

PRE-TRAITEMENT PAR SEPARATION AVEUGLE DE SOURCES POUR LA SEGMENTATION D'IMAGES MULTI-SPECTRALES

Danielle Nuzillard¹ Cosmin Lazar² Patrice Billaudel² Sorin Curila³ Fabien Belloir¹

¹² CReSTIC - URCA

¹ UFR Sciences, Moulin de la Housse, 51687 Reims cedex 2

² IFTS, 7 Bd Jean Delautre, 08000 Charleville-Mézières

³ Catedra de electronica, Strada Universitatii, 410087 Oradea, Bihor, Romania,

{danielle.nuzillard, cosmin.lazar, patrice.billaudel, fabien.belloir} @univ-reims.fr
scurila@uoradea.ro

Résumé

L'interprétation physique des images requiert leur segmentation et celle-ci impose de classifier les pixels en fonction de critères pertinents. Auparavant, l'aspect multi-composante des images nécessite une étape de pré-traitement en vue de réduire la dimensionnalité. Dans cet article, la classification est réalisée grâce à une méthode basée sur l'estimation de la fonction de la densité de probabilité qui ne requiert pas d'hypothèses directes concernant le nombre ou la forme des classes. L'étape préalable de réduction de dimensionnalité est effectuée par une analyse en composantes principales ou indépendantes et l'influence de ce choix sur le résultat est montrée.

Mots clefs

Images multi-spectrales, classification non supervisée, segmentation, séparation aveugle de sources.

1 Introduction

L'application traitée concerne la connaissance des structures biologiques des plantes, celle-ci est très importante pour la valorisation des ressources agricoles. L'objectif est de localiser et d'identifier les différents tissus qui se superposent dans une céréale. Pour cela, des techniques de segmentation des images basées sur des méthodes non supervisées de classification des données sont utilisées. Les données traitées sont constituées d'un cube de 19 images acquises en microscopie confocale de fluorescence représentant une coupe transversale dans un grain d'orge dont les différents tissus contiennent des composés naturellement fluorescents. Chaque pixel comporte 19 composantes qui constituent un pseudo-spectre.

Les méthodes de classification non supervisée sont généralement précédées d'une étape de réduction de dimension. Celle-ci est effectuée par des méthodes de

projections linéaires telles que l'Analyse en Composante Principale (ACP), l'Analyse Factorielle, la transformée Karhunen-Loeve (KL). L'observation des données et la prise en compte de l'objectif à atteindre, qui consiste en leur interprétation physique, nécessitent de prendre en compte les deux arguments suivants pour justifier du choix des méthodes et de leur mise en oeuvre.

D'une part, dans le cas des images multi-spectrales acquises en microscopie de fluorescence, la surface couverte par chaque pixel représente la réponse en longueur d'onde de plusieurs composés fluorescents. Ainsi, au lieu d'analyser des pixels purs, des mélanges de pixels sont analysés. Le modèle de mélange linéaire est souvent retenu pour traiter les mélanges de pixels. Les méthodes d'Analyse en Composantes Indépendantes (ACI) [1] transforment les données sous la contrainte d'indépendance des composantes, contrainte plus générale que celle d'orthogonalité incluse dans l'ACP, et peuvent aussi être utilisées pour la réduction de la dimensionnalité.

D'autre part, les données sont les valeurs des pixels des observations pour différentes longueurs d'onde et divers jeux de filtres. Pour chaque pixel, ces valeurs constituent un vecteur appelé pseudo-spectre. Les résultats recherchés sont les valeurs des pixels de chaque composante pure (pseudo-spectre pur) ainsi que leur carte de répartition.

Les données et les résultats recherchés sont et doivent être positifs et donc, il est préférable d'appliquer des méthodes de Séparations Aveugles de Sources (SAS) qui tiennent compte des contraintes physiques du problème traité, comme la positivité des données [2], [3], [4]. Pour tenir compte des aspects physiques, lors de la réduction de dimensionnalité, les deux premières composantes principales de l'ACP sont remplacées par les deux sources les plus importantes obtenues par une méthode de Factori-

sation en Matrice Non Négative (NNMF) [5].

