

CLASSIFICATION AUTOMATIQUE DE BLOCS D'IMAGES MULTIMODALES UTILISANT DES METHODES STATISTIQUES ET SPECTRALE D'ANALYSE

Reçu le 25/02/98 – Accepté le 20/11/2000

Résumé

Cet article propose une nouvelle méthodologie pour la réalisation d'un classifieur automatique de blocs d'images multimodales. Cette méthode fait appel à un système de décision basé sur l'analyse et la caractérisation d'images multimodales en fonction de leurs propriétés locales. Ces propriétés sont modélisées par un ensemble de six familles de paramètres. Les blocs d'images sont classés par une méthode de classification non supervisée qui prend en compte les paramètres les plus discriminants. Une comparaison des classifieurs automatiques obtenus, en fonction de la taille des blocs, montre l'intérêt à adapter cette dernière au degré d'hétérogénéité de l'image. Enfin, l'efficacité de ces classifieurs est évaluée dans le cas d'images bruitées.

Mots clés: analyse de texture, classification, discrimination non paramétrique, optimisation d'un traitement.

Abstract

In this paper, we present a new methodology for the realisation of an automatic blocks classifier of multimodal images. The classifier is based on the local characteristics, modelled by a set of parameters, of each block. An unsupervised classified, using these features, allows to separate the image blocks on a fixed number of classes. This repartition of blocks leads to construct a simpler classifier, based on a binary decision tree using the most discriminating parameters. On the other hand, in many applications the image can be affected by noise. The origin and the stochastic spatial distribution of the noise could have harmful repercussion on the characteristic parameters extracted from these images and hence can influence the automatic classifier. The robustness of our automatic classifier in the presence of additive noise is studied.

Key words: Texture analysis, classification, adaptive processing, non parametric discrimination.

M. KHAMADJA

Département d'Electronique
Faculté des Sciences
Université Mentouri
Constantine, Algérie

A. BASKURT

R. GOUTTE

CREATIS, I.N.S.A. de Lyon
20, Avenue A. Einstein
69621 Villeurbanne, France

ملخص

تحتوي الصورة الرقمية على عدة معلومات يمكن استخلاصها، معالجتها تم تفسيرها. كل هذه العمليات تشمل تحليل الصورة.

في هذا العمل، قمنا بتقديم طريقة جديدة لتحليل الصور قصد ترتيبها حسب معايير تسمح بمعالجتها بطريقة فعالة. ثم قمنا بدراسة هذه المعايير في حالة وجود اختلالات في الصور. أعطت هذه التقنية نتائج جيدة.

الكلمات المفتاحية: تحليل الصور، ترتيب، تحسين المعالجة.

Le but de ce travail est de présenter une méthodologie pour la réalisation d'un classifieur automatique de blocs d'images multimodales. L'utilisation d'une base d'images multimodales autorise à penser que ce classifieur peut être d'un emploi, sinon universel du moins efficace pour une large gamme d'images. Cette classification préalable des blocs d'une image, basée sur leurs caractéristiques locales, est alors d'un apport certain pour une stratégie optimale de traitement. La réalisation de ce classifieur automatique nécessite une analyse de texture préalable, des différentes zones de l'image, suivie par une classification de ces blocs. L'analyse de l'image est une étape d'autant plus importante quand on utilise une base d'images multimodales.

Le résultat est un classifieur automatique dont l'avantage réside dans sa simplicité (peu de paramètres utilisés, décision rapide). De plus les caractéristiques paramétriques (contraste, moment angulaire d'ordre 2, etc...) utilisées par ce classifieur sont pris individuellement et non combinées entre elles. Ce dernier point est très important puisqu'il permet, en se basant sur la signification physique des paramètres, de décider du traitement à adopter pour chaque classe de blocs des images.

L'analyse de texture des images [1-9] fait l'objet de nombreuses études, mais à chaque fois en utilisant uniquement une ou deux méthodes d'analyse sur une seule image de petite taille et dont la dynamique de niveau de gris est très réduite. Cependant, dans ce travail qui s'inscrit dans une perspective plus généraliste, nous étudions une base d'images multimodales, de taille 128x128, dont la dynamique de niveau de gris est de 256 niveaux, pour laquelle nous utilisons simultanément plusieurs méthodes d'analyse pour caractériser au mieux le contenu informationnel

des images. La classification est réalisée par deux méthodes complémentaires, l'une basée sur la technique des nuées dynamiques, l'autre sur la discrimination non paramétrique.

