

Classification de textures par Descripteurs Généralisés de Fourier dans différents contextes de réduction de dimension

LUDOVIC JOURNAUX¹, JOHEL MITERAN², FREDERIC COINTAULT¹, MARIE-FRANCE DESTAIN³

¹ ENESAD LMAIS, 26 Bd Dr Petitjean BP 87999, 21079 Dijon Cedex, France

² Lab. Le2i, Université de Bourgogne, BP 47870, 21078 Dijon Cedex, France

³ ENESAD UP GAP, 26 Bd Dr Petitjean BP 87999, 21079 Dijon Cedex, France

⁴ Unité de Mécanique et Construction, Faculté Universitaire des Sciences Agronomiques de Gembloux, Passage des Déportés 2, B-5030 Gembloux, Belgique

¹l.journaux@enesad.fr, f.cointault@enesad.fr

²miteranj@u-bourgogne.fr

³destain.mf@fsagx.ac.be

Résumé - Dans un contexte de classification de textures, cet article explore la capacité et la performance de différentes combinaisons d'extraction de caractéristiques, de techniques de réduction de dimensionnalité linéaires et non linéaires et de plusieurs méthodes de classification. Les performances sont évaluées et comparées sous forme d'erreur de classification. Afin de tester notre protocole de classification de texture, l'expérience a été menée sur différentes images de textures provenant de deux sources différentes, la base reconnue de Brodatz et une base de données constituée d'images de textures de surfaces foliaires pour une application agronomique.

Abstract - In the context of texture classification, this article explores the capacity and the performance of some combinations of feature extraction, linear and nonlinear dimensionality reduction techniques and several kinds of classification methods. The performances are evaluated and compared in term of classification error. In order to test our texture classification protocol, the experiment carried out images from two different sources, the well known Brodatz database and our leaf texture images database for an agronomic application.

1 Introduction

L'analyse de texture est une étape essentielle pour les applications liées à l'analyse d'images telles que l'imagerie médicale, agronomique ou industrielle, avec pour but de classer les textures à partir de l'extraction efficace de caractéristiques discriminantes. Cependant, ce problème reste complexe dans le cadre des textures naturelles qui sont sensibles à l'illumination, aux changements d'échelle, aux changements d'orientation et sont généralement non uniformes. Pour surmonter ces problèmes, l'utilisation combinée d'invariants et de méthodes de classification est souvent proposée [1], mais conduit, dans le cas d'images de texture de taille importante, à l'extraction de paramètres de grande dimension provoquant une classification parfois erronée du au phénomène de Hughes [2]. Il est donc intéressant d'utiliser les techniques de réduction de dimension (RD) afin d'améliorer les performances des classifieurs ; cependant, si des comparaisons d'algorithmes de RD ont souvent été réalisées sur des données synthétiques [3], très peu l'ont été sur des données issues de signaux naturels [4].

Dans cet article, nous considérons une famille d'invariants appelés Descripteurs Généralisés de Fourier (DGF) [5] conduisant à un espace de paramètres de dimension élevée dans le cas d'images de grande dimension spatiale. A partir de l'espace de base, nous proposons une comparaison croisée de 6 méthodes de

classification, 13 méthodes de RD et une méthode de sélection de paramètres. Afin de généraliser les résultats de ce protocole nous présentons cette expérience sur deux bases d'images de textures différentes : la base de Brodatz (2048 images de 64x64 pixels réparties en 32 classes) et une base d'images naturelles représentant les surfaces foliaires de différentes plantes d'intérêt agronomique prises au microscope à balayage électronique (1242 images de 512x512 pixels réparties en 6 classes (figure 1)).




Fig. 1 Echantillon des six classes d'images de texture de la base agronomique (tomate, ray grass, blé mûr, pois, blé jeune, prêle).

Tableau 1 : Les 13 méthodes de réduction de dimension

	Globale	Locale
Linéaire	<ul style="list-style-type: none"> Analyse en composante principale (PCA) [6] Analyse discriminante (LDA) [6] Séparation de source aveugle du second ordre (SOBI) [7] Poursuite de projection (PP) [8] 	
Non linéaire	<ul style="list-style-type: none"> Carte de Sammon (Sammon) [9] <i>Isometric Feature Mapping (ISOMAP)</i> [10] <i>ISOMAP à noyaux (K-ISOMAP)</i> [11] ACP à noyaux (K-PCA) [12] Analyse discriminante à noyaux (KDA) [13] 	<ul style="list-style-type: none"> Local linear embedding (LLE) [14] Laplacian eigenmaps (LE) [15] Analyse en Composante curviligne (CCA) [16] <i>Analyse des Distances curvilignes (CDA)</i> [17]