La méthode de classification non supervisée est retenue parce qu'elle ne nécessite pas d'hypothèse directe ni sur la forme, ni sur le nombre de classes. Pour déterminer les classes, il est possible d'utiliser soit la fonction de densité de probabilité f_{dp} estimée et la ligne de partage des eaux "Parzen-watershed" [6], [7] ou équivalent "Parzen-SKIZ" [8], soit les contours des f_{dp} des classes "Support Vector Classification - SVC" [9]. Dans [10], les deux méthodes ont été comparées sur des données artificielles et dans une application de segmentation d'une image multi-spectrale.

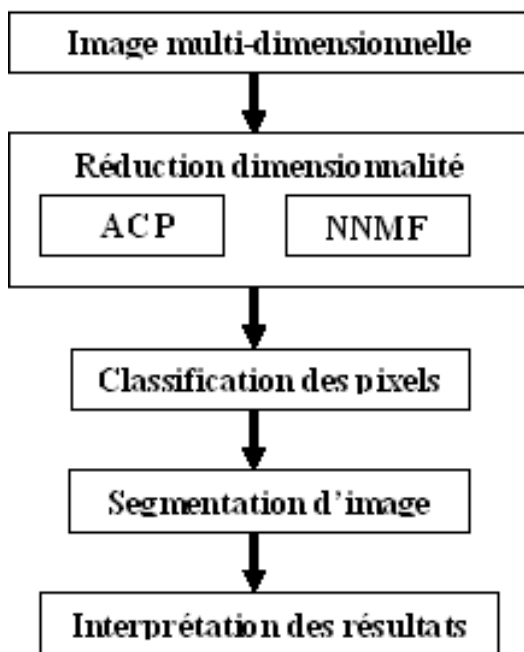


Figure 1 – Schéma de traitement

2 Classification des pixels basée sur l'estimation de la fonction densité de probabilité

B. Schölkopf *et al.* [11] affirment que "l'apprentissage non supervisé consiste à estimer la fonction densité de probabilité d'un ensemble des données". Ce point de vue extrême est soutenu par une autre affirmation qui dit que "connaître la f_{dp} d'un ensemble de données nous permet de résoudre n'importe quel problème lié à ces données". C'est sur cette base que nous avons choisi une approche par une méthode de classification non supervisée basée sur l'estimation de la f_{dp} .




Figure 2 – Réduction de la dimensionnalité; (a) 1^{ère}CP, (b) 2^{ème}CP, (c) 1^{ère}CI, (d) 2^{ème}CI.

2.1 Réduction de dimension

La réduction de la dimension est une étape fréquente de pré-traitement des données en vue d'effectuer une classification non supervisée. Elle consiste à transformer l'ensemble des données d'un espace à d dimensions dans un espace à m dimensions, où $m < d$ et souvent, $m = 2$. Cette transformation se justifie parce qu'un espace à 2 ou 3 dimensions permet de visualiser les données, de simplifier leur interprétation et de valider les résultats de la classification plus aisément [12]. Les méthodes les plus utilisées font appel à des projections linéaires. Une projection linéaire s'écrit comme :

$$y_i = Hx_i \quad (1)$$

où y_i est un vecteur colonne de dimension m , H est une matrice $m \times d$ et x_i est un vecteur colonne de dimension d . Parmi celles-ci, l'ACP et la transformée Karhunen-Loeve sont les plus courantes et les projections sont contraintes par l'orthogonalité. L'importance du modèle de mélange linéaire dans des applications d'analyse d'images multi-spectrales a été justifiée dans l'introduction. Les méthodes de Séparation Aveugle de Sources telles que l'ACI utilisent

une contrainte plus générale : l'indépendance des sources. Ainsi un algorithme tel que FastICA [1] fournit des sources indépendantes mais il autorise des valeurs négatives pour de composantes et de coefficients de mélange. Par contre l'algorithme NMF exploite la non-négativité des sources. Pour cette application, comme les contraintes physiques imposent que les résultats soient positifs, la NMF a été utilisée et les résultats ont été comparés avec ceux fournis par l'ACP.




