyenne d'erreur quadratique du réseau. Staiano et al. (2006) ont utilisé la classification floue pour générer les clusters dans l'espace d'entrée et ont établi pour chaque cluster une relation d'entrée-sortie en utilisant des modèles locaux de régression linéaire. Tsekouras & Tsimikas (2013) ont proposé un algorithme qui sélectionne les valeurs optimales pour les centres des fonctions d'activation (les gaussiennes) de RBFNN. Cet algorithme utilise l'espace de sortie pour ajuster la partition d'entrée en combinant la

classification floue des entrées-sorties et l'optimisation par essais particuliers (PSO : Particle Swarm Optimization).

Basé sur l'état de l'art cité ci-dessus et sachant que l'algorithme du PNN suppose la fixation à priori des classes cibles par l'utilisateur. On est confronté à deux principales problématiques. La première est le choix de ces classes cibles d'une manière qu'elles présentent des groupes compacts et séparables des éléments de l'entrée (pixels de l'image). La seconde problématique réside dans la validation des suppositions sur le nombre de classes issues des données. Une méthodologie d'évaluation est proposée pour déterminer le nombre approprié de classes C^* et les valider. Cette méthodologie utilise la matrice de probabilités issue de la couche cachée du PNN pour calculer l'indice de validité des clusters V proposé pour PNN (voir section 3.3.2) en variant le nombre de classes C dans un intervalle donné $[C_{min} ; C_{max}]$. C_{min} et C_{max} représentent respectivement le nombre minimal et maximal possible de classes qu'un utilisateur fixe à priori. Ces deux paramètres sont donnés par l'utilisateur pour répondre à la tâche de classification comme moyen de compression de données sans affecter l'information qui s'y trouve et pour encadrer l'algorithme dans son temps d'exécution.

Notre processus proposé est résumé par les étapes suivantes :

- (1) Procéder par une classification agglomérative hiérarchique aux données d'entrée en utilisant le critère de Ward pour obtenir C classes.
- (2) Appliquer l'algorithme de PNN en utilisant les C classes obtenues dans l'étape 1 comme classes cibles dans la phase d'apprentissage du réseau.
- (3) Calculer V correspondant à la classification précédente. V requiert les valeurs de la matrice des probabilités produite à la sortie de la couche cachée du PNN.
- (4) Répéter l'étape 1 pour différents nombres de classes C . Le nombre de classes C est choisi à priori dans l'intervalle $[C_{min} ; C_{max}]$.
- (5) Utiliser le nombre approprié de classes (C^*) qui correspond à la valeur maximale de V .

Le schéma suivant (Figure 3.3) illustre la procédure d'automatisation :

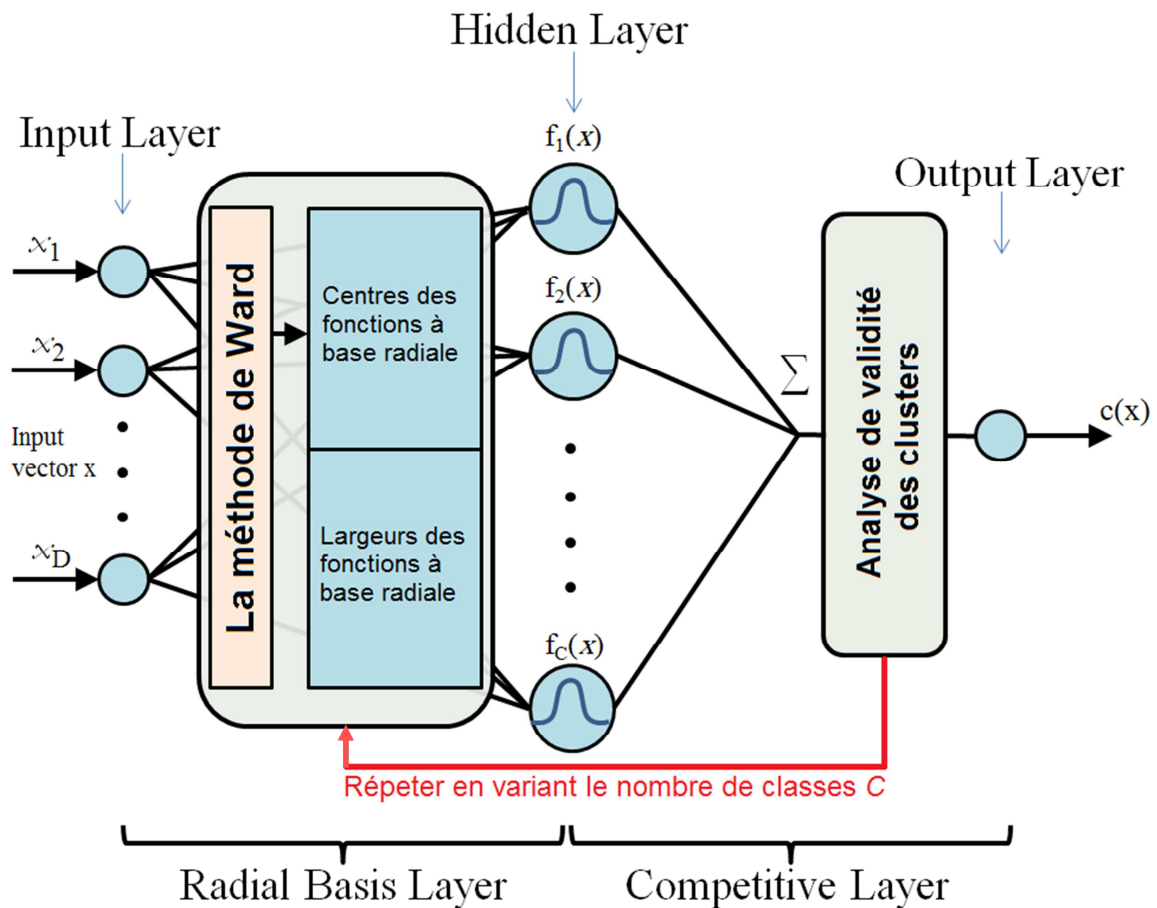


Figure 3.3 : La procédure d'automatisation.

3.3.1. Le calcul des classes

Pour l'apprentissage de la couche RBL (Radial Basis Layer), on estime les positions des C centres et des largeurs ($2sp$) à l'aide d'un algorithme non supervisé. Dans ce travail, on a utilisé, en premier lieu, une classification sur une image monospectrale (en niveau de gris) basée sur l'histogramme et, en deuxième lieu, la classification ascendante hiérarchique (CAH) pour une image multidimensionnelle.

❖ Segmentation utilisant l'histogramme

Proposée pour classifier une image monospectrale, cette approche procède par une répartition linéaire de l'étendue des valeurs des pixels sur C classes, en laissant une marge entre deux classes de $2sp$ et une marge de $1sp$ sur les extrémités des valeurs des nuances de gris des pixels (Figure 3.4).




Figure 3.4 : Répartition linéaire des niveaux de gris de l'image.

Pour éviter le chevauchement des classes lors de la sommation des fonctions d'activation du PNN, on a choisi une propagation radiale de $2sp = (max - min) / N$ avec max et min sont respectivement les extrémités supérieure et inférieure des luminances des pixels.

Pour s'approcher à des classes dominantes dans le vecteur d'entrée, on utilise l'histogramme de l'image pour déplacer chaque $i^{ème}$ classe des C classes sur l'intervalle $[i - sp, i + sp]$ en les remplaçant par les moyennes pondérées m_i des valeurs du vecteur d'entrée qui appartiennent à cet intervalle. Le poids des moyennes m_i est le nombre de pixels associés à chaque valeur de l'intervalle (figure 3.5).

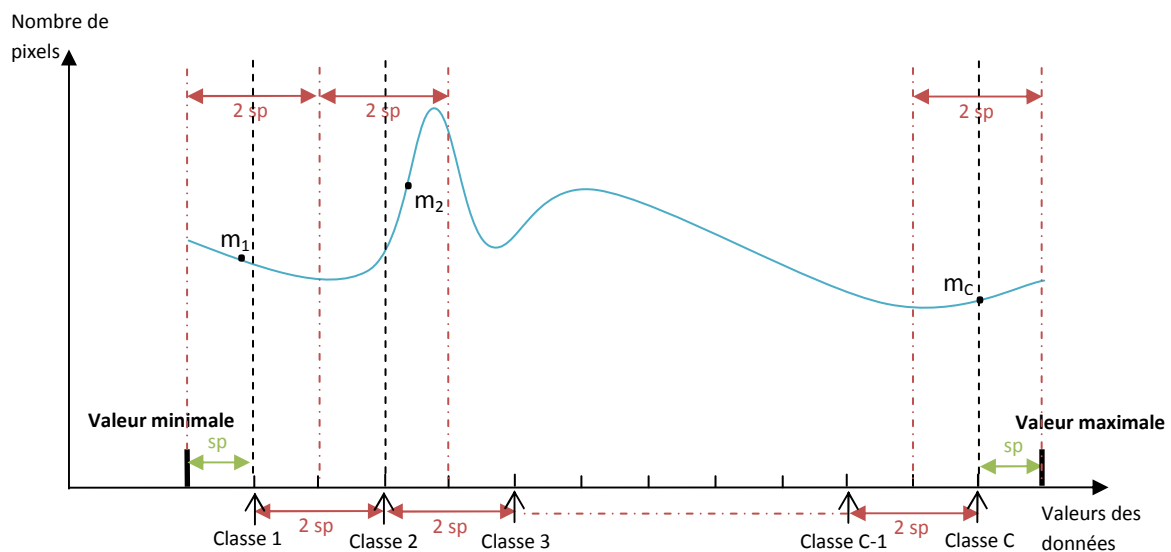


Figure 3.5 : Déplacement des classes en utilisant un exemple d'histogramme.

En utilisant cette approche, on satisfait d'une façon efficace les deux critères : la séparabilité et la compacité des classes. Mais, l'inconvénient demeure qu'elle ne peut pas être utilisée pour des données multidimensionnelles.

❖ Segmentation utilisant la CAH

On classe l'image utilisant la méthode non supervisée par CAH en utilisant la distance euclidienne et le critère de Ward. La partition en C classes s'effectue en coupant le dendrogramme produit par la CAH au niveau présentant C classes. En ce qui concerne la largeur des fonctions d'activation caractérisant chacune des classes cibles du PNN, et pour éviter leur chevauchement, on fixe pour chaque centre une largeur égale au demi du minimum de la distance qui le sépare des autres centres voisins.

3.3.2. L'indice de validité des classes V proposé pour PNN

L'indice V_{MPC} proposé pour la classification floue est en fonction de la matrice d'appartenance U , le nombre de classes C et le degré flou m (Dave, 1996). Or, la technique PNN ne s'appuie pas sur un regroupement flou, mais plutôt sur un classement compétitif des probabilités qu'elle produit (couche compétitive). Dans ce cas, pour calculer l'indice qui valide les résultats de cette technique suivant C , il faut utiliser le maximum des p_{ij} afin d'imiter la couche compétitive du PNN. Ce qui nous amène à remplacer le terme $(u_{ij})^m$ par $\max(u_{ij})$ dans l'expression de l'indice V_{MPC} (Dave, 1996). Ce qui donne un nouvel indice V sous la forme suivante :

$$V(C, U, N) = (C \cdot \sum_{j=1}^N \max_{i \in [1, C]} (u_{ij}) - N) / (N \cdot (C - 1)) \quad (3 - 15)$$

où N le nombre de vecteurs à classer, C le nombre de classes, U la matrice de probabilité issue de la couche cachée du PNN et $\max(p_{ij})$ la valeur maximale des p_{ij} associée à chaque pixel en balayant les C classes. Elle représente la classe la plus proche du pixel. Le nombre de classes optimal C^* est obtenu lorsque V atteint sa valeur maximale en variant le nombre de classes C dans un intervalle donné $[C_{min}, C_{max}]$. Les classes appropriées validées constitueront le vecteur des classes cibles dans l'apprentissage du PNN.

3.4. Programmation et déploiement des algorithmes

3.4.1. Petite vision sur MATLAB

MATLAB (« matrix laboratory ») est un langage de programmation de quatrième génération et un environnement de développement ; il est utilisé à des fins de calcul numérique. Développé par la société The MathWorks, MATLAB permet la manipulation de matrice, afficher des courbes et des données, mettre en œuvre des algorithmes, créer des interfaces utilisateurs, et peut s'interfacer avec d'autres langages comme le C, C++, Java, et Fortran. Les utilisateurs de MATLAB (environ un million en 2004) sont de milieux très différents comme l'ingénierie, les sciences et l'économie dans un contexte aussi bien industriel que pour la recherche. Matlab peut s'utiliser seul ou bien avec des toolbox (boîtes à outils). Le logiciel MATLAB est construit autour du langage MATLAB. Une interface en ligne de commande, qui est un des éléments du bureau MATLAB, permet d'exécuter des commandes simples. Des séquences de commandes peuvent être sauvegardées dans un fichier texte, typiquement avec l'éditeur MATLAB, sous la forme d'un « script » ou encapsulé dans une fonction. MATLAB est utilisé pour développer des solutions nécessitant une très grande puissance de calcul.

3.4.2. Schéma général de la procédure d'automatisation

En général, chaque phase de notre procédure d'automatisation est précédée par une préparation des éléments qui font interagir les sous programmes développés que ça soit les données ou les attributs utilisés par les fonctions MATLAB.

Après la préparation de ces éléments vient le déploiement d'une structure algorithmique suivant l'usage que nous voulons pour aboutir à un tel résultat avec un tel type et une telle taille. Et à la fin, on essaie de coller tous les sous programmes suivant le schéma général de la procédure. Notre procédure se divise en deux parties. On peut décrire la première partie selon le schéma suivant (Figure 3.6) :




Figure 3.6 : Calcul de l'indice de validité pour chaque nombre de classe C choisi.

En effet, c'est un travail en boucle tout en variant le nombre de classes C entre C_{min} et C_{max} . Tandis que la deuxième partie est une comparaison des indices de validité calculés. L'indice le plus grand V_{max} correspond au nombre optimal de classes. Ces classes optimales servent pour l'apprentissage du PNN. On peut schématiser cette partie (figure 3.7) comme suit :

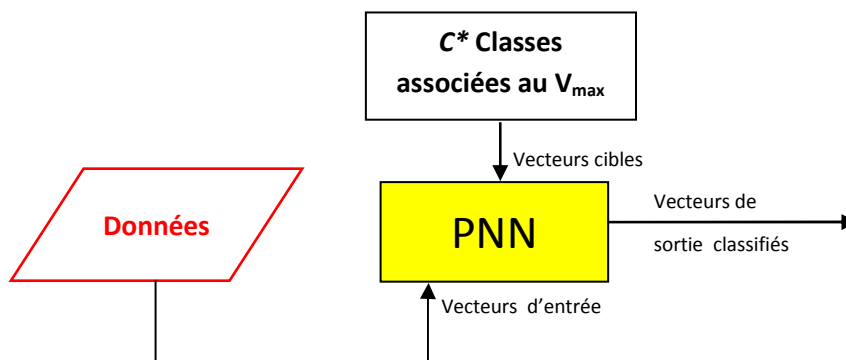


Figure 3.7 : Classification par les C^* classes qui présentent la meilleure répartition.

3.4.3. Les algorithmes développés et les techniques adoptées

❖ L'élimination des redondances

Pour le traitement de données aussi énormes comme les images, On est obligé de procéder par des techniques qui visent à améliorer l'exploitation de ces données et ainsi d'optimiser le temps de calcul pour des traitements tels que la classification. Or, dans ce but, on est amené à éliminer les répétitions inutiles sur les données d'images avant la classification. La commande Matlab « unique » permet d'exploiter les données sans redondances.

❖ Le calcul des classes

Comme il est cité précédemment, le calcul des classes est effectué soit en utilisant l'histogramme ou par une classification hiérarchique ascendante avec le critère de Ward.

Pour le cas utilisant l'histogramme et après le chargement de toutes les images multidimensionnelles, on utilise la commande « imhist » qui produit les vecteurs de l'histogramme qui seront utilisés pour une répartition linéaire en C classes et leur déplacement selon leur poids et les poids des valeurs de niveaux de couleurs qui les entourent tout en évitant le chevauchement.