Métrique : Euclidienne ou *Géodésique*

2 Méthodes

2.1 Les Descripteurs Généralisés de Fourier

Considérant les déplacements dans le plan, Gauthier et al [5] ont proposé une famille d'invariants, appelés descripteurs de mouvement, qui sont invariants en translation, en rotation, insensibles à l'effet miroir. H. Fonga [16] a étendu l'utilisation des descripteurs de mouvement, définis de manière identique et appliqués aux images en niveau de gris. Les DGF sont définis comme suit : Soit f une fonction dans le plan, et \hat{f} sa transformée de Fourier :

$$\hat{f}(\xi) = \int_{\mathbb{R}^2} f(x) \exp(-j\xi x) dx. \quad (1)$$

Si (λ, θ) sont les coordonnées polaires du point ξ , on désigne alors par $\hat{f}(\lambda, \theta)$ la transformée de Fourier de f au point (λ, θ) . Gauthier et al. [5] ont alors défini l'application D_f de \mathbb{R}_+ dans \mathbb{R}_+ par

$$D_f(\lambda) = \int_0^{2\pi} |\hat{f}(\lambda, \theta)|^2 d\theta. \quad (2)$$

Où D_f représente le vecteur (le DGF) caractéristique de chacune des images de texture qui alimentera l'ensemble des classifieurs supervisés et seront réduits par les méthodes de RD.

2.2 Les Méthodes de classification

Parmi les nombreuses méthodes de classification existantes, 6 ont été retenues et évaluées provenant de 4 grandes familles : la méthode de boosting (adaboost) [17] basée sur 3 classifieurs faibles (Hyperplan, Hyperintervalle et Hyperrectangle), l'approche Hyperrectangle (Polytope) [18], les machines à vecteur support (SVM) [19, 20] avec un noyau Gaussien et enfin un perceptron multicouches (MLP) [21]. La validation des performances des classifieurs est déterminée au moyen d'une erreur moyenne calculée à partir de 20 expériences

consécutives dont le résultat est obtenu par validation croisée d'ordre 10.

2.3 Les Méthodes de réduction de dimension et sélection de paramètres

Si les DGF présentent un fort potentiel pour le domaine de la reconnaissance de forme, ils représentent malheureusement un espace de relativement haute dimension dans le cas d'images de textures de grande taille. Ces données sont alors difficiles à manipuler car redondantes, présentant un coût temporel de traitement prohibitif. Elles réduisent finalement de manière significative les performances des classifieurs classiques. Ainsi, pour améliorer ces dernières, il est intéressant d'employer des techniques de réduction de dimension (RD) permettant de conserver l'essentiel de l'information. Dans le cadre de cette étude, 13 méthodes de RD ont été sélectionnées ainsi qu'une méthode de sélection de paramètres séquentielle (Sequential Forward Selection (SFS) [22]). Ces 13 méthodes peuvent être classées selon 3 caractéristiques (Tableau1):

- **La Linéarité (Linéaire ou Non linéaire)** qui décrit le type de transformation appliquée à la matrice de données, les projetant de \mathbb{R}^m vers \mathbb{R}^p ($p < m$).
- **L'échelle d'analyse (Locale ou Globale)** qui reflète le type de propriété que la transformation doit préserver. Dans la plupart des méthodes non linéaires, cela correspond soit à la préservation de la topologie locale des points projetés dans le sous espace réduit \mathbb{R}^p , soit à la préservation globale de la structure des données.
- **La métrique (Euclidienne ou Géodésique)** qui définit le type de la distance utilisée pour évaluer si les deux jeux de données sont proches les uns des autres dans \mathbb{R}^m et doivent par conséquent rester proches dans \mathbb{R}^p après la transformation.