Figure 3 – Pseudo-spectres de référence : (a) cutine, (b) acide férulique et (c) lignine; pseudo-spectres des CI : (d) lignine, (e) acide férulique, (f) et (g) deux spectres non identifiables obtenus par NMF; en abscisse : rang des images, en ordonnée : unités arbitraires.

2.2 Algorithme Parzen-Watershed

Contrairement à d'autres algorithmes non supervisés de classification mis en oeuvre pour la classification des pixels, tels que K-means ou ISODATA, cet algorithme ne requiert aucune supposition ni sur le nombre ni sur la forme des classes. Il est basé sur une estimation non-paramétrique de la *fdp* [13] dans un espace caractéristique normalisé 2D. L'espace de représentation est défini soit par les deux composantes indépendantes, soit par les deux composantes principales issues de l'étape de réduction de la dimension des données.

Dans cet espace, la *fdp* est estimée selon la méthode Par-

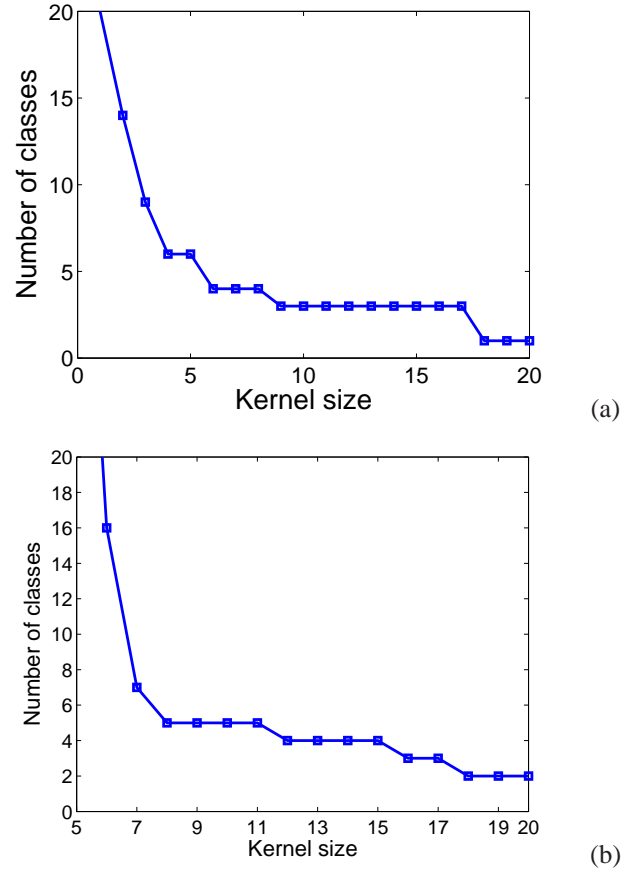


Figure 4 – Critère de stabilité (a) après l'ACP; (b) après NMF

zen où, chaque point dans l'espace caractéristique est transformé en une distribution quasi-continue par convolution avec une fonction noyau telle que :

$$p(x_i) = \lambda \sum_{k=0}^N K\left(\frac{x_i - y_k}{h}\right) \quad (2)$$

où K est la fonction noyau de lissage de taille h et λ est le facteur de normalisation. La *fdp* $p(x_i)$ estimée est caractérisée par quelques modes où points de maximum local. Chaque mode correspond à une classe d'objects. L'espace support de cette fonction est ensuite partagé en zones d'influence par une méthode de morphologie mathématique, soit la méthode Watershed, soit la méthode *Skeleton by Influence Zones* (SKIZ) [14]. Les zones d'influence déterminent le nombre des classes. Chaque pixel est étiqueté en fonction de la zone d'influence où se trouve son image dans l'espace défini par les deux composantes réduites.

La méthode de "Parzen-watershed" ou "Parzen-SKIZ" ne permet pas de déterminer la taille optimale du noyau gaussien utilisé pour l'estimation de la *fdp* de manière analytique, cette taille est donc déterminée empiriquement. Pour

cela, la fdp est estimée pour différentes tailles croissantes de noyau et le nombre de classes correspond au nombre des maximums locaux de la fdp estimée [9]. Le comportement du nombre de classes en fonction de la taille du noyau représente le critère de stabilité choisi pour justifier le choix du nombre de classes. Un nombre de classes est considéré suffisamment crédible si ce critère présente de larges plateaux.