Par ailleurs, dans beaucoup d'applications les images peuvent être affectées par du bruit. L'origine et la répartition spatiale aléatoires du bruit peuvent donc avoir des répercussions néfastes sur les paramètres caractéristiques extraits de ces images et donc influencer sur les classifieurs. On se propose dans cette étude de tester la robustesse des paramètres en présence de bruit additif.

La section 1 présente l'analyse des blocs de l'image. La section 2 donne la méthode de réalisation du classifieur de blocs. Les résultats obtenus font l'objet de la section 3, le comportement du classifieur en présence de bruit fera l'objet de la section 4.

1. ANALYSE DES BLOCS D'IMAGES

L'analyse des blocs d'images est basée sur la comparaison des niveaux de gris dans l'image numérisée. Le niveau de gris varie le plus souvent entre 0 et 255 (codage sur un octet). Différentes approches sont alors possibles [10]. Il est évident que les nombreux paramètres, statistiques et spectraux calculés à l'aide de ces méthodes, pour caractériser les propriétés locales d'une image, constituent des indices importants dans l'analyse du contenu informationnel des différentes zones de l'image considérée. Ceci permet une meilleure connaissance sur la répartition de la stationnarité des images, permettant ainsi d'affecter une signature paramétrique individuelle à chacune de ces zones.

Aussi, dans le souci de caractériser le mieux possible les différents blocs de l'image, on utilise dans cette étude, un ensemble de plusieurs méthodes d'analyse à savoir: les matrices de co-occurrence [1,5], les vecteurs des différences absolues [5], l'histogramme, les transformées spectrales, les séries de pixels de même niveau [1,2], la matrice des voisinages [6,11]. Pour certaines de ces méthodes (les matrices de co-occurrence, le vecteur des différences absolues, la matrice de voisinage), et pour multiplier les possibilités d'analyse nous avons utilisé comme pas de scrutation de l'image les distances de 1, 2, 4 et 8 pixels et pour 4 directions différentes, à savoir 0, 45, 90 et 135°.

Pour analyser les différentes images de la base de données, on les découpe en blocs de tailles 32×32 et 16×16 pixels. Ces tailles sont choisies après une étude statistique des longueurs de corrélation calculées selon les lignes et les colonnes de l'ensemble de la base d'images. Ceci donne un ensemble de 144 blocs dans le premier cas et 576 blocs dans le second. Plus de 90 paramètres (contraste, entropie, homogénéité, moyenne, moment diagonal, énergie spectrale, Laplacien du pic principal, accentuation des grandes plages, hétérogénéités, etc...) sont alors calculés pour chacun de ces blocs. Le calcul d'une matrice de corrélation pour l'ensemble de ces paramètres permet de garder que ceux d'entre eux qui présentent un coefficient de corrélation inférieur à 0,1. De cette manière, on élimine les paramètres redondants. Chaque bloc est alors représenté par un vecteur paramétrique (une sorte de signature paramétrique), dont les composantes sont les valeurs des

paramètres les moins corrélés. Cet ensemble de vecteurs est alors utilisé comme ensemble d'apprentissage pour la méthode des nuées dynamiques.

2. METHODES DE CLASSIFICATION

Les techniques d'analyse remplacent chaque bloc de l'image par un vecteur de paramètres. Classifier un bloc revient alors à l'associer à un ensemble de vecteurs ayant des caractéristiques semblables. Dans ce travail, nous avons combiné la méthode des nuées dynamiques avec la méthode de discrimination non paramétrique pour aboutir à la réalisation d'un classifieur automatique.


2.1- Nuées dynamiques [12-14]

La méthode des nuées dynamiques a pour but de fournir une partition d'un ensemble E d'individus en k classes fixées a priori.


Si E est un ensemble fini contenant n éléments, P_k est l'ensemble des partitions de E en k classes, L est l'ensemble de représentation et L_k l'ensemble des k -uplets éléments de L , notés $L: (A_1, \dots, A_k)$ où $A_i \in L$.