Tableau 2 : Résultats de classification sur la base de Brodatz (% d'erreur de classification)

Methods	Boosting			Hyperrectangle	SVM	MLP
	Hyperplan	Hyperinterval	Hyperrectangle			
<i>Original features</i>	17,26	12,2	22,5	15,5	2,65	20,4
<i>Selection</i>	21,3	19,7	13,4	8,3	3,06	15,3
PCA	23,4	18,5	13,2	7,4	8,4	11,2
LDA	17,5	18,5	12,8	6,9	2,8	13,2
SOBI	46,6	27,1	25,7	24,8	10,46	16,4
PP	84	82	69	75	61,4	73,0
Sammon	23,8	21,2	12,9	15,6	7,8	13,3
Isomap	23,4	19,5	12,9	7,3	6,55	12,1
LLE	22,5	23,4	15,3	8	4,5	15,9
CCA	23,7	20,7	13,9	9,1	5,7	18,2
CDA	22,6	20	15,3	7,4	3,9	15,6
Laplacian	16,7	11,8	14	5,56	1,20	10,2
K-PCA	23,6	19,1	14,2	7,2	6,65	11,8
KDA	24,5	15,3	12,2	6,6	0,8	12,3
K-Isomap	21,3	17,7	15,1	6,13	1,9	9,6

Tableau 3 : Résultats de classification sur la base de surfaces foliaires (% d'erreur de classification)

Methods	Boosting			Hyperrectangle	SVM	MLP
	Hyperplan	Hyperinterval	Hyperrectangle			
<i>Original features</i>	6,52	3,3	16,87	27,61	1,47	35,7
<i>Selection</i>	18,19	14,97	3,7	10,5	5,71	9,7
PCA	7,64	3,94	8,62	9,66	2,35	11,9
LDA	7,5	4,2	9,5	11,9	1,5	12,1
SOBI	15,29	4,99	9,56	13,2	4,8	15,8
PP	87,2	85,58	87,45	84,54	82	81,2
Sammon	26,9	25,84	10,89	10,1	5,48	13
Isomap	7,2	5,12	4,25	7,8	2,28	11,2
LLE	22,86	17,87	7,81	8,29	1,96	14,1
CCA	31,07	17,47	5,23	9,98	2,89	16,2
CDA	34,13	7,6	4,83	9,75	1,92	15,4
Laplacian	5,2	2,5	10,38	8,1	1,25	7,8
K-PCA	7,05	13,2	11,75	11,51	1,86	13,9
KDA	6,85	12,1	9,37	11,7	0,4	12,5
K-Isomap	6,8	3,9	11,43	6,3	1,31	10,2

Tableau 4 : Nombre de vecteurs supports nécessaire pour la fonction de décision des SVM

Données	Originales données	Selection	CCA	SOBI	PCA	K-PCA	CDA	LLE	Lapl	K-iso	Iso	Sam	PP	LDA	KDA
Brodatz	1545	1120	1006	1025	1035	1050	1059	1078	1095	1155	1163	1189	1467	1056	985
Plants leaf	504	209	363	172	232	332	419	291	267	296	328	272	1090	245	184

3 Résultats

Pour la base de textures de Brodatz (Tableau 2), ainsi que pour la base d'images de surfaces foliaires (Tableau 3), les meilleurs résultats à partir des DGF bruts sont obtenus en utilisant le classifieur SVM ($e_{\text{brodatz}}=2.65\%$ et $e_{\text{plantes}}=1.47\%$).

Dans le cadre de la réduction de dimension, les résultats montrent d'une manière générale que les méthodes de RD améliorent significativement la classification avec un optimum obtenu par la combinaison des SVM avec la KDA ($e_{\text{brodatz}}=0.8\%$, : erreur divisée par un facteur 3 et $e_{\text{plantes}}=0.4\%$: l'erreur est divisée par un facteur 3.6) ; notons cependant que la combinaison des SVM avec la méthode LE présente des résultats proches ($e_{\text{brodatz}}=1.2\%$ et $e_{\text{plantes}}=1,25\%$).

Par ailleurs, il est important de noter que l'emploi des approches à noyaux dans les méthodes de RD améliore sensiblement les performances par rapport à celles obtenues avec les méthodes originales.

De plus, il est intéressant de noter que les méthodes de RD permettent de minimiser le nombre de vecteurs supports nécessaires à la fonction de décision des SVM. Pour la méthode KDA, le gain est de 30% dans le cas de la base de Brodatz et 63% pour la base de surface foliaires. Ceci a pour effet de réduire significativement le temps de calcul de la phase de décision des SVM, temps qui dépend linéairement du nombre de vecteurs supports (tableau 4).