Tandis que la classification hiérarchique ascendante est effectuée par la commande « clusterdata » avec l'option « linkage » sur « ward » en introduisant le nombre de classes à retenir.

❖ L'utilisation de la couche RBF et la classification PNN

Pour récupérer les sorties de la première couche « RBF » du PNN sous forme d'un vecteur de probabilités, on utilise la commande Matlab « newrbe ». Cette commande exige que les entrées soient sous forme d'un vecteur, ce qui nous amène à effectuer une sérialisation pour chacune des scènes à l'entrée. Pour ce faire, on utilise la commande Matlab « reshape » qui permet de transformer une matrice $M*N$ à un vecteur de $M*N$ éléments que ce soit selon les lignes ou les colonnes à condition d'effectuer une transformation inverse lors de la restitution de l'image classifiée.

La classification par PNN est effectuée par la commande Matlab « newpnn » qui exige aussi une sérialisation à l'entrée.

Un autre paramètre à fixer lors de la classification PNN est la largeur de la fonction radiale. Pour éviter tout chevauchement des fonctions produites par les classes, on fixe la

largeur de la fonction radiale du PNN « spread » au demi du minimum des distances qui séparent des classes voisines.

3.4.4. Quelques fonctions MATLAB utilisées

Commandes Matlab	Description
clusterdata : classification agglomérative <code>T = clusterdata(X, Name, Value)</code>	X : Matrice à classifier. Name = 'linkage', 'ward' : pour utiliser le critère de Ward. Value : Nombre de classes.
newrbe : construction de RBF <code>net = newrbe(P, T, spread)</code>	P : le vecteur des éléments d'entrée. T : le vecteur des classes. spread : la largeur de la fonction radiale.
newpnn : construction de PNN <code>net = newpnn(P, T, spread)</code>	P : le vecteur des éléments d'entrée. T : le vecteur des classes. spread : la largeur de la fonction radiale.
sim : simulation d'un réseau de neurones <code>Y = sim(net, P)</code>	net : le réseau de neurones construit. P : les entrées de réseau de neurones. Y : les sorties du réseau de neurones.
imhist : retourne le vecteur de l'histogramme <code>[counts, x] = imhist(I)</code>	I : l'image en niveaux de gris. [counts, x] : le compte de l'élément x.
unique : élimine les redondances <code>C = unique(A)</code>	C a les mêmes valeurs que A mais sans redondances.
reshape : changement de la taille d'une matrice. <code>B = reshape(A, M, N)</code>	Transformation de A en B de dimension M*N à condition que le nombre des éléments de A et B est identique.

3.5. Validation et comparaison

Pour valider notre méthodologie, Elle a été appliquée sur plusieurs données avec des différentes distributions de regroupements. Les tests sont effectués sur les données des iris de Fisher (Fisher, 1936), très utilisées pour tester les techniques de classification, sur des images synthétiques et autres réelles, soit en niveaux de gris ou des images RGB numériques (multicouches). Une étude comparative des résultats est effectuée entre les résultats de notre algorithme et ceux par la classification FCM automatisée utilisant le même principe de validation des classes.

3.5.1. Application sur les données des iris de Fisher

Les données des iris de Fisher ont été collectées par Anderson (1935). Ce sont des mesures en centimètres des variables suivantes : longueur du sépale, largeur du sépale,

longueur du pétale et largeur du pétale pour trois espèces d'Iris : Setosa, Versicolor et Virginica. Fisher a utilisé ces données pour construire des combinaisons linéaires des variables permettant de séparer au mieux les trois espèces d'iris (Fisher, 1936). Pour chaque espèce, 50 observations de ces mesures ont été enregistrées. Pour voir la structure des données des iris de Fisher, la figure 3.8 montre le graphique des nuages de points correspondant à ces données. A partir de cette figure, il est bien clair que le regroupement des Setosa est bien distinct tandis que les deux regroupements des Versicolor et Virginica sont collés, croisés et difficile à classifier.

On applique notre méthodologie et celle utilisant FCM pour trouver le nombre de classes optimal qui est $C^*=3$ et calculer leur précision de classification. On choisit un nombre de classes C qui varie dans l'intervalle $[C_{min}=2, C_{max}=6]$ pour calculer les indices de validité des classes pour chaque méthode. Les résultats des indices de validité de classes selon C sont donnés dans le tableau 3.1.

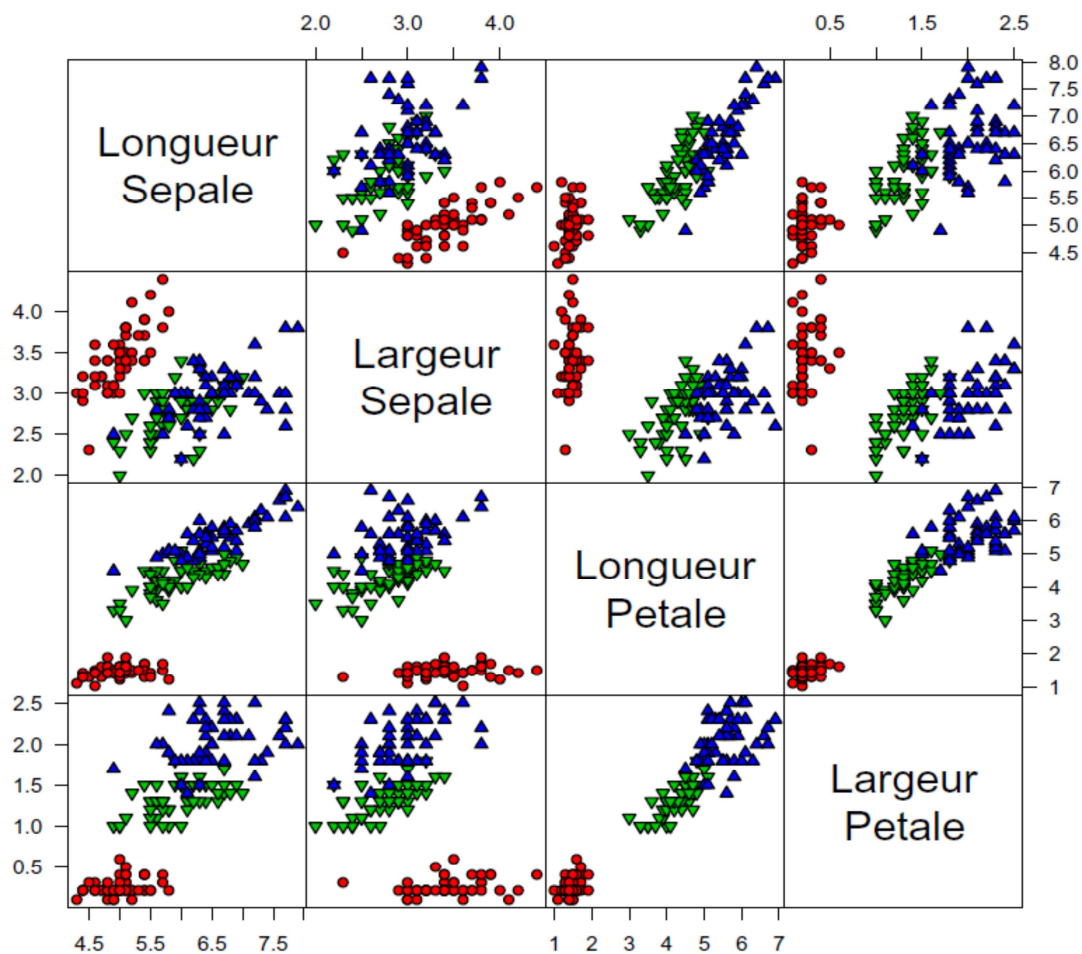


Figure 3.8 : Le graphique des nuages de points selon les mesures sur des espèces d'iris : Setosa en rouge, Versicolor en vert et Virginica en bleu.

Tableau 3.1. Variabilité de l'indice de validité des classes selon le nombre de classes C pour les données des iris de Fisher.

C classes	2	3	4	5	6
Indice V (PNN)	0,681	0,697	0,591	0,605	0,628
Indice V_{MPC} (FCM)	0,663	0,675	0,609	0,531	0,528

Les deux techniques ont donné le nombre exact de classes, mais la différence réside dans la précision de la classification. Le tableau 3.2 montre le nombre des espèces détecté correctement et la précision de l'identification.

Tableau 3.2. Les espèces détectées correctement et la précision de la classification pour chaque méthode.

Methodes	Setosa	Versicolor	Virginica	Précision
PNN automatique	50	48	36	89,33 %
FCM automatique	50	47	33	86,66 %

Dans cet exemple et pour plusieurs cas, notre algorithme fournit des résultats plus précis avec un taux d'erreur infime par rapport à la méthode FCM. Ceci montre la qualité d'utiliser le réseau des neurones probabiliste dans les problèmes de classification.

3.5.2. Application sur des images en niveaux de gris

Nous travaillons sur deux types d'images en niveaux de gris. La première est synthétique et la deuxième est réelle. Le but est de valider notre méthode automatique par PNN pour ce type de donnée et de tester sa performance en comparaison avec la méthode par FCM (Iounousse et al., 2012).

❖ Test sur une image synthétique

L'image synthétique choisie présente un gradient de huit niveaux de gris avec une distribution uniforme des couleurs (figure 3.9). Comme le nombre de classes adéquat est connu $C^*=8$, on teste notre algorithme s'il est possible de détecter les huit classes et on compare avec la procédure par FCM.

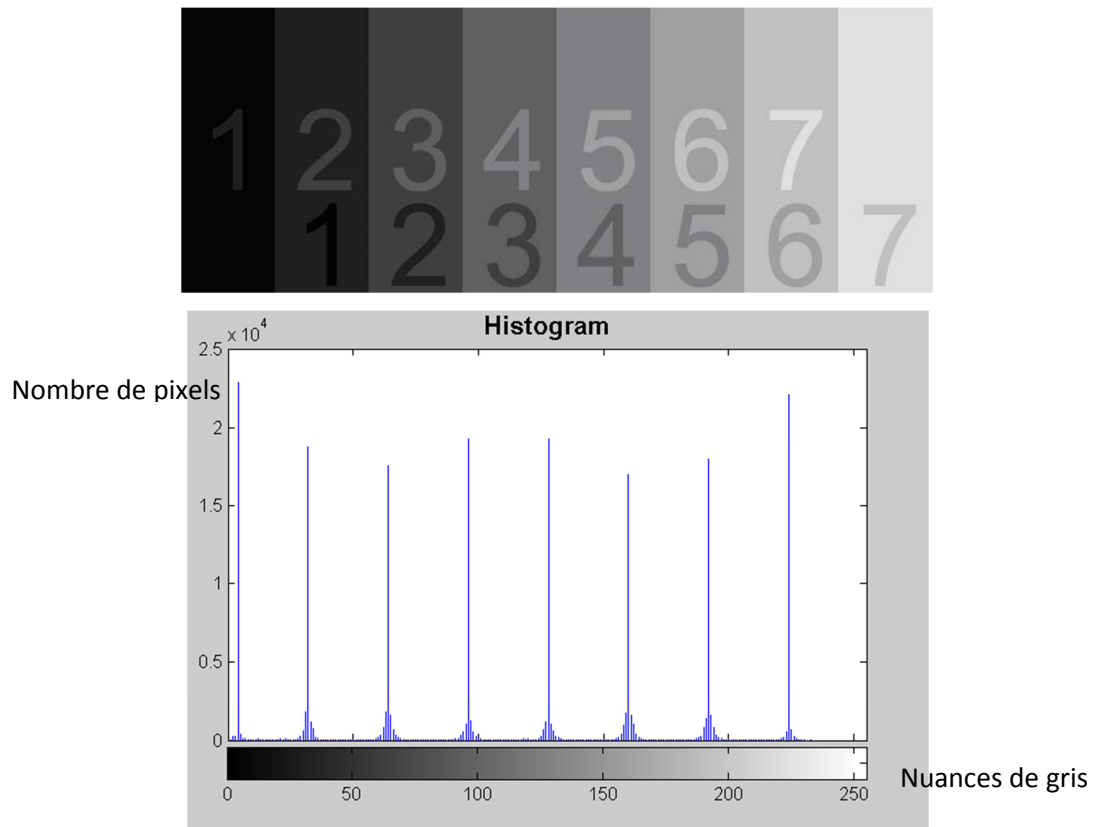


Figure 3.9 : Exemple d'image synthétique en niveaux de gris et son histogramme.

On choisit [$C_{min}= 3, C_{max}= 8$] comme intervalle sur le nombre de classes C possible. Les résultats du calcul de l'indice de validité de ces classes sont présentés dans le tableau 3.3. L'indice de validité maximal (0.969) correspond à 8 classes pour notre méthode tandis que, pour la méthode par FCM, $\max(V_{MPC}) = 0.894$ est associé à une classification en 7 classes. L'image classifiée par les deux techniques est illustrée dans la figure 3.10.

Tableau 3.3. Variabilité de l'indice de validité selon le nombre de classes C pour l'image synthétique en niveaux de gris.

C classes	3	4	5	6	7	8
Indice V (PNN)	0,721	0,752	0,741	0,734	0,844	0,969
Indice V_{MPC} (FCM)	0,706	0,728	0,701	0,785	0,894	0,878



Figure 3.10 : Image classifiée par : (a) PNN automatisé, (b) FCM automatisé.

La comparaison montre que notre algorithme arrive à trouver le nombre de classes optimal C^* à l'inverse de la méthode FCM.

❖ Test sur une image réelle

On teste notre méthode sur une image réelle en niveaux de gris (figure 3.11) qui présente un carrelage marocain (Zellij) avec une distribution de couleurs avec de différentes largeurs de propagation comme le montre son histogramme (figure 3.12) ce qui la rend difficile à classifier. L'objectif est de trouver les 3 classes présentes dans l'image et ainsi tester le pouvoir de notre méthode dans la discrimination par rapport à FCM.

Pour ce faire, on choisit le nombre de classe C dans l'intervalle [$C_{min}=2$, $C_{max}=8$]. Le tableau 3.4 montre les résultats concernant l'indice de validité de ces classes.




Figure 3.11 : Exemple d'image réelle de carrelage en niveaux de gris.




Figure 3.12 : L'histogramme de l'exemple d'image réelle de carrelage en niveaux de gris.

Tableau 3.4. Variabilité de l'indice de validité selon le nombre de classes C pour l'image réelle de carrelage en niveaux de gris.

C classes	2	3	4	5	6	7	8
Indice V (PNN)	0,738	0,823	0,658	0,609	0,583	0,515	0,479
Indice V_{MPC} (FCM)	0,768	0,807	0,816	0,696	0,661	0,649	0,635

En utilisant la méthode proposée, le nombre de classes optimal trouvé est $C^* = 3$ tandis que la technique par FCM a détecté 4 classes. La figure 3.13 illustre le résultat de la classification automatique par les deux méthodes.




Figure 3.13 : Image de carrelage classifiée par : (a) PNN automatisé, (b) FCM automatisé.

Ce cas montre que notre algorithme a pu distinguer les classes présentes dans l'image tandis que l'utilisation de la FCM a trouvé une difficulté pour déterminer le nombre de classe adéquat.

3.5.3. Application sur des images RVB numériques

Dans cette partie, on teste notre procédure et celle par FCM sur deux images RVB à trois couches radiométriques (Rouge, Vert, Bleu).

En ce qui concerne notre méthodologie et pour automatiser la classification des images multicouches, il y a deux façons pour le faire :

- La première est de classifier l'image, telle qu'elle est, dans le sens de l'espace utilisé suivant les scènes de l'image (l'espace peut être radiométrique, temporel ou les deux à la fois).
- La deuxième manière consiste à réaliser une classification spatiale pour chacune des scènes de l'image dans le but de réduire le nombre de niveaux de couleurs dans chaque scène (compression) et de les classifier après dans l'espace utilisé (c.à.d. selon le temps ou selon la fréquence radiométrique).

Les deux façons produisent approximativement les mêmes résultats, mais la différence réside dans le temps des calculs. En procédant par la deuxième manière, on gagne plus dans le temps des calculs. Elle nous donne aussi la possibilité de choisir entre les deux méthodes, que nous avons proposées pour le calcul des classes servant à l'apprentissage de PNN (section 3.2.1.), pour la classification spatiale.