L'algorithme des nuées dynamiques consiste à trouver un couple (L, P) , où $L \in L_k$ et $P \in P_k$ qui minimise un critère W donné a priori. Ce qui donne d'une manière formelle:


$$W(L, P) = \text{Min } W(L^*, P^*) \text{ avec } L^* \in L_k, P^* \in P_k$$




étape 1: 2 points A et B sont tirés au hasard et appelés noyaux.



étape 2: chaque point est associé au noyau le plus proche.



étape 3: les nouveaux noyaux C et D sont calculés en prenant le point le plus proche du centre de gravité de chaque classe.



étape 4: chaque point est associé au noyau le plus proche: les classes naturelles sont détectées automatiquement.

Figure 1: Principe de l'algorithme des nuées dynamiques.

L'algorithme fournit, itérativement, une partition d'une population en un nombre de classes fixé a priori, en maximisant le critère d'inertie interclasse associé à cette partition. La figure 1 donne le principe de cette méthode. La métrique choisie est la métrique euclidienne usuelle. Chaque itération de l'algorithme se fait en deux étapes. Dans la première, dite d'affectation, un individu est affecté à la classe dont il est le plus proche. Cette proximité est mesurée par la distance au centre de gravité de la classe. Dans la seconde, dite de représentation, à chaque classe est

associée un nouveau noyau qui est son centre de gravité. Chacune de ces étapes fait croître le critère d'inertie interclasse. L'algorithme converge en un nombre fini d'itérations vers un optimum dépendant des conditions initiales. Le résultat est la répartition de l'ensemble des blocs en un nombre de classes. Cette répartition sert d'ensemble d'apprentissage pour la méthode de discrimination non paramétrique (DNP).

2.2- Discrimination non paramétrique [15]

La construction de l'arbre de décision binaire, devant mener à la réalisation du classifieur automatique, fait appel à une méthode de discrimination non paramétrique, c'est-à-dire qu'aucune hypothèse n'est faite sur les distributions de probabilités des groupes à discriminer. L'objectif est de construire une règle de décision permettant de bien reconnaître les classes de blocs, en effectuant une sélection des paramètres les plus discriminants parmi l'ensemble des paramètres, ayant servi à répartir les différents blocs en 7 classes. Ceci permet l'optimisation du nombre de paramètres devant servir à réaliser le classifieur. Une des représentations de ces méthodes est l'arbre binaire de décision. Cet arbre (Fig. 2) est construit de manière récursive en sélectionnant à chaque nœud la meilleure question binaire. Seuls les paramètres les plus discriminants sont utilisés pour la réalisation du classifieur automatique.

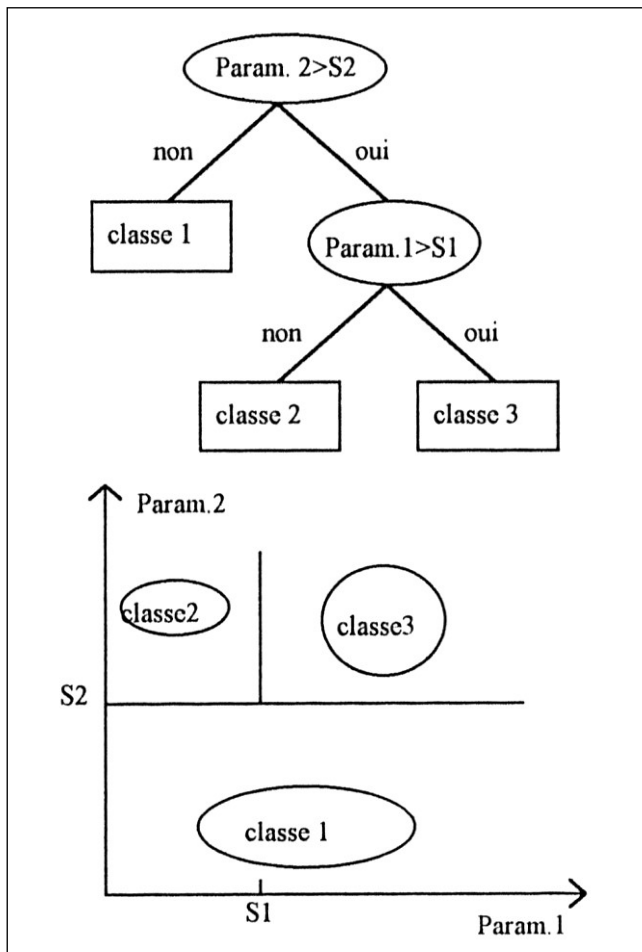


Figure 2: Arbre de décision binaire avec deux paramètres et trois classes.