Figure 5 – Classification après l'ACP : (a) fdp estimée, (b) zones d'influence et (c) image segmentée.




Figure 6 – Classification après NNMF : (a) fdp estimée, (b) zones d'influence et (c) image segmentée.

3 Resultats expérimentaux

L'image multi-spectrale d'une section de grain d'orge, acquise en fluorescence est segmentée suivant le schéma

général de la figure 1 en vue de l'identification des tissus. Les grains ont été fournis par l'INRA de Clermont-Ferrand et les images ont été enregistrées par l'INRA de Nantes et transmises par M.-F. Devaux. Les données se composent d'un ensemble de 19 images de 512x512 pixels qui sont réduites à deux dimensions en ne gardant que les deux premières composantes principales (CP) ou composantes indépendantes (CI) obtenues après une séparation par l'algorithme Non Negative Matrix Factorisation (NNMF), présentées dans la figure 2. La distribution d'énergie après les transformations linéaires, table 1 justifie de ne garder seulement que les deux premières composantes.

Tableau 1 – Distribution d'énergie des composantes après les transformations linéaires.

ACP	77.4%	16.8%	2.5%	1.3%
NNMF	42%	41%	12%	5%

L'avantages de la méthode NNMF sur l'ACP est qu'elle fournit une transformation dont les résultats sont physiquement interprétables. Les colonnes de la matrice de mélange sont comparées avec les pseudo-spectres de référence des composants chimiques responsables de la fluorescence du tissu externe du grain d'orge : la lignine, la cutine et l'acide férulique, figure 3, les unités en ordonnées sont arbitraires. La comparaison des spectres permet d'identifier parmi les colonnes de la matrice de mélange deux composés fluorescents : la lignine et l'acide férulique, les deux autres spectres étant non identifiables.

Le critère de stabilité, figure 4 propose 6, 4 ou 3 classes dans le cas où la réduction de la dimensionnalité a été effectuée par l'ACP et 5, 4 ou 2 dans le cas où l'algorithme NNMF est mise en oeuvre pour le prétraitement. Les résultats de la classification sont présentés dans les figures 5 et 6.

Pour être validés, ces résultats de classification non supervisée doivent être confrontés soit avec une vérité terrain, soit avec l'avis d'un expert. Ils ont été comparés à une coupe théorique d'un grain d'orge présenté dans la figure 7 qui décrit la structure et localise les tissus de la partie externe du grain. Les composés responsables de la fluorescence des tissus du grain d'orge sont localisés dans la couche aleurone - l'acide férulique, dans la partie externe du grain d'orge - la lignine et la cutine se situent en faibles quantités dans le tissu qui couvre le grain d'orge [15].

Les résultats expérimentaux montrent que, dans le cas où la réduction de la dimensionnalité a été effectuée par NNMF, les coefficients correspondants à l'acide férulique sont plus importants dans la région d'image où est localisé la couche

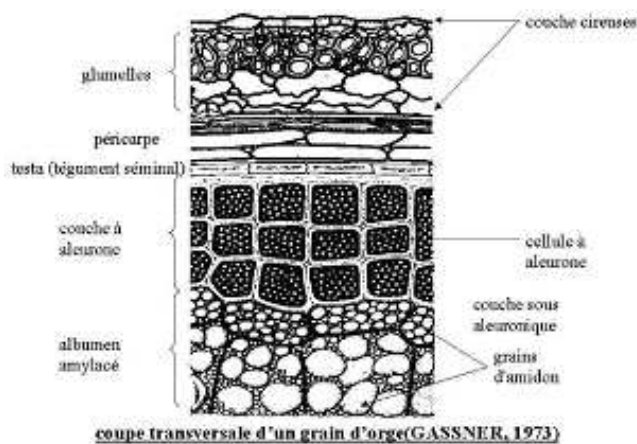


Figure 7 – Coupe transversale d'un grain d'orge

aleurone, tandis que pour la lignine, les coefficients les plus importants sont concentrés dans la partie externe du grain d'orge, figure 2 deuxième ligne. Le résultats sont conformes avec ceux présentés en [15]. La cutine n'est pas identifiable.