Dans tous les travaux qui suivent et pour une classification d'une image multicouche, on utilise la deuxième manière, et la méthode utilisant l'histogramme pour l'étape de la classification spatiale. La classification dans l'espace des scènes de l'image s'effectue par la CAH utilisant le critère d'agrégation de Ward.

❖ Test sur une image RVB à couleurs limitées

Le test est effectué sur une image numérique de zelij marocain fassi composé de 5 couleurs différentes (figure 3.14) avec des regroupements de couleurs distincts d'après son histogramme 3D. On choisit, dans l'intervalle [$C_{min}=3$, $C_{max}=8$], les suppositions sur le nombre de classes C . Les résultats des indices de validité obtenus par notre méthode et par FCM sont présentés dans le tableau 3.5.

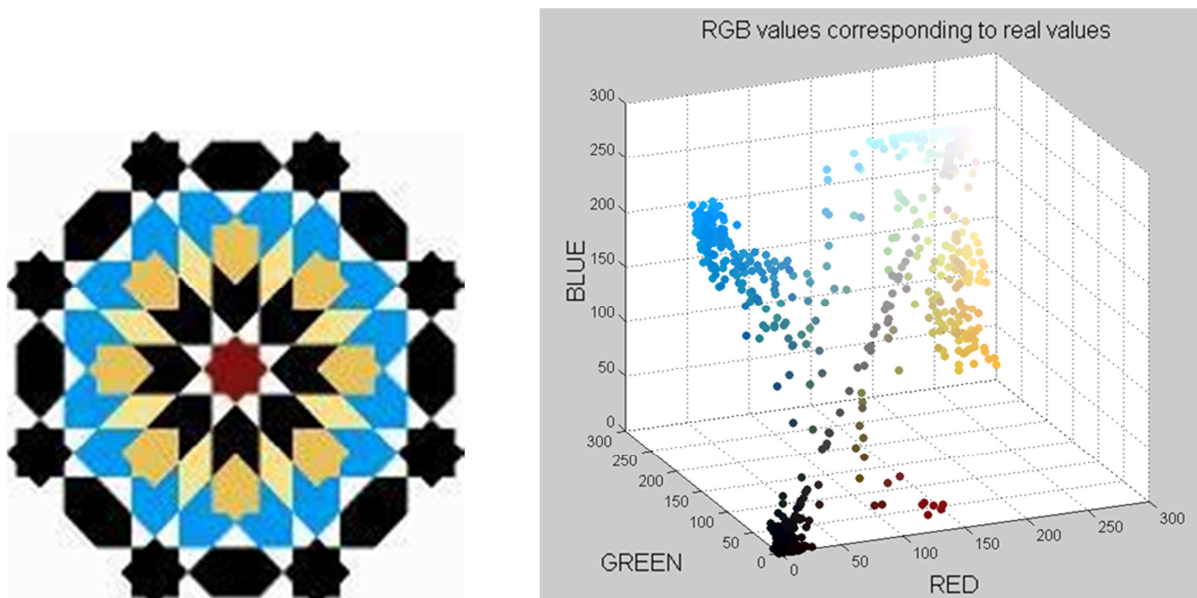


Figure 3.14 : Exemple d'image RVB de zelij à couleurs limitées et son histogramme 3D.

Tableau 3.5. Variabilité de l'indice de validité selon le nombre de classes C pour l'image RVB à couleurs limitées.

C classes	3	4	5	6	7	8
Indice V (PNN)	0,878	0,881	0,882	0,792	0,753	0,777
Indice V_{MPC} (FCM)	0,810	0,844	0,829	0,812	0,799	0,791

Dans cet exemple aussi, notre algorithme a pu trouver le nombre de classes exact $C^*=5$ à l'inverse de la FCM automatisée qui n'a trouvé que 4 classes, car elle a fusionnée les pixels marrons et les noirs qui forment les regroupements de couleurs les plus voisins dans l'image. La classification résultante de cet exemple est sur la figure 3.15.




Figure 3.15 : Image de zelij classifiée par : (a) PNN automatisé, (b) FCM automatisée.

❖ Test sur une image RVB réelle

Dans cet exemple, on ne dispose pas d'informations à priori sur la structure interne des couleurs de l'image et sur le nombre optimal de classes correspondant. L'image (figure 3.16) présente une scène réelle dans la nature se composant d'objets hétérogènes, mais discriminables. Le but de ce test est d'identifier les objets présents dans l'image. On procède par une analyse des classes obtenues pour juger.

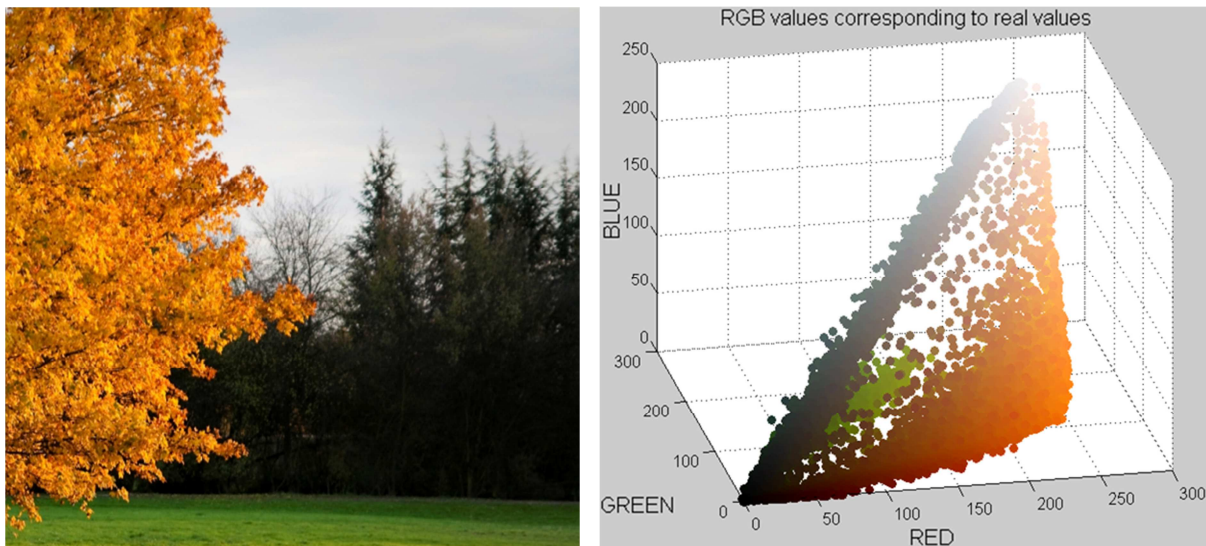


Figure 3.16 : Exemple d'image RVB réelle et son histogramme 3D.

Le nombre de classes C choisi varie dans l'intervalle $[C_{min}=3, C_{max}=10]$. Les indices de validité calculés pour les deux méthodes sont dans le tableau 6 et les images classifiées sont dans la figure 3.17.

Tableau 3.6. Variabilité de l'indice de validité selon le nombre de classes C pour une image RVB réelle

C classes	3	4	5	6	7	8	9	10
Indice V (PNN)	0,801	0,787	0,770	0,801	0,821	0,831	0,799	0,800
Indice V_{MPC} (FCM)	0,755	0,699	0,698	0,674	0,670	0,648	0,649	0,644




Figure 3.17 : Image RVB classifiée par : (a) PNN automatisé, (b) FCM automatique.

En utilisant notre algorithme, on obtient $C^* = 8$. Si on analyse ces huit classes, on trouve qu'elles représentent les objets suivants : (1) Le ciel, (2) le gazon, (3) le gazon ombré, (4) les sapins, (5) l'ombre des sapins, (6) les feuilles jaunes de l'arbre à gauche, (7) l'ombre des feuilles jaunes et (8) les branches de l'arbre à gauche.

La classification obtenue par FCM est grossière et ne présente que 3 classes. Cette technique a détecté un nombre de classes $C^* = 3$ loin de la réalité et elle n'a pas pu dépaqueter les couleurs présentes dans l'image et ressortir ses détails.

Ce test a montré la performance de notre méthodologie dans la discrimination des classes constituant l'image tout en utilisant que la propriété couleur.

3.6. Conclusion

Dans ce chapitre, nous avons mis en place une méthodologie de classification complètement automatique en se basant sur plusieurs techniques, telles que PNN pour la classification avec un apprentissage par des classes cibles obtenues en utilisant la classification hiérarchique agglomérative sous le critère de Ward. Nous avons aussi proposé une fonction de validité des classes pour optimiser la classification en se basant sur la matrice de probabilités que PNN délivre.

Cette procédure que nous avons déployée, est testée sur plusieurs types de données. Les résultats ont été comparés avec ceux obtenus par la méthode FCM utilisant le même principe d'automatisation. On a montré que les résultats sur plusieurs exemples et types de données sont meilleurs que ceux obtenus par FCM, que ce soit dans la détermination du nombre adéquat de classes ou dans la précision totale de la classification. Nous avons aussi développé des outils afin d'adapter notre technique avec tous les types de données et particulièrement les images multidimensionnelles (multicouches). En effet, les tests sur des images RVB à trois couches ont donné les mêmes résultats précédents au niveau de la comparaison et de la performance. A cet effet, les résultats de ces tests nous ont permis de montrer l'efficacité de notre algorithme et sa capacité d'être appliquée pour des images multicouches, telles que les images de télédétection. L'utilisation de notre procédure sur des images multidimensionnelles fera l'objet du chapitre suivant dans le but d'extraire les profils de végétation et dresser des cartes d'occupation du sol.

Chapitre 4 :

**Application de la procédure
proposée sur une série
multitemporelle d'images
satellites pour
l'identification de la végétation**

4.1. Introduction

Ce chapitre présente une application de notre méthodologie développée de classification automatique sur une série multitemporelle d'images satellitaires de la zone irriguée de Sidi Rahal, dans la plaine Haouz à 40 km de la ville de Marrakech. L'objectif est de réaliser une carte portant sur l'occupation du sol en analysant l'évolution temporelle des scènes NDVI.

Pour atteindre cet objectif sur des images multitemporelles, on procède par deux classifications : la première est spatiale pour classifier, une par une, les scènes de NDVI appartenant à des dates différentes d'une année de culture, la deuxième est temporelle pour extraire les profils de végétation en classifiant l'évolution du NDVI pendant la période représentant ces dates.

En fait, le chapitre présente en premier lieu les premiers travaux sur ces images qui ont été effectués utilisant l'analyse de l'histogramme pour la classification spatiale des scènes NDVI une par une. Tandis que la classification temporelle a été réalisée en utilisant :

- Un modèle déjà étudié pour la région qui définit des critères sur les profils NDVI en se basant sur les résultats des années précédentes (Simonneaux et al., 2008).
- Une classification supervisée par des profils NDVI proposés en se basant sur des parcelles de la région identifiées par échantillonnage sur terrain.

Ces travaux constituent un supplément des séries de tests présentées dans le chapitre précédent et présentent une comparaison qualitative entre les classifications par PNN et par FCM. En deuxième lieu et après avoir trouvé une manière pour classifier les images multicouches, on a pu effectuer la classification temporelle automatiquement. Ce qui va nous conduire à dessiner des cartes d'occupation du sol de la région et comparer nos résultats avec ceux produits par les méthodes automatiques usuelles (FCM et k-means).

Pour donner une vue sur l'intérêt de la classification effectuée (c.à.d. l'occupation du sol) dans la gestion des eaux d'une région semi-aride, une partie à la fin présente l'estimation du flux d'évapotranspiration dans la zone selon les types de végétation trouvés.

4.2. Matériels

4.2.1. La zone d'étude

La région d'intérêt : la région de Sidi Rahal est une zone irriguée située en plaine du Haouz (Figure 4.1) dans le centre du bassin de Tensift (Maroc central) à 40 km vers l'est de la ville de Marrakech. Le climat est de type méditerranéen semi-aride avec une moyenne de précipitations annuelles de 250 mm dont 70% tombent de novembre à avril. Ce secteur irrigué

a été intensivement étudié au cours des saisons agricoles 2002-2006 (Hadria et al., 2006; Duchemin et al., 2006; Er-Raki et al., 2007; Duchemin et al., 2008; Simonneaux et al., 2008) et jusqu'à récemment (Belaqziz et al., 2013; Le Page et al., 2014). Ce périmètre couvrant une superficie plate de 2800 ha (figure 4.1) est essentiellement utilisé pour la production de céréales. On y cultive majoritairement du blé, sur plus de la moitié de la surface (1550 ha en 2002-2003), ainsi que des oliviers (dans la partie nord-ouest) et des cultures maraîchères (dans la partie sud). Une partie non négligeable, un quart à un tiers selon les années, est laissée en jachère ou non cultivée. Les céréales sont semées entre novembre et janvier, atteignent leur maximum de développement fin mars, et sont récoltées en fin mai – début juin.

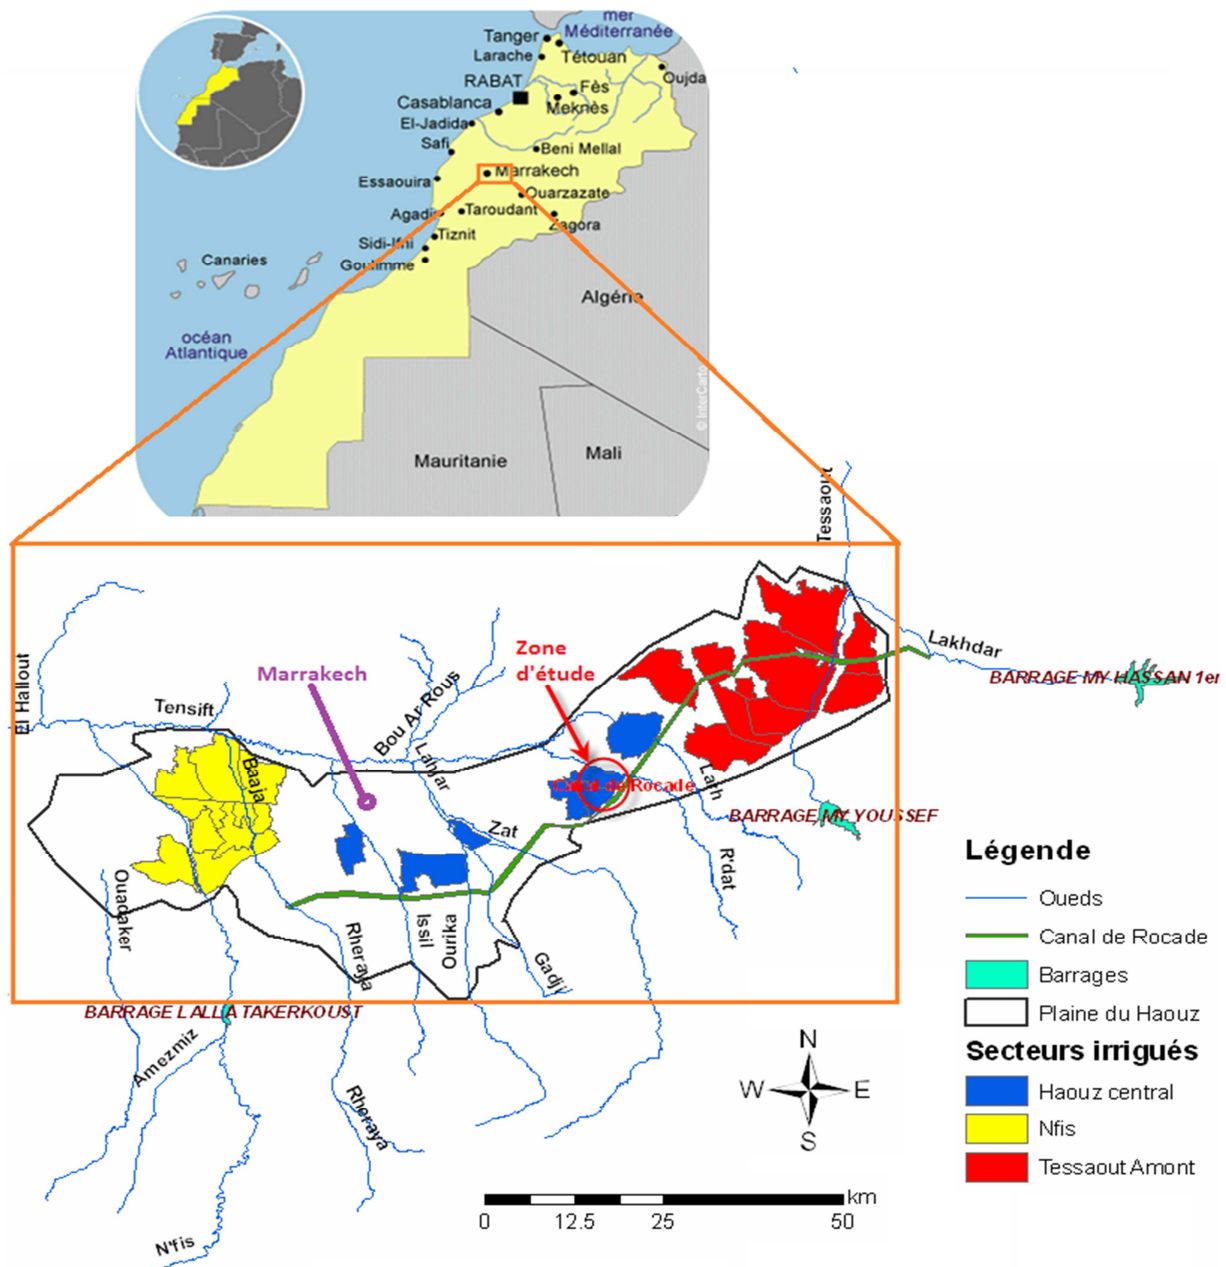


Figure 4.1 : La zone d'étude et les principaux secteurs irrigués, barrages et ressources en eaux gérés par l'ORMVAH, la plaine du Tensift est délimitée en noir.