3. RESULTATS

La base de données utilisée consiste en un ensemble de 9 images, représentant différentes modalités, de taille 128×128 , codées sur 8 bits, c'est-à-dire ayant une dynamique de 256 niveaux de gris (Fig. 3).

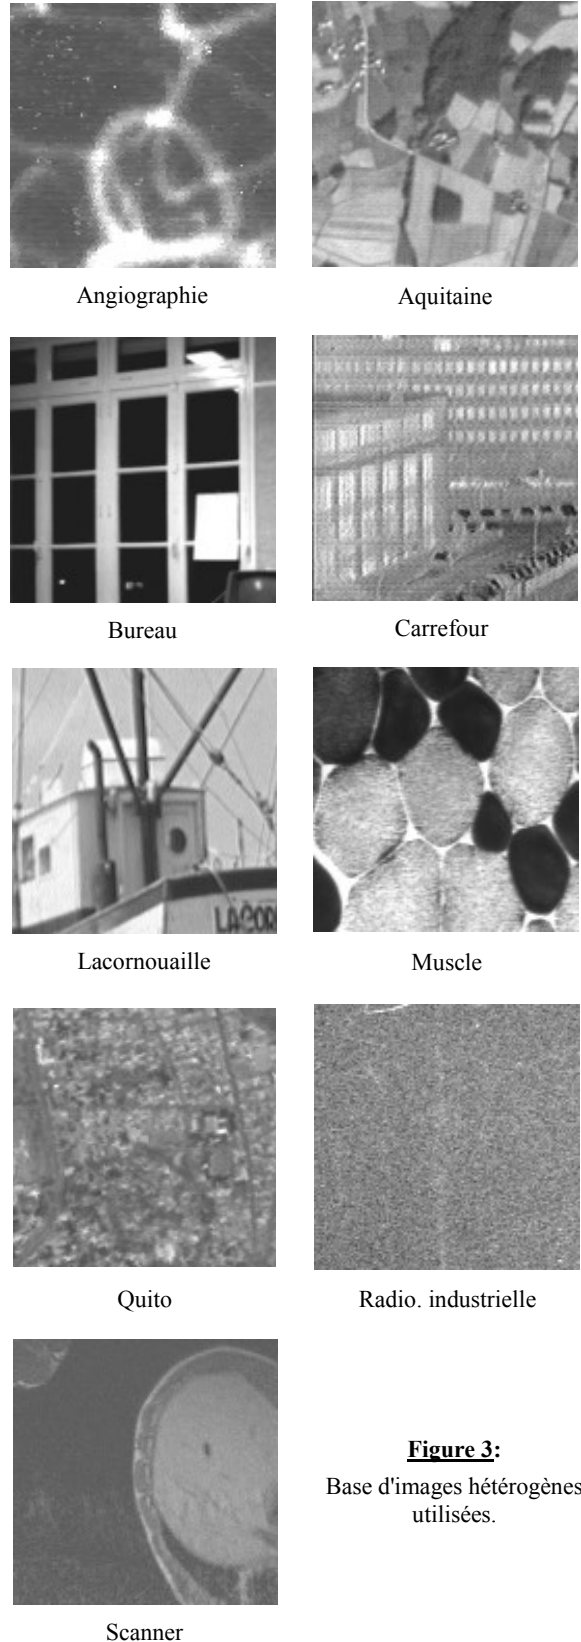


Figure 3: Base d'images hétérogènes utilisées.