4 Conclusion

Dans cet article nous avons proposé une comparaison croisée de 13 méthodes de RD combinées à plusieurs

méthodes de classification, dans un contexte de classification de textures naturelles sur la base des Descripteurs Généralisés de Fourier. Dans tous les cas, les SVM surpassent tous les autres classifieurs à travers les données des descripteurs originaux (bruts). Cependant, nous avons démontré expérimentalement, que certaines méthodes de RD (KDA et LE) permettent d'améliorer les performances finales des classifieurs. Dans tous les cas, les méthodes de RD réduisent significativement le nombre de vecteurs supports, permettant d'optimiser le coût final de traitement. Sur la base de ces résultats, nos futurs travaux s'orienteront sur l'application de ce protocole croisé de méthodes sur des images hyperspectrales dans un contexte comparatif de segmentation d'images.

Références

1. Arivazhagan, S., L. Ganesan, and S.P. Priyal, *Texture classification using Gabor wavelets based rotation invariant features*. Pattern Recognition Letters, 2006. **27**(16): p. 1976-1982.
2. Hughes, G.F., *On the mean accuracy of statistical pattern recognizers*. IEEE Transactions on Information Theory, 1968. **14**: p. 55-63.
3. Aldo Lee, J., A. Lendasse, and M. Verleysen, *Nonlinear projection with curvilinear distances: Isomap versus curvilinear distance analysis*. Neurocomputing, 2004. **57**: p. 49-76.
4. Journaux, L., I. Foucherot, and P. Gouton, *Reduction of the number of spectral bands in Landsat images : a comparison of linear and nonlinear methods*. Optical Engineering, 2006. **45**(6): p. 067002
5. Gauthier, J.-P., G. Bornard, and M. Silbermann, *Harmonic analysis on motion groups and their homogeneous spaces*. IEEE Transactions on

- Systems, Man and Cybernetics, 1991. **21**(1): p. 159-172
6. Duda, R.O., P.E. Hart, and D.G. Stork, *Pattern Classification (2nd Edition)*, ed. W. Interscience. 2001. 654p.
 7. Belouchrani, A., et al., *A blind source separation technique using second order statistics*. IEEE Transactions on signal processing, 1997. **45**(2): p. 434-444.
 8. Friedman, J.H. and J.W. Tukey, *A projection pursuit algorithm for exploratory data analysis*. IEEE Transactions on computers, 1974. **C23**(9): p. 881-890.
 9. Sammon, J.W., *A nonlinear mapping for data analysis*. IEEE Transactions on Computers, 1969. **C-18**: p. 401-409.
 10. Tenenbaum, J.B., Vin de Silva, and J.C. Langford, *A Global Geometric Framework for Nonlinear Dimensionality Reduction*. Science, 2000. **290**: p. 2319-2323.
 11. Choi, H. and S. Choi, *Robust kernel Isomap*. Pattern Recognition, 2007. **40**(3): p. 853-862.
 12. Schölkopf, B., A.J. Smola, and K.-R. Müller, *Nonlinear component analysis as a kernel eigenvalue problem*. Neural Computation, 1998. **10**: p. 1299-1319.
 13. Liang, Z., D. Zhang, and P. Shi, *Robust kernel discriminant analysis and its application to feature extraction and recognition*. Neurocomputing, 2006. **69**(7-9): p. 928-933.
 14. Roweis, S.T. and L.K. Saul, *Nonlinear Dimensionality Reduction by Locally Linear Embedding*. Science, 2000. **290**: p. 2323-2326.
 15. Belkin, M. and P. Niyogi, *Laplacian eigenmaps for dimensionality reduction and data representation*. Neural Computation, 2003. **15**(6): p. 1373-1396.
 16. Fonga, H., *Analyse harmonique sur les groupes et reconnaissance de formes*. 1992: PHD thesis, université de Grenoble.
 17. Schapire, R.E., *The strenght of weak learnability*. Machine Learning, 1990. **5**: p. 197-227.
 18. Miteran, J., P. Gorria, and M. Robert, *Geometric classification by stress polytopes. Performances and integrations*. Traitement du signal, 1994. **11**: p. 393-407.
 19. Vapnik, V., *Statistical learning theory*, ed. J.W. sons. 1998: John Wiley & sons, INC.
 20. Abe, S., *Support Vector Machines for Pattern Classification*. Advances in Pattern Recognition 2005: Springer-Verlag.
 21. Rumelhart, D.E., J.L. McClelland, and a.t.P.R. Group, *Parallel Distributed Processing*. Vol. 1. 1986, Cambridge, Mass: MIT Press.
 22. Kittler, J., *Feature set search algorithms*, in *Pattern Recognition and Signal Processing*, S.a. Noordhoff, Editor. 1978, Chen, H. . p. 41-60.