Cette zone est gérée conjointement par des associations d'agriculteurs et un centre local de l'ORMVAH (Office Régional de Mise en Valeur Agricole du Haouz), notamment en termes d'irrigation. En début de saison, ils décident du nombre de tour d'eau et des quantités attribuées pour l'irrigation des cultures céréalières. Si le taux de remplissage des barrages le permet, il est procédé jusqu'à 5 tours d'eau pour le blé (décembre-mai), avec des quantités fixes d'un tour à l'autre à l'échelle du secteur. Pour la saison 2002-2003, les quantités d'eau étaient égales à 30 mm par tour d'eau. A chaque tour, les agriculteurs reçoivent un volume en fonction de la superficie des exploitations, même si certaines zones sont inexploitées. Cette organisation (figure 4.2) engendre une grande hétérogénéité spatiale et temporelle des volumes d'eau d'irrigation à l'échelle de la parcelle. Plus de détails sur la description du site et les données expérimentales sont données dans (Duchemin et al., 2006; Er-Raki et al., 2007).




Figure 4.2 : Organisation de la zone irriguée de Sidi Rahal.

4.2.2. Les données satellitaires

Une série temporelle d'images Landsat ETM+ est collectée durant la saison agricole du blé (Novembre 2002- Juin 2003). En raison de la nébulosité des images et l'incertitude dans

les corrections atmosphériques, seulement sept images ont été utilisées dans cette étude (Figure 4.3).

Ces images ont été étalonnées radiométriquement et corrigées atmosphériquement en fonction de la réflectance des objets invariants et transformées en cartes NDVI (Simonneaux et al., 2008). Ces scènes NDVI ont été dérivées à partir des bandes de réflectances rouge et proche infrarouge comme suit :

$$NDVI = (NIR - RED) / (NIR + RED) \quad (4-1)$$

Où *NIR* et *RED* représentent respectivement les valeurs de réflectance mesurées dans le canal proche infrarouge et le canal rouge des images Landsat ETM+.




Figure 4.3 : La série temporelle de 7 scènes NDVI d'images Landsat ETM+.

4.3. Les premiers travaux de classification

Dans nos premiers travaux, nous avons effectué une classification spatiale non supervisée sur chaque scène des sept scènes NDVI, tandis que la classification temporelle est réalisée suivant deux modèles : le premier modèle décrit l'évolution temporelle du NDVI selon des critères proposés par (Simonneaux et al., 2008) et un deuxième modèle que nous avons proposé par apprentissage supervisé du PNN.

Cette partie a pour but de comparer notre méthodologie d'automatisation avec celle définie pour la technique FCM sur des images satellitaires et avoir aussi une idée sur la quantité d'information qu'on peut perdre en les utilisant pour la classification spatiale. Cela

nous donne une idée finale et une preuve supplémentaire sur la performance de notre procédure.

4.3.1. La classification spatiale non supervisée des scènes NDVI

On applique les deux techniques sur chaque scène NDVI pour différents nombres de classes C dans l'intervalle [$C_{min} = 5$, $C_{max} = 15$]. On a choisi un nombre minimal de classes 5 en tenant compte la minimale diversité du sol dans la zone d'étude : sol nu, céréales, arbres, arbres avec herbes, en jachère, ...etc. Tandis que $C_{max} = 15$ pour une unique raison, c'est de nous permettre de garder la majorité des détails, spécialement dans les scènes présentant une multitude de niveaux dans la plage de NDVI. Le tableau 4.1 montre la variabilité de l'indice de validité des classes V selon le nombre de classes C et le tableau 4.2 présente l'effet de la classification spatiale sur le nombre de niveaux NDVI dans chaque scène.

Tableau 4.1 Variabilité de l'indice de validité selon le nombre de classes C pour chaque scène NDVI.

		Nombre de classes										
		5	6	7	8	9	10	11	12	13	14	15
Indice de validité des classes V	7 Nov	0.882	0.772	0.705	0.673	0.709	0.771	0.711	0.724	0.684	0.677	0.659
	25 Déc	0.755	0.670	0.671	0.656	0.664	0.696	0.663	0.668	0.677	0.710	0.694
	26 Jan	0.693	0.632	0.684	0.695	0.707	0.717	0.711	0.712	0.721	0.713	0.698
	11 Fèv	0.710	0.646	0.666	0.693	0.699	0.708	0.714	0.705	0.695	0.706	0.695
	31 Mars	0.656	0.682	0.683	0.702	0.707	0.716	0.711	0.714	0.721	0.711	0.714
	18 Mai	0.630	0.648	0.669	0.663	0.667	0.698	0.670	0.689	0.683	0.716	0.715
	27 Juin	0.853	0.690	0.650	0.705	0.700	0.696	0.685	0.690	0.690	0.667	0.721

Tableau 4.2 Effet de la classification spatiale sur le nombre de niveaux NDVI.

	Scènes NDVI						
	7 Nov 02	25 Déc 02	26 Jan 03	11 Fèv 03	31 Mars 03	18 Mai 03	27 Juin 03
Nombre de niveaux dans la scène NDVI d'origine	73	75	77	75	82	77	87
Nombre de niveaux après classification	5	5	13	11	13	14	5

D'après le tableau 4.2, le nombre optimal de classes après la classification spatiale change d'une scène à l'autre. En analysant les histogrammes des sept scènes (Figure 4.4), on trouve que ce sont les scènes avec un histogramme étroit (7 Nov. 2002, 25 Déc. 2002 et 27 Juin 2003) qui ont pris le nombre minimal de classes $C^* = C_{min} = 5$ alors que les scènes qui

ont un histogramme large (26 Jan. 2003, 11 Fév. 2003, 31 Mars 2003 et 18 Mai 2003) ont eu un nombre de classes supérieur à 10.

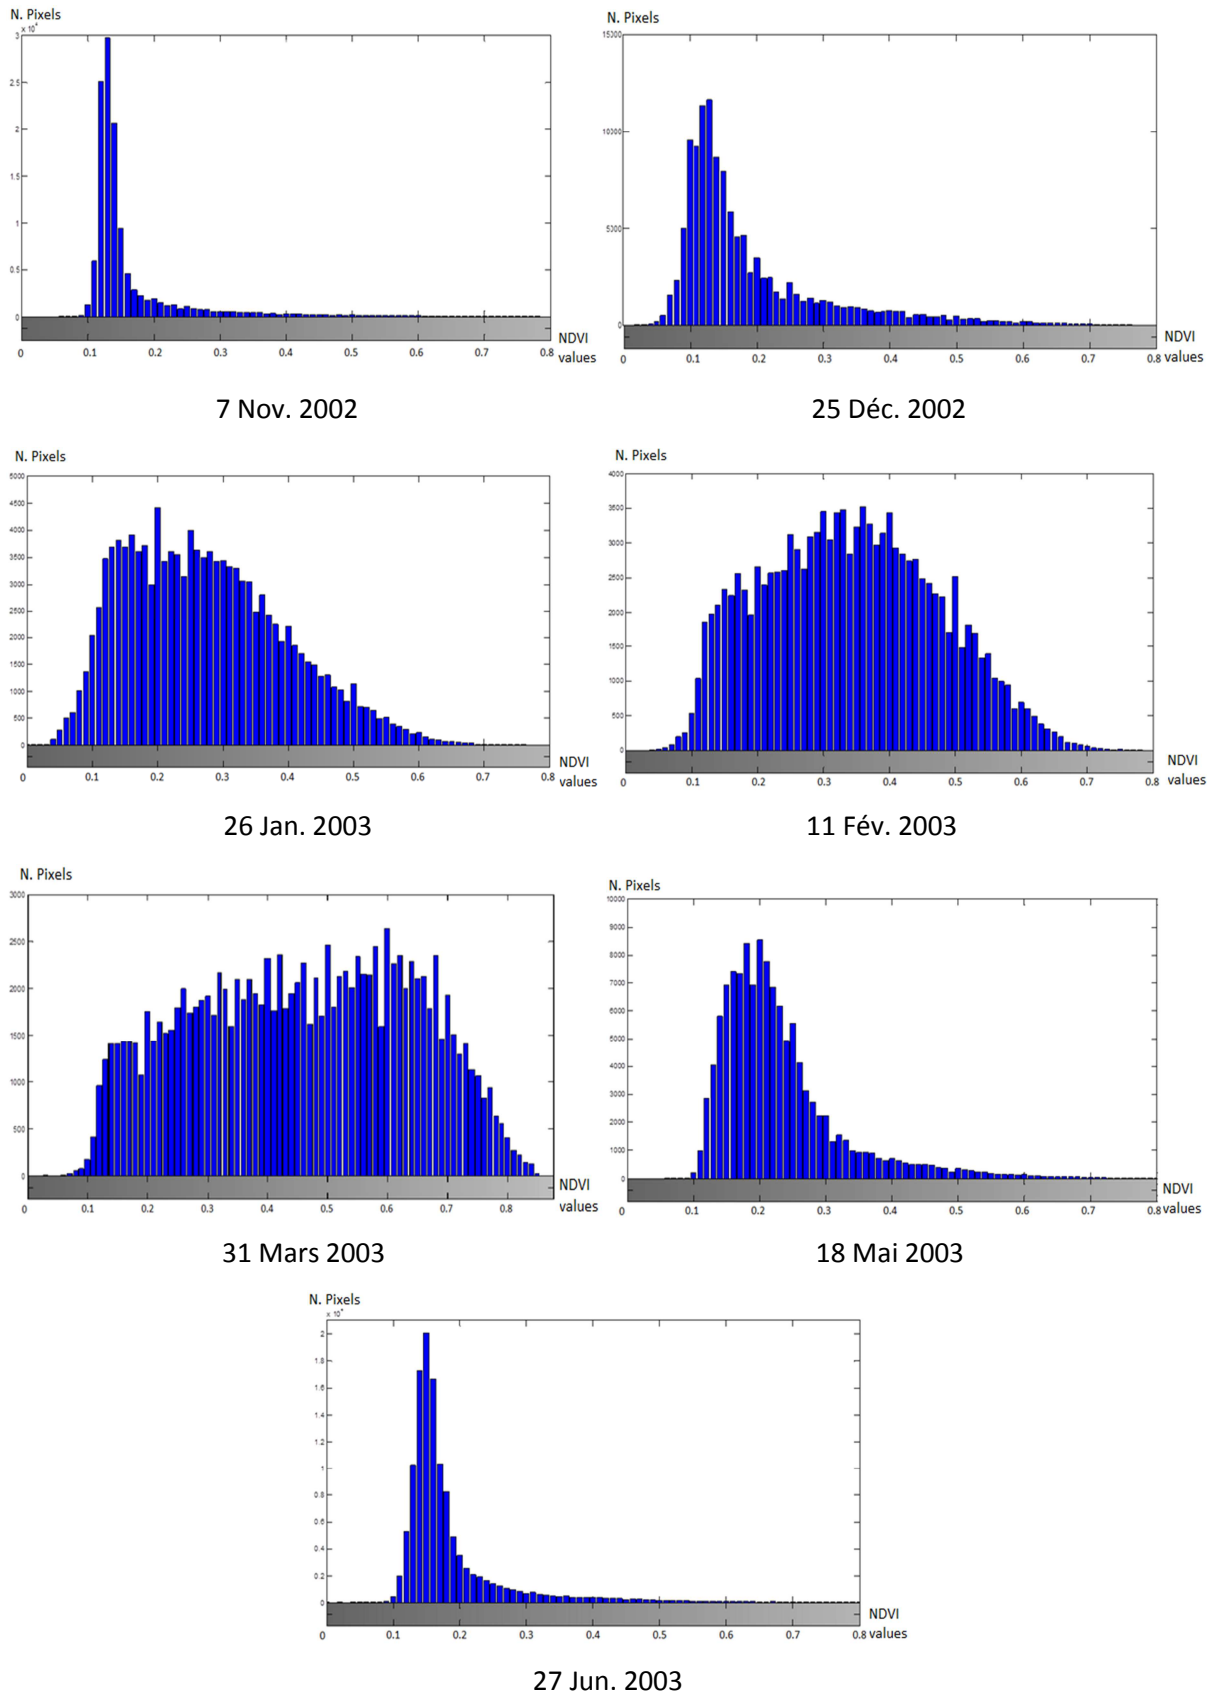


Figure 4.4 : Les histogrammes des sept scènes.

Les résultats obtenus sont raisonnables et logiques parce que dans la saison agricole du blé (les céréales), la densité de verdure est minimale dans la période du 7 novembre au 25 décembre correspondant à la période de semis précoce et au 27 juin après la récolte, tandis que la période du 26 janvier au 18 mai présente la phase de croissance avec une activité végétative intense ce qui s'introduit par une verdure plus dense montrant plusieurs niveaux de verdure et ainsi plusieurs valeurs de NDVI. En prenant l'évolution de chaque pixel selon les 7 scènes utilisées, notre classification a réduit le nombre de niveaux sur les valeurs de NDVI en conservant l'information. C'est une forme de compression de l'information qui nous a servi à gagner le temps de calcul pour la classification temporelle en réduisant le nombre de combinaisons temporelles sur les valeurs de NDVI de 121 493 à 4 619.

4.3.2. La classification temporelle supervisée des scènes NDVI

❖ Utilisation d'un modèle de critères sur les profils NDVI

Pour une discrimination fiable des classes thématiques dans la région, un modèle a été proposé par Simonneaux et al. (2008), basé sur l'analyse de l'évolution des profils de NDVI au cours de l'année 2001-2002. L'examen visuel des profils a permis de déterminer 3 principales classes : Sol nu, Cultures annuelles et Arbres, selon des critères (des seuils sur les valeurs de NDVI) qui figurent dans le tableau 4.3.

Tableau 4.3 Critères utilisés pour une classification supervisée des profils NDVI.

Conditions sur les valeurs de NDVI	Conditions sur la gamme de NDVI	Classes
Tous NDVI < Sn	Non	Sol nu
Des NDVI > Sn et autres NDVI < Sn	Non	Cultures annuelles
Tous NDVI > Sn	max(NDVI) - min(NDVI) < Sr et tous NDVI < Sa	Arbres dans sol nu
	max(NDVI) - min(NDVI) > Sr et des NDVI > Sa	Arbres avec plantes saisonnnières

Avec Sn = 0.19, Sa = 0.45 et Sr = 0.15

La figure 4.5 représente le résultat de la classification suivant ce modèle sur les scènes NDVI spatialement classifiées par la méthode FCM automatique (en tenant compte la redondance des niveaux NDVI dans chaque scène) et par notre algorithme. Le tableau 4.4 présente les pourcentages d'erreur de chaque technique sur chaque classe. Le pourcentage

d'erreur représente le nombre de pixels mal classifiés sur le nombre de pixels correspondant à une classe.