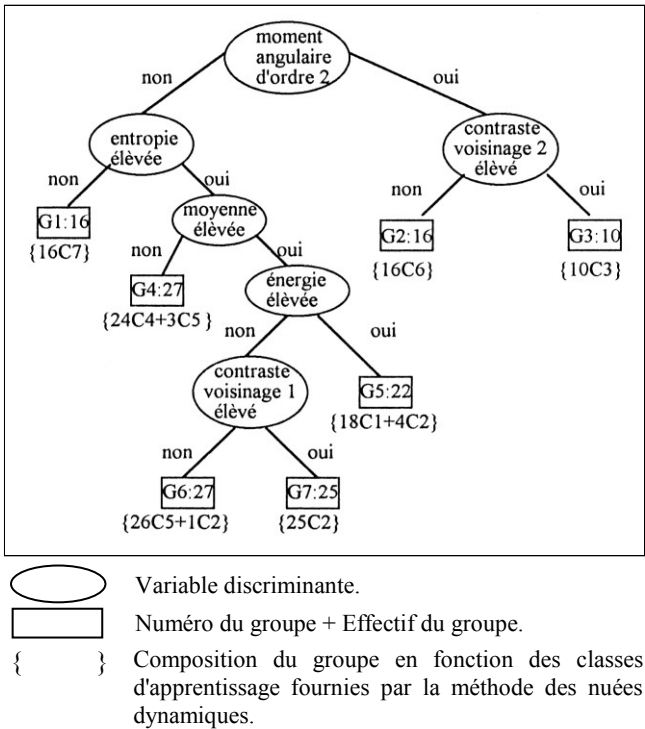


Figure 4: Arbre de décision binaire: cas des blocs 32x32.

3.1- cas des blocs 32x32

Parmi l'ensemble des paramètres de départ, seuls 19 sont retenus pour être introduits comme ensemble d'apprentissage pour la méthode des nuées dynamiques. Celle-ci permet la répartition des 144 blocs en 7 classes fixées à priori. Ce nombre est choisi en fonction de la base d'images et de la taille du bloc. Enfin, à partir de cette répartition la DNP permet de sélectionner les paramètres les plus discriminants donnant pratiquement la même classification. Le résultat obtenu permet de construire l'arbre de décision (Fig. 4), dont l'étude montre que seuls 6 paramètres, parmi les 19 sélectionnés, sont utilisés.

Le classifieur automatique, que nous réalisons et qui permet de classer tout autre individu n'appartenant pas à la base d'apprentissage, utilise donc les 6 paramètres suivants:

- moment angulaire d'ordre 2 pas 1 (ASM 1):

$$ASM1 = \sum_{i=0}^K P(i)^2$$

- moyenne (MOY 1):

$$MOY1 = \sum_i^k i.P(i) / k$$

- contraste pas 1 et 2 (CON 1, CON 2):

$$CON1 = \sum_i \sum_j (i - j)^2 P(i, j)$$

- entropie pas 1 (ENT1):

$$ENT1 = - \sum_i \sum_j P(i, j) \log(P(i, j))$$

- énergie spectrale (ENEF):

$$ENEF = \sum_u \sum_v^M \|\mathbf{F}(u, v)\|^2$$

3.2- cas des blocs 16x16

Dans ce cas, le nombre de classes fixé à priori, pour la méthode des nuées dynamiques, est de 10. A partir de la répartition des blocs sur ces 10 classes, la DNP mène à la reconstruction d'un arbre de décision similaire à celui de la figure 3, sauf que dans ce cas, seuls 10 paramètres sur les 20 sélectionnés pour la méthode des nuées dynamiques, sont utilisés pour l'arbre. Ces 10 paramètres, les plus discriminants, serviront à réaliser le classifieur automatique dans le cas des blocs 16x16.

Les figures 5 et 6 montrent des images de la base classifiées par les deux classifieurs réalisés.




Figure 5: Exemple d'images classées à l'aide du classifieur automatique, cas des blocs 32x32.

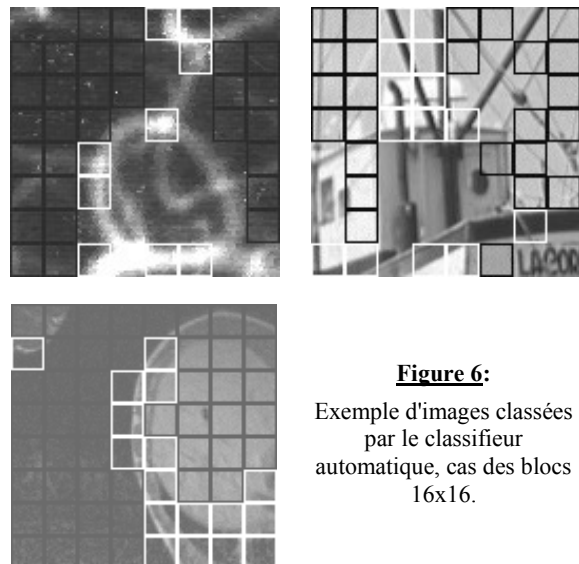


Figure 6: Exemple d'images classées par le classifieur automatique, cas des blocs 16x16.