4 Conclusion

Des méthodes de séparation aveugle des sources et de classification non supervisée ont été associées pour le traitement des images multispectrales en vue de leur analyse.

Des travaux précédents ont montré l'intérêt d'introduire la positivité dans les méthodes de SAS. Cette contribution souligne la pertinence de la SAS contrainte, réalisée ici par NNMF, dans l'étape de la réduction de dimensionnalité, puisqu'elle respecte la physique des données et facilite l'interprétation des résultats de classification par rapport au cas où la réduction de la dimension est réalisée par l'ACP.

Un des inconvénients de la méthode Parzen-Watershed est qu'elle donne de bons résultats dans des espaces à 2, 3 dimensions car la complexité de calcul augmente exponentiellement avec la dimensionnalité. Si, après l'étape de réduction de dimensionnalité plus de 3 composantes importantes sont révélées cette méthode ne peut pas être utilisée.

Références

- [1] Aapo Hyvärinen, Erkki Oja, "Independent Component Analysis : Algorithms and Applications" , Neural Networks, 13(4-5) :411-430, 2000.
- [2] A. Elhafid, D. Nuzillard, M.-F. Devaux, N. Petrochilos, F. Belloir, "Extraction des signatures de composés purs constituant la couche externe du grain d'orge à partir d'images de fluorescence", CDRom 449, Belgique, *GRETSI'05*, 2005.
- [3] C. Gobinet, A. Elhafid, V. Vrabie, R. Huez and D. Nuzillard, "About importance of positivity constraint for source separation in fluorescence spectroscopy", CDRom 1467, Antalya Turkey, *EUSIPCO 2005*.
- [4] A. Bijaoui, D. Nuzillard, T. Deb Barma, "BSS, Classification and Pixel Demixing", *5rd Int. ICA'04*, pp. 96-103, Granada, Spain, 22-24 september 2004.
- [5] Patrick O. Hoyer, "Non-negative matrix factorization with sparseness constraints", *Journal of Machine Learning Research*, 5 :1457 - 1469, 2000.
- [6] J. Cutrona, N. Bonnet, M. Herbin, F. Hofer, "Advances in the segmentation of the multi-component microanalytical images", *Ultra-microscopy*, vol.103, 141-152, 2005.
- [7] N. Bonnet, "Artificial intelligence and pattern recognition techniques in microscopic image processing and analysis", *Adv. Imag. Electron. Phys.* vol.14, 1-77, 2000.
- [8] M. Herbin, N. Bonnet, P. Vautrot, " Number of clusterings and influence zones", *Pattern Recognition Letters* vol.22, 1557-1568, 2001.
- [9] A. Ben-Hur, D. Horn, H. Siegelmann, V. Vapnik, "Support vector Clustering", *Journal of Machine Learning Research* 2, 125-137, 2001.
- [10] D. Nuzillard, C. Lazar, "Comparison of Two Unsupervised Methods of Classification for Segmenting Multi-spectral Images", *International Conference on Acoustics, Speech, and Signal Processing 2006*, Toulouse, France, may, 2006.
- [11] B. Schölkopf, J.-C. Platt, J. Shawe-Taylor, A.J. Smola, R.C. Williamson, "Estimating the support of a high dimensional distribution", *Neural Computing* vol.13, 1443-1471, 2001.
- [12] A. K. Jain, R.C. Dubes, "Algorithms for Clustering Data", *Prentice Hall College Div*, New Jersey March 1988.
- [13] E. Parzen, " On the estimation of a probability density function and mode", *Annals Math. Stats.* vol.33, 1065-1076, 1962.
- [14] J. Serra, "Image Analysis and Mathematical Morphology", *Academic Press*, New York, 1982.
- [15] A. Saadi, I. Lempereur, S. Sharonov, J. C. Autran and M. Manfait, "Spatial distribution of phenolic materials in durum wheat grain by confocal fluorescence spectral imaging", *Journal of Cereal Science*, 28 (1998) 107-114.