Figure 4.5 : Application du modèle par critères sur les scènes classifiées par: (a) FCM automatisée, (b) PNN automatisé.

Tableau 4.4 Pourcentages d'erreur sur chaque classe et sur la totalité des classes après la classification temporelle par le modèle des critères sur NDVI.

Techniques \ Classes	Sol nu	Cultures annuelles	Arbres	Toutes les classes
FCM avec redondances	25,15 %	3,50 %	15,56 %	5,38 %
FCM sans redondances	37,44 %	3,80 %	11,07 %	8,97 %
PNN automatisé	5,45 %	2,70 %	14,03 %	3,93 %

Les résultats obtenus montrent que la méthode PNN présente moins d'erreurs sur la classification de la totalité des classes avec une efficacité de 96%, mieux que la méthode par FCM automatique marquant une efficacité de 91%.

❖ Utilisation du PNN avec apprentissage supervisé

Nous avons créés des profils de NDVI qui répondent aux différentes classes les plus marquées dans la région en se basant sur des échantillons identifiés sur terrain. En prenant la position de ces échantillons sur les scènes NDVI issues des images Landsat, on obtient six profils NDVI (Figure 4.6): blé, orge, sol nu, jachère, oliviers et luzerne.

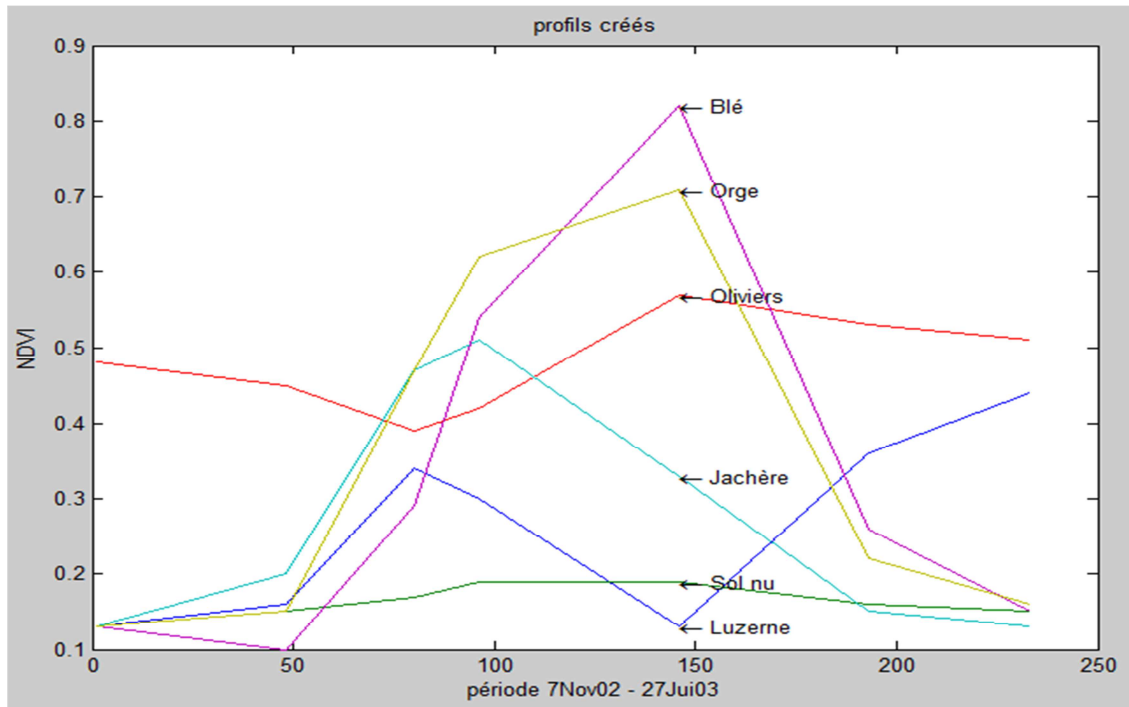


Figure 4.6 : Evolution temporelle de NDVI des six profils identifiés.

La figure 4.7 montre l'occupation du sol en utilisant ces six profils comme apprentissage de la classification temporelle par PNN des scènes spatialement classifiées par les deux méthodes automatiques utilisant PNN et FCM.

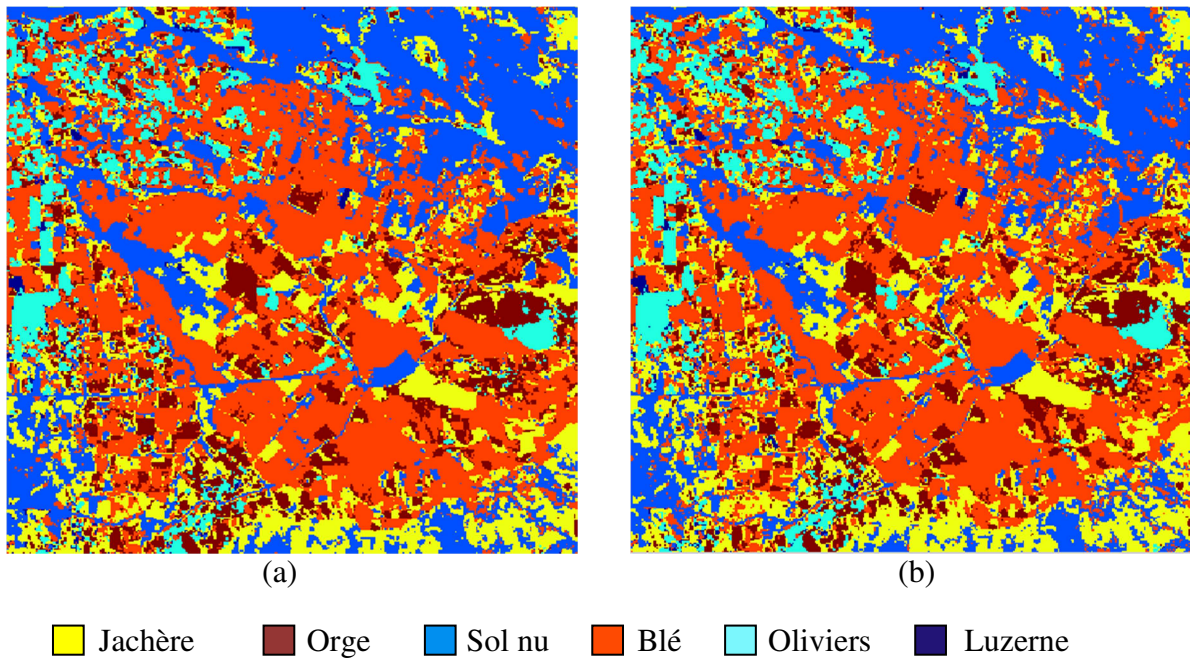


Figure 4.7 : Classification par PNN supervisé sur les scènes classifiées par: (a) FCM automatique, (b) PNN automatique.

Le tableau 4.5 présente les taux d'erreur de la classification par chaque technique et pour chaque classe.

Tableau 4.5. Pourcentages d'erreur sur chaque classe et sur la totalité des classes après la classification temporelle par PNN supervisé.

Techniques \ Classes	Blé	Sol nu	Jachère	Orge	Oliviers	Luzerne	Toutes les classes
FCM avec redondances	9,08 %	10,76 %	6,50 %	20,18 %	5,10 %	18,06 %	10,01 %
FCM sans redondances	10,44 %	11,04 %	11,01 %	14,54 %	8,99 %	36,01 %	11,24 %
PNN automatisé	4,98 %	5,55 %	6,55 %	9,45 %	13,02 %	24,50 %	6,63 %

Les résultats obtenus montrent que la méthode par PNN automatisé présente moins d'erreurs de classification sur les classes dominantes dans la région et sur la totalité des classes avec une efficacité de 93%, mieux que la méthode par FCM automatique marquant une efficacité de 89%.

4.4. Application de la procédure complètement automatique

Pour répondre à la problématique d'obtenir l'occupation du sol de la zone d'étude d'une façon automatique sans avoir à passer par une étape d'apprentissage. On procède premièrement par une classification spatiale automatique, c'est ce qu'on a déjà fait dans la section 4.3.1. Ensuite, on passe à une classification temporelle non supervisée en utilisant la CAH pour le calcul des classes (Iounousse et al., 2012).

4.4.1. La carte d'occupation du sol

On applique notre algorithme sur la série temporelle des 7 scènes spatialement classifiées pour extraire les différents comportements temporels de NDVI. Le nombre de classes C est choisi dans l'intervalle $[C_{min}=5, C_{max}=15]$. La variabilité de l'indice de validité des classes V selon C est présentée dans le tableau 4.6. On peut voir que le nombre optimal de classes obtenu est $C^*=15$ correspondant au V maximal $V_{max} = 0,99$.

Tableau 4.6. Variabilité de l'indice de validité des clusters V selon le nombre de classes C utilisant PNN automatique.

Nombre de classes C	5	6	7	8	9	10	11	12	13	14	15
Indice V	0.893	0.889	0.930	0.951	0.971	0.962	0.969	0.977	0.983	0.986	0.990

La figure 4.8 illustre les courbes de l'évolution temporelle des quinze profils de NDVI obtenus. Ces 15 profils seront utilisés pour l'identification des types de cultures présents dans la zone.




Figure 4.8 : Les courbes temporelles des quinze profils NDVI obtenus par PNN non supervisé.

Pour faire une interprétation de ces profils et d'associer à chacun une classe sémantique dans la zone d'étude, une analyse du comportement temporel des valeurs de NDVI est effectuée.

Or, la classe représentant le sol nu est simple à trouver. Cette classe a une valeur constante de NDVI autour de 0.15 durant toute l'année de culture (0.15 correspond à un sol argileux). Certaines fluctuations de NDVI de cette classe sont dues à la variation de l'humidité du sol.

Une autre classe qu'on peut discriminer correctement est la classe des arbres. Cette classe a un profil de NDVI toujours au-dessus de 0.18 étant donné que la majorité des arbres sont à feuilles persistantes (oliviers et agrumes). La biomasse de ces arbres est relativement constante au fil du temps, en dépit de quelques légères variations dues aux stades de croissance et à l'élagage annuel, ce qui rend leur valeur de NDVI généralement constante. Les arbres sur le sol nu sont clairement identifiés par leur profil ayant toutes les valeurs de NDVI inférieures à un seuil de 0.43 avec des variations limitées de NDVI (une plage de variation de 0.17). Tous les autres profils d'arbres ayant soit des valeurs élevées ou hautes plages de NDVI

sont considérés comme des arbres avec des herbes ou avec cultures basses. La distinction de ces deux classes est utile pour la gestion de l'eau d'irrigation.

La classe des cultures annuelles est définie par des valeurs de NDVI s'élevant au-dessus de 0.18, illustrant la biomasse végétale importante, associée à des valeurs inférieures à 0.18, montrant la couverture végétale non permanente (soit une période de sol nu). Cette période sans végétation permet de les distinguer des plantations d'arbres à feuilles persistantes, qui produisent souvent à cette période. Cette classe comprend principalement les céréales comme le blé et l'orge qui peuvent être divisés en classes précoces ou tardives compte tenu de son évolution temporelle des valeurs de NDVI (Er-Raki et al., 2007). A partir des 15 profils, Nous avons trouvé cinq profils représentant le (blé / orge) précoce cultivés avant le 15 Décembre et trois profils de (blé / orge) tardifs cultivés après le 15 Janvier.

Enfin, la classe des terres en jachère peut être définie comme des terres avec presque pas de végétation ou un blé très peu développé à faibles valeurs de NDVI (blé sous précipitations). Cette classe est caractérisée par des valeurs de NDVI inférieures à 0.45.

Cette classification est conforme à celle de (Simonneaux et al., 2008) quand ils ont utilisé un algorithme par arbre de décision. Ainsi, les 15 classes sont fusionnées suite à leur évolution temporelle du NDVI en 6 principales classes en prenant en considération les profils de NDVI du couvert végétal en plaine du Haouz. Le tableau 4.7 montre les classes d'occupation du sol après cette fusion. La carte d'occupation du sol résultante est illustrée dans la figure 4.9.

Tableau 4.7. La fusion des profils obtenus et leur interprétation.

Les Profils NDVI							Interprétation des profils
7 Nov	25 Dec	26 Jan	11 Fev	31 Mar	18 Mai	27 Jun	
0.13	0.24	0.24	0.26	0.28	0.17	0.08	Terres en jachère
0.18	0.26	0.34	0.39	0.39	0.26	0.27	
0.18	0.21	0.22	0.23	0.36	0.25	0.27	
0.12	0.15	0.20	0.19	0.13	0.17	0.14	Sol nu
0.43	0.47	0.48	0.55	0.60	0.49	0.49	Arbres avec herbes
0.37	0.42	0.39	0.39	0.53	0.44	0.47	Arbres (en sol nu)
0.28	0.40	0.43	0.50	0.62	0.36	0.27	
0.14	0.17	0.45	0.60	0.78	0.26	0.18	(blé / orge) précoce
0.14	0.17	0.38	0.51	0.58	0.24	0.17	
0.13	0.15	0.26	0.41	0.79	0.27	0.16	
0.16	0.19	0.27	0.35	0.60	0.28	0.27	
0.15	0.39	0.52	0.55	0.49	0.24	0.19	
0.13	0.15	0.28	0.34	0.36	0.17	0.08	(blé / orge) tardif
0.12	0.15	0.14	0.23	0.61	0.27	0.16	
0.14	0.18	0.09	0.12	0.42	0.30	0.11	

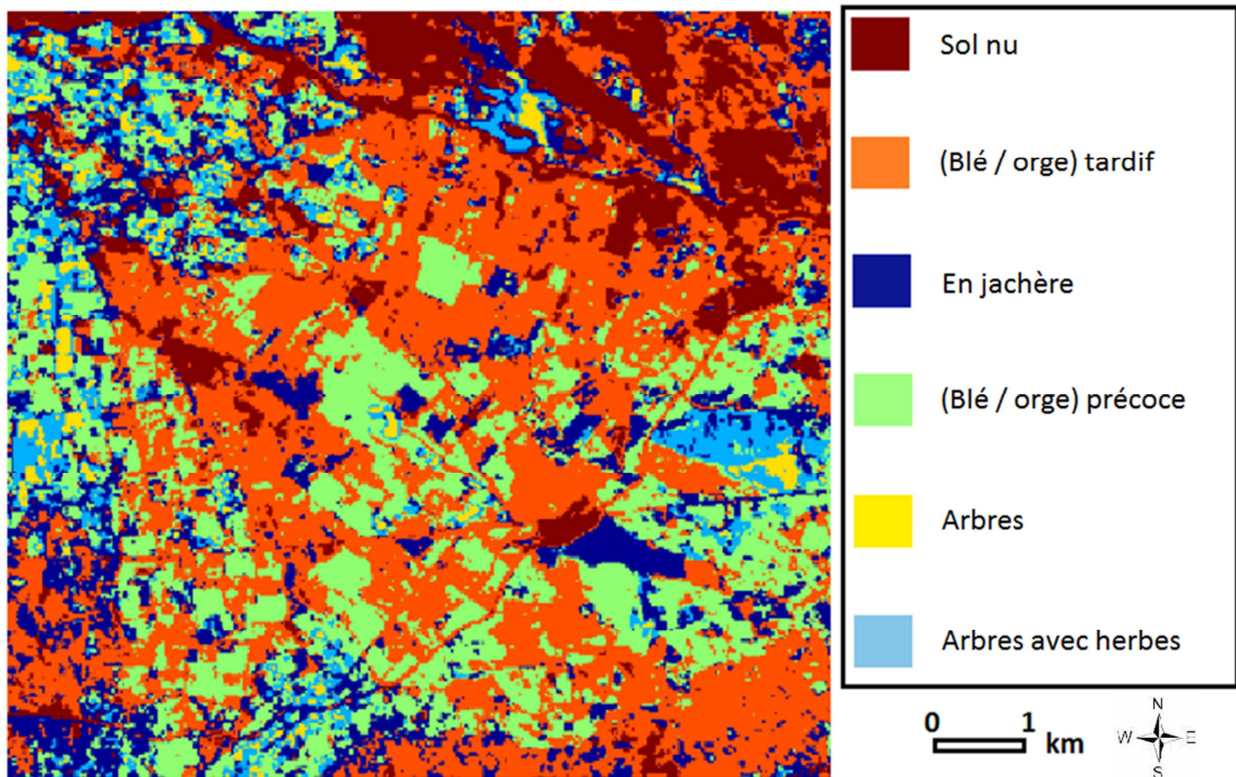


Figure 4.9 : La carte d'occupation du sol obtenue par la classification automatique utilisant PNN.