La comparaison des images classifiées (Fig. 5 et 6) montre que les blocs identiques se retrouvent dans les mêmes classes. Cependant, lorsqu'on prend des blocs de taille 16x16, la classification est mieux affinée que pour les blocs 32x32, malgré l'augmentation du nombre des classes. Les détails noyés dans les blocs 32x32 sont placés cette fois

dans des classes qui leur sont plus proches. Ceci s'explique par le fait que les blocs étant plus petits, il y a plus de chance qu'ils renferment la même "information". Donc, le choix de l'un ou l'autre des classifieurs automatiques est subordonné à la dimension des zones de l'image que l'on cherche à étudier, ainsi qu'à son degré de stationnarité.

4. ROBUSTESSE DES CLASSIFIEURS EN PRESENCE DE BRUIT

Dans le but de mesurer l'efficacité des classifieurs en présence de bruit, on ajoute à chacune des images de la base de données un bruit gaussien, dans un rapport signal à bruit variant. L'image obtenue est telle que:

$$f(x, y) = s(x, y) + b(x, y)$$

où $s(x, y)$ est l'image originale, $b(x, y)$ est l'image de bruit et $f(x, y)$ est l'image résultante ou bruitée.

L'addition de bruit à l'image se traduit par une perte d'information, et donc une dégradation ou distorsion de l'image. On associe à cette distorsion un rapport signal sur bruit (RSB), défini par:

$$RSB = 10 \log_{10} \frac{M \times N (2^b - 1)^2}{\sum_{i=0}^{M-1} \sum_{j=0}^{N-1} (L_{ij} - \hat{L}_{ij})^2}$$

où $M \times N$: taille de l'image et $(2^b - 1)$ est la valeur crête à crête des pixels de l'image originale.

L_{ij} : valeur du pixel aux coordonnées (i, j) .

\hat{L}_{ij} : valeur du pixel de l'image bruitée aux coordonnées (i, j) .

Les paramètres, retenus pour la réalisation des deux classifieurs, sont alors calculés pour toutes les images bruitées dans un rapport signal sur bruit variant de 61,58 dB à 32,52 dB. Les résultats obtenus sont donnés dans les tableaux 1 et 2.

L'étude des tableaux 1 et 2 montre qu'en fonction du rapport signal sur bruit, la base d'image se répartit en 3 grandes catégories:

- Les images pour lesquelles les paramètres des classifieurs sont très sensibles au bruit. Leurs blocs changent de classes même s'ils sont très légèrement bruités, comme l'image de radiographie industrielle (en particulier dans le cas des blocs 32x32). Cette image est constituée de blocs homogènes et très faiblement contrastés, l'introduction du bruit même avec un faible rapport apportant une perturbation suffisante pour que les blocs de cette image changent de classe.

- Les images pour lesquelles les paramètres des classifieurs sont très stables et qui ne sont pas influencées, ou peu, par le bruit, comme l'image du Scanner: les blocs de cette image se répartissent entre la classe 4 et la classe 3. Ces dernières sont déterminées par une faible homogénéité et une forte entropie; aussi, en ajoutant le bruit, on ne fait qu'accentuer l'hétérogénéité des blocs et donc ils se maintiennent dans les mêmes classes.

- Les images pour lesquelles les paramètres des classifieurs évoluent, plus ou moins rapidement, en fonction du bruit, par exemple, l'image Bureau: les blocs de cette image sont essentiellement constitués de zones homogènes

RSB (dB)	61,58	52,96	47,78	41,98	38,51	36,03	32,52
Angiographie	80	75	62,5	62,5	62,5	50	25
Aquitaine	93,75	0	0	0	0	0	0
Bureau	82,25	75	43,75	37,5	37,5	31,25	31,25
Carrefour	78	75	75	68,75	68,75	68,75	68,75
Lacornouaille	70	62,5	62,5	62,5	62,5	62,5	56,25
Muscle	75	68,75	68,75	68,75	68,75	68,75	56,25
Quito	98	93,75	90	87,5	87,5	87,5	81,25
Radio. Ind	0	0	0	0	0	0	0
Scanner	95	95	90,55	90,55	88,25	87,5	68,75

Tableau 1: Pourcentage de blocs (32x32) bien classés en fonction du rapport signal sur bruit (RSB).