Les données obtenues donnent une couverture du sol selon les pourcentages suivants : sol nu 17,24%, en jachère 12,14%, (blé / orge) tardif 39,47%, (blé / orge) précoce 22,44%, les arbres 2.57% et les arbres avec herbes 6.13%.

4.4.2. La validation des résultats obtenus

Afin de valider la précision de notre approche, nous avons comparé la couverture du sol que nous avons obtenue avec la couverture réelle dans la région étudiée. Durant la saison 2002-2003, un ensemble de données a été récolté dans le cadre du programme Valeri (VALERI, 2003) sur une série de 450 parcelles réparties à travers la plaine (Simonneaux et al., 2008) (Figure 4.10) (Tableau 4.8).

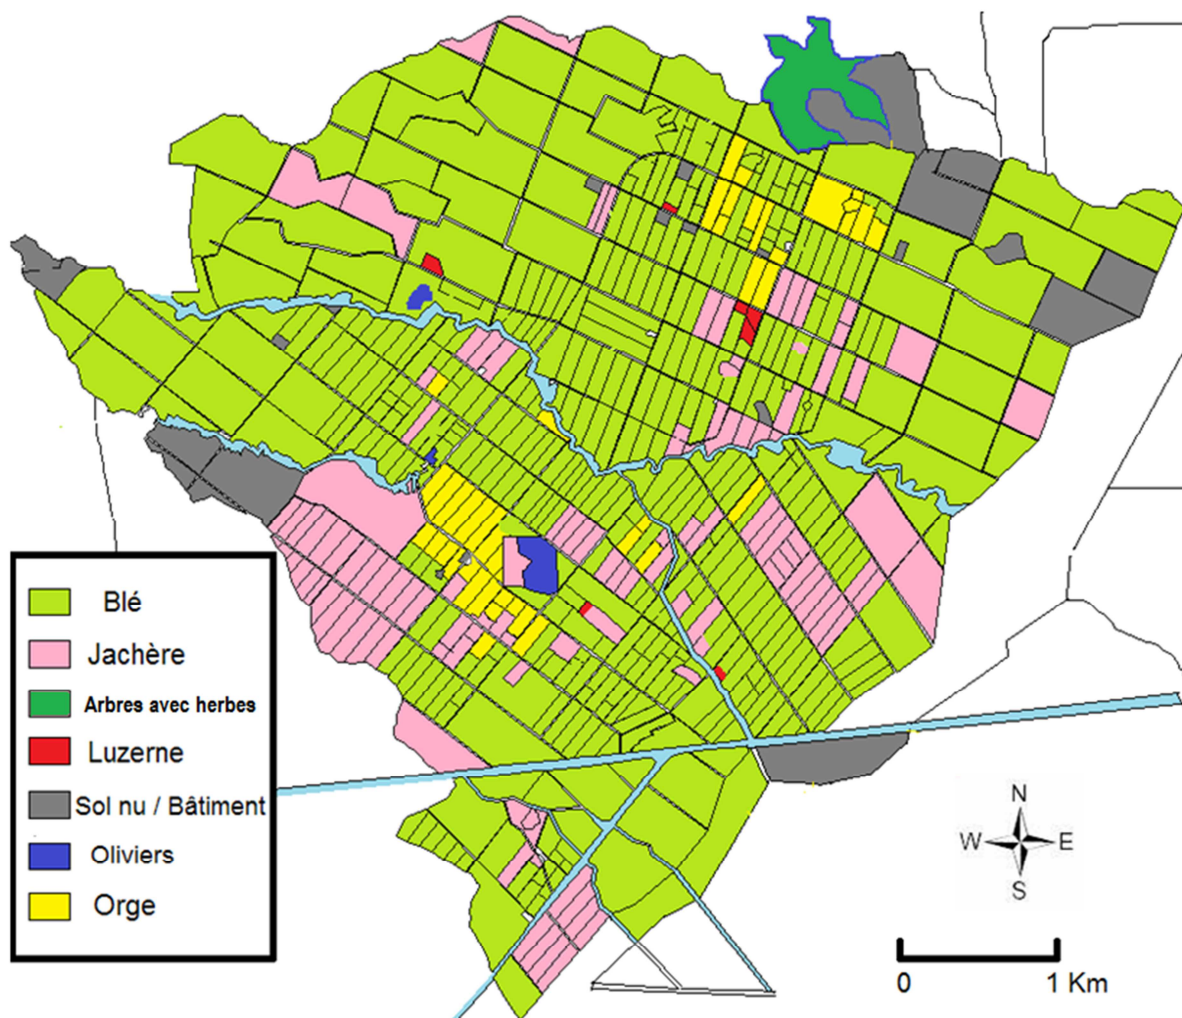


Figure 4.10 : La carte d'occupation du sol réelle obtenue par échantillonnage sur terrain pour la saison 2002-2003.

Tableau 4.8. Résultats par échantillonnage de l'occupation du sol en 2002-2003.

Type de culture	Nombre de parcelles	Pourcentages
Céréales	234	52.00 %
Orges	29	6.45 %
En jachère / non cultivé	59	13.11 %
Luzerne	4	0.89 %
Oliviers	5	1.11 %
Bâti	3	0.67 %
Sol nu - jachère	77	17.11 %
Arbres	11	2.44 %
Arbres sur végétation	28	6.22 %
Total	450	100 %

On fusionne les classes qui représentent le même type de culture : la classe Bâti est ajoutée au sol nu, les oliviers à la classe des arbres et les orges à la classe des céréales. Le Tableau 4.9 donne une comparaison entre nos résultats de l'occupation du sol avec la réalité. La précision globale est calculée comme le pourcentage des pixels correctement classés (pourcentage de prédiction) (Congalton & Green, 1999). C'est aussi la somme des produits de la proportion de l'occupation du sol et la précision de classification pour chaque classe.

Tableau 4.9. Comparaison des résultats de l'occupation du sol et calcul de la précision globale.

Classes	Occupation du sol		Précision
	par échantillonnage	par notre classification	
Céréales (blé + orge)	58.45 %	61.91 %	100 %
Jachère / non cultivé	13.11 %	12.14 %	92.60 %
Arbres (en sol nu)	3.55 %	2.57 %	72.39 %
Arbres avec végétation	6.22 %	6.13 %	98.55 %
Sol nu	17.78 %	17.25 %	97.02 %
Luzerne	0.89 %	-	-
Total	100 %	100 %	*96.56 %

$$* \text{précision globale} = \sum_{\text{Classes}} (\text{précision de classification} \times \text{proportion de l'occupation du sol})$$

La classe représentant la luzerne (0.89 % de la région d'étude) n'a pas été détectée après notre classification par ce qu'on n'avait pas assez de points pour assurer l'apparition de son profil NDVI. Cette classe connaît une variation fréquente des valeurs de NDVI à cause des semailles (faibles valeurs de NDVI) et des poussées rapides (fortes valeurs de NDVI) durant une année de culture. C'est suite à l'exclusion de quelques scènes NDVI couvertes par les nuages que les pixels qui présentent cette classe ont été affectés à d'autres classes.

Les classes obtenues coïncident en pourcentages avec la réalité du terrain à précision totale de 96.56 %. Ainsi, notre algorithme a prouvé une grande efficacité à retrouver les profils des cultures existants dans la zone d'étude.

4.4.3. Comparaison des résultats avec d'autres méthodes

Afin de mettre en évidence d'avantage la performance de la méthode proposée, une étude comparative avec des méthodes habituelles de classification automatique (FCM, k-means) est effectuée en utilisant la même série temporelle de sept images NDVI.

En ce qui concerne la classification par FCM. Les résultats ont menés à un nombre optimal de classes de 5 suivant la variabilité de l'indice de validité de clusters V_{MPC} (Tableau 4.10). L'évolution temporelle des cinq profils de NDVI obtenus est présentée dans la figure 4.11.

Tableau 4.10. Variabilité de V_{MPC} selon le nombre de classes C utilisant FCM automatique.

Nombre de classes C	5	6	7	8	9	10	11	12	13	14	15
Indice V_{MPC}	0.326	0.293	0.266	0.254	0.241	0.226	0.217	0.206	0.197	0.187	0.181




Figure 4.11 : Les courbes temporelles des cinq profils NDVI obtenus par FCM automatique.

En considérant les variations temporelles des profils NDVI obtenus, on peut identifier quatre classes comme suit :

- La classe « Céréales » présentée par les profils 1 et 2 couvrants 41.65 % de la zone d'étude avec une précision de 70.15 %.
- La classe « Sol nu » présentée par le profil 3 couvrant 22.57 % de la zone d'étude avec une précision de 89.98 %.
- La classe « Jachère » présentée par le profil 4 couvrant 25.53 % avec une précision de 99.16 %.
- La classe « Arbres » présentée par le profil 5 couvrant 10.25 % avec une précision de 92.12 %.

Tandis que la méthode par k-means a produit un nombre optimal de classes de 7 (Tableau 4.11) dont l'évolution temporelle de NDVI est montrée dans la figure 4.12.

Tableau 4.11. Variabilité de l'indice de validité des clusters selon le nombre de classes C utilisant k-means automatique.

Nombre de classes C	5	6	7	8	9	10	11	12	13	14	15
Indice V_{MPC}	0.99	0.99	0.991	0.989	0.989	0.988	0.988	0.988	0.988	0.987	0.987




Figure 4.12 : Les courbes temporelles des sept profils NDVI obtenus par k-means automatique.

Ces profils ont aboutis à une identification de cinq classes majeures :

- La classe « Céréales » présentée par les profils 1, 7 (semences tardives) et le profil 3 (semences précoces) couvrants 43.73 % de la zone d'étude avec une précision de 74.82 %.
- La classe « Sol nu » présentée par le profil 5 couvrant 22.86 % de la zone d'étude avec une précision de 95.61 %.
- La classe « Jachère » présentée par le profil 6 couvrant 23.32 % avec une précision de 95.35 %.
- La classe « Arbres avec herbes » présentée par le profil 4 couvrant 5.79 % avec une précision de 93.09 %.
- La classe « Arbres en sol nu » présentée par le profil 2 couvrant 4.3 % avec une précision de 84.51 %.

Les cartes d'occupation du sol obtenues par la technique FCM et k-means sont respectivement présentées dans la figure 4.13 et 4.14. Le Tableau 4.12 récapitule la comparaison des résultats entre les trois méthodes utilisées.




Figure 4.13 : La carte d'occupation du sol obtenue par la classification automatique utilisant FCM.




Figure 4.14 : La carte d'occupation du sol obtenue par la classification automatique utilisant k-means.

Tableau 4.12. Comparaison des résultats des trois méthodes utilisées.

		Précision de classification		
		PNN automatique	FCM automatique	k-means automatique
Classes	Céréales (blé + orge)	100 %	70.15 %	74.82 %
	Jachère	92.6 %	99.16 %	95.35 %
	Arbres (en sol nu)	72.39 %	92.12 %	84.51 %
	Arbres avec végétation	98.55 %		93.09 %
	Sol nu	97.02 %	89.98 %	95.61 %
	Luzerne	0 %	0 %	0 %
Précision totale		96.56 %	79 %	82.02 %

Comme on s'y attendait, la méthode FCM a donné la plus faible précision de (79 %) et a été incapable d'estimer le bon nombre de classes. Deux classes (arbres avec des herbes et des arbres en sol nu) ont été fusionnées due à leur proche regroupement de centroïdes. En ce qui concerne la méthode k-means, elle a montré une précision relativement raisonnable, avec

(82.02 %) et des classes détaillées avec le bon nombre et type. Tandis que l'approche proposée utilisant PNN a produit les meilleurs résultats avec une très bonne estimation du nombre de classes et une précision globale de 96.56 % par rapport l'occupation réelle du sol.

4.5. Conclusion

Dans ce chapitre, nous avons testé et validé notre algorithme sur un exemple d'application. L'objectif est de classifier et d'extraire automatiquement les profils de différents couverts végétaux existants dans une région semi-aride à partir d'une série de scènes NDVI tirées des images satellite de la région et de dresser une carte d'occupation du sol qui peut servir à plusieurs fins telles que la contribution à l'estimation du flux de l'évapotranspiration dans la région par spatialisation. La région étudiée est Sidi Rahal, située dans la plaine Haouz près de Marrakech, qui a fait objet d'études par plusieurs chercheurs dans plusieurs domaines de recherche concernant l'agriculture et la gestion des eaux.

Notre méthode est procédée par deux types de classification. La première est spatiale, effectuée sur chaque scène NDVI afin de réduire le nombre de niveaux de NDVI dans chacune. Une deuxième classification temporelle est appliquée pour déterminer des prototypes de l'évaluation des NDVI selon le temps qui marquent des profils de végétation qu'on peut facilement interpréter.

Des premiers travaux de classification ont été réalisés en utilisant PNN et FCM pour la classification spatiale et en se basant sur des modèles prédéfinis pour la classification temporelle. Cette étape nous a permis de comparer une autre fois les deux méthodes et de reprouver la performance et l'efficacité du notre technique par PNN automatisé.

Les résultats de l'occupation du sol obtenus par notre méthode sur les images satellites de la région d'étude ont montré une précision de 96.56% par rapport à l'occupation du sol réelle. La comparaison avec les résultats des autres techniques usuelles telles que FCM et k-means a montré l'efficacité et la performance de notre procédure dans l'identification des végétations de la région. Ce qui rend notre méthode un outil efficace et performant dans la réalisation des cartes de l'estimation de l'évapotranspiration dans la zone par spatialisation en utilisant le modèle FAO (La section suivante). Ces cartes sont très utiles pour la gestion des ressources en eaux dans la zone d'étude et aident à donner des solutions pour affronter le problème de pénurie d'eau dans un pays généralement semi-aride comme le Maroc.

4.6. L'estimation du flux de l'évapotranspiration

Le phénomène de l'évapotranspiration se compose de l'évaporation directe qui s'effectue à partir des sols humides et des différents plans d'eau, mais aussi de la transpiration des végétaux. Le modèle de la FAO a été choisi pour l'estimation de l'évapotranspiration (Allen et al., 1998; Allen, 2000; Er-Raki et al., 2010). Ce modèle est basé sur l'hypothèse que toute culture peut être comparé à une culture standard (un gazon bien arrosé) dont elle diffère par un coefficient multiplicatif simple, le « coefficient culturel », qui varie au cours du temps en fonction du développement de la culture. On a donc :

$$ET_c = K_c \cdot ET_0 \text{ [mm]} \quad (4-2)$$

Avec ET_c est l'évapotranspiration des cultures en supposant l'absence du stress hydrique, ET_0 est l'évapotranspiration de référence [mm] et K_c est le coefficient culturel de la couverture végétale étudiée.

La valeur ET_0 est calculée en utilisant l'équation de Penman-Monteith et les paramètres climatiques suivants: la température de l'air, l'humidité de l'air, la vitesse du vent et le rayonnement net. Les mesures de ces paramètres peuvent être enregistrées sur le terrain habituellement en utilisant des stations d'enregistrement climatologiques.

Pour les cultures annuelles, le coefficient K_c est en fait la somme d'un coefficient global qui englobe la fraction d'évaporation du sol des flux d'eau appelé K_e et la fraction de la transpiration nommée K_{cb} (b pour basale). C'est la méthode « *Dual-crop coefficient* » :

$$K_c = K_e + K_{cb} \quad (4-3)$$

L'information spectrale inclus dans les images est généralement étroitement liée à la phénologie de la végétation, en particulier lors de l'utilisation des indices de végétation. De nombreux auteurs ont confirmé le fait que le NDVI et le coefficient cultural caractérisant la transpiration K_{cb} peuvent être reliés par une relation linéaire (Bausch & Neale, 1987; Ray & Dadhwal, 2001; Duchemin et al., 2006; Er-Raki et al., 2007) . La relation NDVI - K_{cb} est prise des directives du FAO (Allen et al., 1998):

$$K_{cb} = 1.64 (NDVI - NDVI_{min}) \text{ avec } NDVI_{min} = 0.14 \quad (4-4)$$

Ainsi, en utilisant les images de télédétection, il est possible d'estimer NDVI pour les dates de chaque image, ou d'interpoler un profil NDVI pour chaque jour de la saison de végétation et par la suite on peut calculer le K_{cb} à partir des valeurs de NDVI estimées.

Alors que K_e qui dépend de la teneur en eau dans le sol. Sa valeur est modulée pour chaque pixel de l'image de télédétection en fonction de la couverture du sol par la végétation pour minimiser K_e lorsque la couverture végétale est dense. Proposée par les directives du FAO (Allen et al., 1998), la relation de K_e est la suivante :

$$K_e = (1 - f_c) K_{e,max} \quad (4-5)$$

Avec f_c est la couverture du sol par la végétation : $f_c = 1.18 (NDVI - NDVI_{min})$ et $K_{e,max}$ est le coefficient d'évaporation qui est fixé à 0.3 par analyse des tableaux de la FAO et d'après la fréquence des apports d'eau dans la région.

Finalement, on peut combiner les relations de K_{cb} et K_e pour obtenir une estimation de l'évapotranspiration ET_c en fonction d' ET_0 comme suit :

$$ET_{Annuelles} = [1.286 (NDVI - 0.14) + 0.3] \cdot ET_0 \quad [\text{mm}] \quad (4-6)$$

Pour les arbres avec feuilles persistantes, l'évaporation est presque nulle or on utilise la méthode « *single-crop coefficient* » :

$$ET_{Arbres} = K_c \cdot ET_0 \quad [\text{mm}] \quad \text{avec } K_c \text{ fixé à } 0.6 \quad (4-7)$$

En conclusion, si l'évapotranspiration est calculée, les spécialistes peuvent avoir une idée sur la consommation des ressources et les besoins en eau à partir de l'occupation du sol d'une région.

Conclusion générale

A l'issue de ce travail de thèse, une méthodologie d'automatiser la classification des données par les réseaux de neurones probabilistes a pu être réalisée. L'objectif qui est son application sur des images de télédétection pour l'analyse, la catégorisation et la cartographie a été atteint. Quatre points principaux ont été abordés : la revue bibliographique mettant l'accent sur l'état de l'art concernant les techniques de classification et leur utilisation dans l'imagerie en télédétection, le développement et la validation expérimentale d'algorithmes permettant la classification automatique par PNN et finalement l'application de l'approche proposée sur des images de télédétection pour l'identification de la végétation.

Cette thèse de doctorat avait pour but le développement d'une procédure qui automatise la classification utilisant le PNN. L'étude bibliographique a permis de lister les principales méthodes de classification et de distinguer entre des techniques supervisées et autres non supervisées. Elle a permis aussi de cerner ces deux types de classification et de mettre en évidence leurs avantages et inconvénients. Pour réduire la supervision dans la classification, les recherches ont été orientées selon deux axes. Le premier axe propose de combiner les deux types de classification dans une méthode hybride. Dans ce cas, le point critique se situe dans la nécessité de l'intervention du praticien et les délais excessifs de l'analyse. Tandis que le deuxième axe utilise des algorithmes qui analysent la partition des groupes pour aboutir à la meilleure classification. La difficulté ici est de proposer un algorithme qui s'adapte à toute distribution de groupes. Ceci nous a conduits à développer des algorithmes qui combinent les deux solutions proposées dans la littérature pour réaliser une classification automatique utilisant le PNN.

Pour classifier une image, il est indispensable de fouiller l'information qu'elle contient. Nous nous sommes intéressés à la classification de l'imagerie en télédétection et son apport dans l'étude de la végétation. Or, nous avons donné quelques exemples d'application utilisant les images de la télédétection dans l'agriculture. Nous avons aussi décrit les méthodes d'acquisition de ces images en citant leurs propriétés et leurs caractéristiques. Enfin, nous avons présenté les différents descripteurs qui caractérisent et discriminent l'information extraite de l'image. Dans ce contexte, nous nous sommes intéressés aux descripteurs qui nous permettent l'identification de la végétation et construire ainsi des cartes d'occupation du sol des régions agricoles.

Concernant la mise en œuvre de la classification non supervisée par PNN, nous avons proposé les algorithmes suivants :

- L'apprentissage du réseau de neurones probabiliste par la classification hiérarchique agglomérative sous le critère de Ward.
- La validation des classes par un indice de validité proposé pour la classification par PNN.
- La classification des images multidimensionnelles en utilisant une classification spatiale et une autre dans le sens de l'espace multidimension (spectral ou temporel).

Ensuite, cette procédure d'automatiser la classification par PNN a été testée et validée sur plusieurs types de données. Les résultats de ces tests nous ont permis de juger l'efficacité de notre procédure et sa capacité d'être appliquée pour des images multicouches telles que les images de télédétection.

Dans la partie applicative, l'objectif était de classifier et d'extraire automatiquement les profils de végétation existants dans une région semi-aride. Une série multitemporelle de scènes NDVI tirées des images satellites a été utilisée afin de dresser une carte d'occupation du sol.

Pour atteindre cet objectif, nous avons procédé par deux classifications. Une première est spatiale et a été effectuée sur chaque scène NDVI pour la compression. La seconde classification est temporelle appliquée pour déterminer les profils de végétation selon l'évaluation temporelle des valeurs de NDVI. Nos résultats obtenus de l'occupation du sol ont été très satisfaisants avec une précision totale de 96.56% par rapport à l'occupation réelle du sol. Nous avons aussi montré que les résultats obtenus sont meilleurs que ceux produits par des méthodes usuelles (FCM et K-means) utilisant aussi l'étude de la validité des classes. Ceci a permis de ressortir les points forts de notre méthodologie de classification et qui sont :

- Sa précision et sa performance de classification.
- Son adaptabilité à toutes sortes de données.
- Le fait qu'elle est non supervisée et totalement automatique.

Plusieurs applications pourraient être envisagées par l'exploitation des résultats obtenus dans cette partie applicative. Nous avons également élargi le champ d'application de notre procédure de classification pour lui permettre d'intégrer des problématiques supplémentaires. L'exemple choisi est la détermination du bilan hydrique d'une zone par l'estimation du flux d'évapotranspiration. Ce dernier a été calculé par le modèle FAO en combinant les résultats de la classification avec les propriétés climatiques de la zone. Cela permettra aux spécialistes d'établir des plans de décisions et d'actions à mener concernant la gestion des ressources en eau.

Plusieurs perspectives pourraient être envisagées en appliquant notre procédure de classification. Prenant comme exemple le domaine de la médecine où la recherche est la plus importante et la plus active. Sachant que grâce au progrès de l'informatique et l'imagerie, ce secteur connaît une grande révolution lui permettant de visualiser indirectement l'anatomie, la physiologie ou le métabolisme du corps humain. Actuellement, l'image médicale prend plusieurs formes selon son utilité et sa représentation des tissus existants dans le corps humain. Elle peut contenir des descripteurs spectraux (des niveaux de gris d'une image scanner par exemple), des descripteurs texturaux (la structure d'un tissu dans une image microscopique par exemple) ou des descripteurs géométriques (contour d'une tumeur dans l'IRM par exemple). La classification et l'analyse de ces descripteurs peut être effectuée d'une façon automatique en utilisant notre approche à travers un logiciel spécialisé. Ce logiciel va faciliter l'interprétation des experts médicaux en comparant les résultats obtenus avec une base de données contenant des mesures préalablement effectuées.

Références bibliographiques

- Ait Kerroum, M., Hammouch, A., & Aboutajdine, D. (2010). Textural feature selection by joint mutual information based on Gaussian mixture model for multispectral image classification. *Pattern Recognition Letters*, 31(10), 1168–1174.
- Aksoy, S., Koperski, K., Tusk, C., Marchisio, G., & Tilton, J. (2005). Learning bayesian classifiers for scene classification with a visual grammar. *IEEE Transactions on Geoscience and Remote Sensing*, 43(3), 581 – 589.
- Allen, R. G. (2000). Using the FAO-56 dual crop coefficient method over an irrigated region as part of an evapotranspiration intercomparison study. *J. Hydrology*, 229, 27–41.
- Allen, R. G., Pereira, L. S., Raes, D., & Smith, M. (1998). *Crop Evapotranspiration- Guidelines for Computing Crop Water Requirements, Irrigation and Drain*. Paper No. 56. FAO, Rome, Italy.
- Anderson, E. (1935). The irises of the Gaspe Peninsula. *Bulletin of the American Iris Society*, 59, 2-5.
- Arribas, J., Sánchez-Ferrero, G., Ruiz-Ruiz, G., & Gómez-Gil, J. (2011). Leaf classification in sunflower crops by computer vision and neural networks. *Computers and Electronics in Agriculture*, 78(1), 9-18.
- Ball, G., & Hall, D. (1965). *ISODATA: A novel method of data analysis and pattern classification*. In Technical report, Stanford Research Institute, Menlo Park, USA.
- Bannari, A., Morin, D., & He, D.-C. (1997). Caractérisation de l'environnement urbain à l'aide des indices de végétation dérivés des données de hautes résolutions spatiale et spectrale. in A. UREF (ed.), *Téledétection des milieux urbains et périurbains*, pp. 47-64.
- Bannari, A., Morin, D., Huete, A., & Bonn, F. (1995). A review of vegetation indices. *Remote Sensing Reviews*, 13, 95-120.
- Bausch, W. C., & Neale, C. M. (1987). Crop coefficients derived from reflected canopy radiation: a concept. *Transactions of the American Society of Agricultural Engineers*, 30(3), 703–709.
- Belaqziz, S., Khabba, S., Er-Raki, S., Jarland, L., Le Page, M., Kharrou, M.H., El Adnani, M., & Chehbouni, A. (2013). A new irrigation priority index based on remote sensing data for assessing the networks irrigation scheduling. *Agricultural Water Management*, 119, 1- 9.
- Berkhin, P. (2002). *Survey of clustering data mining techniques*. Accrue Software.
- Bezdek ^a, J. C. (1974). Numerical taxonomy with fuzzy sets. *Journal of Mathematical Biology*, 1, 57-71.
- Bezdek ^b, J. C. (1974). Cluster Validity with fuzzy sets. *J. Cybernetics*, 3, 58-73.
- Bezdek, J. C. (1975). Mathematical models for systematics and taxonomy. in *Proceedings : 8th International Conf. on Numerical Taxonomy* (pp. 143-166). San Francisco: G. Estabrook, ed. Freeman.
- Broomhead, D. S., & Lowe, D. (1988). Multivariate functional interpolation and adaptive networks. *Complex Systems*, 2, 321-355.
- Carteron, A., Jeanmougin, M., Leprieur, F., & Spatharis, S. (2012). Assessing the efficiency of clustering algorithms and goodness-of-fit measures using phytoplankton field data. *Ecological Informatics*, 9, 64-68.

- Chen, L., Zhou, C., & Shen, L. (2012). Facial Expression Recognition Based on SVM in E-learning. *IERI Procedia*, 2, 781–787.
- Coggins, J. M. (1982). *A framework for texture analysis based on spatial filtering*. Computer Science Department, Michigan State University, East Lansing, Michigan: PhD thesis.
- Congalton, R., & Green, K. (1999). *Assessing the Accuracy of Remotely Sensed Data*. Lewis Publications, Boca Raton, FL.
- Cross, G. C., & Jain, A. K. (1983). Markov random fields texture models. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 5(1), 25-39.
- Datcu, M., Daschiel, H., Pelizzari, A., Quartulli, M., Galoppo, A., Colapicchioni, A., . . . D’Elia, S. (2003). Information mining in remote sensing image archives : system concepts. *IEEE Transactions on Geoscience and Remote Sensing*, 41(12), 2923–2936.
- Dave, R. N. (1996). Validating fuzzy partition obtained through c-shells clustering. *Pattern Recognition Letters*, 17, 613–623.
- Diday, E. (1986). Une représentation visuelle des classes empiétantes : les pyramides. *Revue RAIRO APII*, 20(5), pp. 475-526.
- Dillner, A. M., Schauer, J., Christensen, W. F., & Cass, G. .. (2005). A quantitative method for clustering size distributions of elements. *Atmos. Environ.*, 39, 1525–1537.
- Duchemin, B., Hadria, R., Er-Raki, S., Boulet, G., Maisongrande, P., Chehbouni, A., . . . Simonneaux, V. (2006). Monitoring wheat phenology and irrigation in Central Morocco: On the use of relationships between evapotranspiration. *Agricultural Water Management*, 79, 1- 27.
- Duchemin, B., Hagolle, O., Mougnot, B., Simonneaux, V., Benhadj, I., Hadria, R., . . . Chehbouni, A. (2008). Agrometeorological study of semi-arid areas: an experiment for analysing the potential of FORMOSAT-2 time series of images in the Marrakech plain. *International Journal of Remote Sensing*, 29(17-18), 5291-5300.
- Dunn, D., & Higgins, W. E. (1995). Optimal gabor filters for texture segmentation. *IEEE Transactions on Image Processing*, 4(7), 947–964.
- Dunn, D., Higgins, W. E., & Wakeley, J. (1994). Texture segmentation using 2-d gabor elementary functions. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 16(2), 130–149.
- Dunn, J. C. (1973). A Fuzzy Relative of the ISODATA Process and its Use in Detecting Compact Well-Separated Clusters. *J. Cybernetics*, 3(3), 32-57.
- El Harchaoui, N.-E., Ait Kerroum, M., Hammouch, A., Ouadou, M. & Aboutajdine, D. (2013). Unsupervised approach data analysis based on fuzzy possibilistic clustering: Application to medical image MRI. *Computational Intelligence and Neuroscience*, Volume 2013, Article ID 435497, 12 pages.
- El Merabet, Y., Meurie, C., Ruichek, Y., Touahni, R. & Sbihi, A. (2014). Segmentation d’images aériennes par coopération lpe-régions et LPE-contours. Application à la caractérisation de toitures. *Revue Francaise de Photogrammétrie et de Télédétection*, Juin 2014.

- Er-Raki, S., Chehbouni, A., & Duchemin, B. (2010). Combining Satellite Remote Sensing Data with the FAO-56 Dual Approach for Water Use Mapping In Irrigated Wheat Fields of a Semi-Arid Region. *Remote Sensing*, 2, 375-387.
- Er-Raki, S., Chehbouni, A., Guemouria, N., Duchemin, B., Ezzahar, J., & Hadria, R. (2007). Combining FAO-56 model and ground-based remote sensing to estimate water consumptions of wheat crops in a semi-arid region. *Agricultural Water Management*, 87, 41-54.
- Fisher, R. (1912). On an absolute criterion for fitting frequency curves. *Messenger of Mathematics*, 41, 155-160.
- Fisher, R. A. (1936). The use of multiple measurements in taxonomic problems. *Annals of Eugenics*, 7(2), 179-188.
- Foody, G. M., & Mathur, A. (2004). A relative evaluation of multiclass image classification by support vector machines. *IEEE Trans. Geosci. Remote Sens.*, 42(6), 1335–1343.
- Forgy, E. W. (1965). Cluster analysis of multivariate data : efficiency versus interpretability of classifications (abstract). *Biometrics*, 21, 768-769.
- Forsyth, D. A., & Ponce, J. (2003). *Computer vision: a modern approach*. Prentice Hall.
- Fua, P., & Hanson, A. J. (1987). Resegmentation using generic shape : Locating general cultural objects. *Pattern Recognition Letters*, 5(3), 243–252.
- Fujino, A., Ueda, N., & Saito, K. (2005). A Hybrid Generative/Discriminative Approach to Semi-Supervised Classifier Design. *Association for the Advancement of Artificial Intelligence (AAAI)*, 764–769.
- Gancheva, T. D., Tasoulisb, D. K., Vrahatisb, M. N., & Fakotakis, N. D. (2007). Generalized locally recurrent probabilistic neural networks with application to text- independent speaker verification. *Neurocomputing*, 70, 1424–1438.
- Geerken, R., Zaitchik, B., & Evans, J. (2005). Classifying rangeland vegetation type and coverage from NDVI time series using Fourier Filtered Cycle Similarity. *International Journal of Remote Sensing*, 26(24), 5535-5554.
- González, J., Rojas, I., Pomares, H., Ortega, J., & Prieto, A. (2002). A new clustering technique for function approximation. *IEEE Transactions on Neural Networks*, 13(1), 132–142.
- Greenhill, D., Ripke, L., Hitchman, A., Jones, G., & Wilkinson, G. (2003). Characterization of suburban areas for land use planning using landscape ecological indicators derived from ikonos-2 multispectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 41(9), 2015–2021.
- Grigorescu, S., Petkov, N., & Kruijinga, P. (2000). A comparative study of filter based texture operators using mahalanobis distance. *Proceedings in: 15th International Conference on Pattern Recognition*, 3, pp. 885–888.
- Hadria, R., Duchemin, B., Lahrouni, A., Khabba, S., Er-Raki, S., Dedieu, G., & Chehbouni, A. G. (2006). Monitoring of irrigated wheat in a semi-arid climate using crop modelling and remote sensing data: Impact of satellite revisit time frequency. *International Journal of Remote Sensing*, 27, 1093- 1117.

- Halder, A., Ghosh, A., & Ghosh, S. (2011). Supervised and unsupervised landuse map generation from remotely sensed images using ant based systems. *Applied Soft Computing*, 11, 5770-5781.
- Hands, S., & Everitt, B. (1987). A Monte Carlo study of the recovery of cluster structure in binary data by hierarchical clustering techniques. *Multivariate Behavioral Research*, 22, 235–243.
- Haralick, R. M., Shanmugan, K., & Dinstein, I. (1973). Textural features for image classification. *IEEE transactions on Systems, Man and Cybernetics*, 3(6), 610–621.
- Hartigan, J., & Wong, M. (1979). Algorithm AS136: A kmeans clustering algorithm. *Journal of Applied Statistics*, 28, 100-108.
- Huang, N., Xu, D., Liu, X., & Lin, L. (2012). Power quality disturbances classification based on S-transform and probabilistic neural network. *Neurocomputing*, 98, 12-23.
- Idrissi, M.J., Sbihi, A. & Touahni, R. (2004). An improved neural network technique for data dimensionality reduction in remotely sensed imagery. *International Journal of Remote Sensing*, 25(10), 1981-1986.
- Iounousse, J., Er-Raki, S., El Motassadeq, A., & Chehouani, H. (2015). Using an unsupervised approach of Probabilistic Neural Network (PNN) for land use classification from multitemporal satellite images. *Applied Soft Computing*, 30, 1–13.
- Iounousse, J., Farhi, A., El Motassadeq, A., & Chehouani, H. (2011). Extraction de profils de végétation par automatisation de la technique de classification utilisant les réseaux de neurones probabilistes. *Proceeding de la Conférence Méditerranéenne sur l'Ingénierie Sûre des Systèmes Complexes MISC'11*, Mai 2011, Agadir, Maroc. 211-216.
- Iounousse, J., Farhi, A., El Motassadeq, A., Chehouani, H., & Er-Raki, S. (2012). Unsupervised classification of grayscale image using Probabilistic Neural Network (PNN). *Proceedings in International Conference on Multimedia Computing and Systems – ICMCS'12*, May 10-12, 2012, Tangier, Morocco. 101-105. <http://dx.doi.org/10.1109/ICMCS.2012.6320161>
- Iounousse, J., Farhi, A., Er-Raki, S., El Motassadeq, A., & Chehouani, H. (2012). Approche de classification non supervisée par les réseaux de neurones probabilistes pour établir des cartes d'occupation du sol de la région de Tensift Al Haouz (Maroc). *Proceedings in African Association of Remote Sensing of the Environment (AARSE)*, Oct 29 – Nov 2, 2012, Eljadida, Morocco. 36-37.
- Jain, A. K., Murty, M. N., & Flynn, P. J. (1999). Data Clustering: A Review. *ACM Computing Surveys*, 31, 264-323.
- Jiang, Z., Zhang, S., & Zeng, J. (2013). A hybrid generative/discriminative method for semi-supervised classification. *Knowledge-Based Systems*, 37, 137-145.
- Jibrini, H. (2002). *Reconstruction de modèles de bâtiments à partir de données cadastrales vectorielles et d'un couple d'images aériennes à haute résolution*. Ecole Nationale Supérieure des Télécommunications, Paris, France: PhD thesis.
- Julien, Y., Sobrino, J., & Jiménez-Munoz, J.-C. (2011). Land use classification from multitemporal Landsat imagery using the Yearly Land Cover Dynamics (YLCD) method. *International journal of applied earth observation and geoinformation*, 13, 711-720.

- Kaefler, F., Heilman, C., & Ramenofsky, S. (2005). A neural network application to consumer classification to improve the timing of direct marketing activities. *Computers & Operations Research*, 32(10), 2595-2615.
- Kavzoglu, T., & Colkesen, I. (2009). A kernel functions analysis for support vector machines for land cover classification. *International Journal of Applied Earth Observation and Geoinformation*, 11, 352–359.
- Kersten, P. R., Lee, J. S., & Ainsworth, T. L. (2005). Unsupervised Classification of Polarimetric Synthetic Aperture Radar Images Using Fuzzy Clustering and EM Clustering. *IEEE Transactions on Geoscience and Remote Sensing* 43, 519–27.
- Le Page, M., Toumi, J., Khabba, S., Hagolle, O., Tavernier, A., Kharrou, M., Er-Raki, S., Huc, M., Kasbani, M., Moutamanni, A., Yousfi, M. & Jarlan, L. (2014). A life-size and near real-time test of irrigation scheduling with a sentinel-2 like time series (SPOT4-Take5) in Morocco. *Remote Sensing*, 6(11), 11182–11203.
- Loncaric, S. (1998). A survey of shape analysis techniques. *Pattern Recognition*, 31(8), 983–1001.
- Lowitz, G. E. (1983). Can a local histogram really map texture information ? *Pattern recognition*, 16(2), 141–147.
- Mac-Queen, J. B. (1967). Some methods for classification and analysis of multivariate observations. *Proceedings of the 5th Berkeley Symposium on Mathematical Statistics and Probability 1*, 281-297. Berkeley, University of California Press.
- Maenpaa, T., & Pietikainen, M. (2004). Classification with color and texture : jointly or separately ? *Pattern Recognition*, 37(8), 1629–1640.
- Mallat, S. G. (1989). A theory for multiresolution signal decomposition: The wavelet representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 11(7), 674–693.
- Mallat, S. G. (2003). *A wavelet tour of signal processing*. Elsevier, 2nd edn.
- Mandelbrot, B. B. (1983). *The fractal geometry of nature*. San Francisco: Freeman.
- Massa, A., Boni, A., & Donelli, M. (2005). A classification approach based on SVM for electromagnetic subsurface sensing. *IEEE Trans. Geosci. Remote Sens.*, 43(9), 2084–2093.
- Mather, P. (2004). *Computer processing of remotely-sensed images. An introduction*. John Wiley & Sons, Ltd, third edition.
- McQuitty, L. L. (1960). Hierarchical linkage analysis for the isolation of types. *Educational and Psychological Measurement*, 20, 55–67.
- Mohan, V., & Kannan, A. (2010). Color Image Classification and Retrieval using Image mining Techniques. *International Journal of Engineering Science and Technology*, 2(5), 1014-1020.
- Moody, J., & Darken, C. J. (1989). Fast Learning in Network for Locally Tuned Processing Units. *Neural Computation*, 1, 281-294.
- Park, H. S., Chung, Y. D., Oh, S. K., Pedrycz, W., & Kim, H. K. (2011). Design of information granule-oriented RBF neural networks and its application to power supply for high-field magnet. *Engineering Applications of Artificial Intelligence*, 24, 543-554.

- Park, H. S., Pedrycz, W., & Oh, S. K. (2009). Granular neural networks and their development through context-based clustering and adjustable dimensionality of receptive fields. *IEEE Transactions on Neural Networks*, 20(10), 1604–1616.
- Pedrycz, W. (1998). Conditional fuzzy clustering in the design of radial basis function neural networks. *IEEE Transactions on Neural Networks*, 9(4), 601–612.
- Pedrycz, W., Park, H. S., & Oh, S. K. (2008). A granular-oriented development of functional radial basis function neural networks. *Neurocomputing*, 72, 420–435.
- Perumal, K., & Bhaskaran, R. (2010). Supervised classification performance of multispectral images. *Journal of computing*, 2(2), 124-129.
- Pesaresi, M., & Benediktsson, J. (2001). A new approach for the morphological segmentation of high-resolution satellite imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 39(2), 309–320.
- Peura, M., & Iivarinen, J. (1997). Efficiency of simple shape descriptors. *In Aspects of Visual Form, World Scientific, Capri, Italy*, 443–451.
- Phyu, T. (2009). Survey of Classification Techniques in Data Mining. *in: Proceedings of the International MultiConference of Engineers and Computer Scientists (IMECS 2009)*, 978-988.
- Picard, N., Mortier, F., Rossi, V., & Gourlet-Fleury, S. (2010). Clustering species using a model of population dynamics and aggregation theory. *Ecol. Modell.* , 221, 152-160.
- Poggio, T., & Girosi, F. (1990). Network for approximation and learning. *Proc. IEEE*, 78(9), 1481 - 1497.
- Pradhan, R., Ghose, M. K., & Jeyaram, A. (2010). Land Cover Classification of Remotely Sensed Satellite Data using Bayesian and Hybrid classifier. *International Journal of Computer Applications*, 7(11), 1-4.
- Raghuraj, R., & Lakshminarayanan, S. (2008). Variable predictive model based classification algorithm for effective separation of protein structural classes. *Computational Biology and Chemistry*, 32(4), 302-306.
- Rajpoot, K. M., & Rajpoot, N. (2004). Wavelets and support vector machines for texture classification. *In: Proceedings of 8th International Multitopic Conference*, 328–333.
- Randen, T., & Husoy, J. (1999). Filtering for texture classification : a comparative study. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 21(4), 291–310.
- Ray, S. S., & Dadhwal, V. K. (2001). Estimation of crop evapotranspiration of irrigation command area using remote sensing and GIS. *Agricultural Water Management*, 49, 239-249.
- Roh, S. B., Ahn, T. C., & Pedrycz, W. (2010). The design methodology of radial basis function neural networks based on fuzzy K-nearest neighbors approach. *Fuzzy Sets and Systems*, 161(13), 1803–1822.
- Rojas, R. (1996). *Neural networks : a systematic introduction*. Editions Springer- Verlag.
- Rondeaux, G., Steven, M., & Baret, F. (1996). Optimisation of Soil-Adjusted Vegetation Index. *Remote Sensing of Environment*, 5(2), 95 – 107.

- Rouse, J., Haas, R., Schell, J., & Deering, D. (1973). Monitoring vegetation systems in the Great Plains with ERTS. *In : 3rd Earth Resources Technology Satellite-1 Symposium*, 309-317.
- Rouse, J., Haas, R., Schell, J., Deering, D., & Harlan, J. (1974). Monitoring the vernal advancement and retrogradation (greenwave effect) of natural vegetation. *NASA/GSFC Type III Final Report, Greenbelt, Md*, (p. 371).
- Rumpf, T., Mahlein, A. K., Steiner, U., Oerke, E. C., Dehne, H. W., & Plumer, L. (2010). Early detection and classification of plant diseases with Support Vector Machines based on hyperspectral reflectance. *Computers and Electronics in Agriculture*, 74(1), 91-99.
- Shyu, C., Klaric, M., Scott, G., Barb, A., Davis, C., & Palaniappan, K. (2007). GeoIRIS : Geospatial Information Retrieval and Indexing System - Content Mining, Semantics Modeling and Complex Queries. *IEEE Transactions on Geoscience and Remote Sensing*, 45(4), 839–852.
- Simonneaux, V., Duchemin, B., Helson, D., Er-Raki, S., Olioso, A., & Chehbouni, A. G. (2008). The use of high-resolution image time series for crop classification and evapotranspiration estimate over an irrigated area in central Morocco. *International Journal of Remote Sensing*, 29, 95-116.
- Singh, M., & Singh, S. (2002). Spatial texture analysis : a comparative study. *Proceedings in:16th International Conference on Pattern Recognition 1*, 676-679.
- Sneath, P. H. A. (1957). The application of computers to taxonomy. *Journal of General Microbiology*, 17, 201–226.
- Sokal, R. R., & Michener, C. D. (1958). A statistical method for evaluating systematic relationships. *University of Kansas Scientific Bulletin*, 38, 1409–1438.
- Sokal, R. R., & Sneath, P. H. A. (1963). *Principles of Numerical Taxonomy*. San Francisco: Freeman.
- Specht, D. (1988). Probabilistic neural networks for classification, mapping, or associative memory. *IEEE International Conference on Neural Networks*, 525-532.
- Specht, D. (1990). Probabilistic neural networks. *Neural Networks*, 3(1), 109-118.
- Staiano, A., Tagliaferri, R., & Pedrycz, W. (2006). Improving RBF networks performance in regression tasks by means of a supervised fuzzy clustering. *Neurocomputing* 69, 1570–1581.
- Steinnocher, K., Kressler, F., & Kostl, M. (2003). Modelling population pressure in suburban and rural regions based on remote sensing and statistical data. *Proceedings in: IEEE International Geoscience and Remote Sensing Symposium. IGARSS '03*, 3, 1969–1971.
- Sun, J., Yang, J., Zhang, C., Yun, W., & Qu, J. (2013). Automatic remotely sensed image classification in a grid environment based on the maximum likelihood method. *Mathematical and Computer Modelling*, 58(3-4), 573-581.
- Swain, M. J., & Ballard, D. H. (1991). Color indexing. *International Journal of Computer Vision*, 7(1), 11 – 32.
- Timung, S., & Mandal, T. K. (2013). Prediction of flow pattern of gas-liquid flow through circular microchannel using probabilistic neural network. *Applied Soft Computer*, 13, 1674-1685.
- Tsekouras, G. E., & Tsimikas, J. (2013). On training RBF neural networks using input-output fuzzy. *Fuzzy Sets and Systems*, 221, 65-89.

- Tuceryan, M., & Jain, A. K. (1998). Texture analysis, *The handbook of pattern recognition and computer vision* (2nd edition). *World Scientific Publishing Co., Inc., River Edge ,NJ, USA*, 207–248.
- Uykan, Z., Guzelis, C., Celebi, M. E., & Koivo, H. N. (2000). Analysis of input–output clustering for determining centers of RBFNN. *IEEE Transactions on Neural Networks*, *11*(4), 851–858.
- VALERI. (2003). VALERI Project (Validation of Land European Remote sensing Instruments) Available online: <http://w3.avignon.inra.fr/valeri/Afrique/maroc/2003/identification.php>.
- Vapnik, V. N. (1995). *The nature of statistical learning theory*. Editions Springer- Verlag.
- Vapnik, V. N. (1998). *Statistical Learning Theory, Inc.* New York: John Wiley and Sons.
- Wang, J., Chiang, W., Hsu, Y., & Yang, Y. (2013). ECG arrhythmia classification using a probabilistic neural network with a feature reduction method. *Neurocomputing*, *116*, 38-45.
- Wang, W., & Zhang, Y. (2007). On fuzzy cluster validity indices. *Fuzzy sets and systems*, *158*, 2095-2117.
- Ward, J. H. (1963). Hierarchical Grouping to Optimize and Objective Function. *Journal of the American Statistical Association*, *58*(301), 236-244.
- Wasserman, P. D. (1993). *Advanced Methods in Neural Computing*. *New York: Van Nostrand*, 35-55.
- Weston, J., & Watkins, C. (1999). Support vector machines for multiclass pattern recognition. *In: Proceedings of the 7th European Symposium on Artificial Neural Networks*.
- Xu, W., Wang, M., Zhang, X., Wang, L., & Feng, H. (2008). A novel filter method for cancer-related gene selection. *Bioinformation*, *2*(7), 301–303.
- Zhang, D., & Lu, G. (2004). Review of shape representation and description techniques. *Pattern Recognition*, *37*(1), 1-19.
- Zhang, G. P. (2000). Neural Networks for Classification: A Survey. *EEE Transaction on Systems, Man, and Cybernetics- Part C: Applications and Reviews*, *30*(4), 451-462.
- Zheng, L., & He, X. (2005). Classification Techniques in Pattern Recognition. *in: Proceedings of The 13th International Conference in Central Europe on Computer Graphics, Visualization and computer vision (WSCG 2005)*, 77-78.