RSB (dB)	61,58	52,96	47,78	41,98	38,51	36,03	32,52
Angiographie	78,25	75	75	75	68,75	68,75	62,5
Aquitaine	81,25	81,25	81,25	81,25	81,25	81,25	75
Bureau	75	68,75	68,75	68,75	62,50	62,50	37,50
Carrefour	43,75	43,75	43,75	43,75	43,75	43,75	43,75
Lacornouaille	81,25	25	0	0	0	0	0
Muscle	87,5	12,5	0	0	0	0	0
Quito	81,25	0	0	0	0	0	0
Radio. Ind.	93,75	62,5	0	0	0	0	0
Scanner	87,5	81,25	81,25	81,25	75	75	75

Tableau 2: Pourcentage de blocs (16x16) bien classés en fonction du rapport signal sur bruit (RSB).

dont les contours sont très nets: on passe de zones noires à des zones blanches ou grises. Tant que le rapport sur bruit est fort, il ne perturbe pas l'homogénéité de ces zones, mais son effet commence à apparaître dès que ce rapport diminue.

D'une façon générale, la taille des blocs semble avoir un effet sur la valeur des paramètres du classifieur automatique. Un des exemples les plus frappants est celui de l'image Aquitaine: dans le cas des blocs 32x32, les paramètres du classifieur, très sensibles au bruit, deviennent quasiment insensibles dans le cas des blocs 16x16. A notre avis, ce phénomène trouve son explication dans le fait que d'une part, le bruit, de moyenne nulle, est ajouté d'une manière aléatoire à l'ensemble de l'image, alors que le calcul des paramètres se fait sur des blocs de taille beaucoup plus réduite que l'image originale. D'autre part, le classifieur des blocs 16x16 utilisent des paramètres en plus dont certains peuvent être plus résistants au bruit.

CONCLUSION

Dans ce travail, une méthodologie de réalisation d'un classifieur automatique de blocs d'images est présentée. Deux tailles de blocs, 32x32 et 16x16 pixels, sont utilisées pour découper les images. Pour chaque bloc, plus de 90 paramètres caractéristiques sont calculés.

Une méthode de classification non supervisée, basée sur l'utilisation complémentaire d'une technique des nuées dynamiques et d'une technique de discrimination non paramétrique, est proposée. La première permet la séparation des blocs d'image en un nombre de classes fixé a priori. A partir de cette répartition, on construit un arbre de

décision binaire par la méthode de discrimination non paramétrique. Cet arbre permet de réaliser un classifieur automatique, logiciel qui permet la classification d'un individu n'appartenant pas à l'ensemble d'apprentissage. Cette partition des individus est basée sur les propriétés mathématiques les plus caractéristiques de notre population. Alors, dans la mesure où ces individus sont classés par groupe de propriétés, il est juste de penser que cela va permettre des traitements adaptés à chacun de ces blocs, si on fait l'hypothèse que les caractéristiques mathématiques des blocs nous renseignent sur le type de traitement à adopter (car chacun de ces paramètres traduit une propriété spécifique du bloc de l'image).

L'étude de ces classifieurs en présence de bruit montre que selon le type d'image et la taille des blocs utilisés pour l'analyse, les paramètres de ces classifieurs peuvent être sensibles, insensibles ou évoluant avec la dynamique du bruit ajouté. Mais d'une façon générale, jusqu'à un RSB = 41,98 dB, les paramètres de ces classifieurs sont insensibles au bruit.

Les résultats obtenus sont très satisfaisants. Les classifieurs conduisent à une bonne discrimination des blocs. L'avantage de ces classifieurs réside dans leur simplicité (peu de paramètres utilisés). Leur implantation facile sur PC en fait un outil de travail performant. D'autre part, le fait que les paramètres soient connus et, pour la plupart, physiquement interprétables, offre l'intérêt d'une meilleure analyse en vue d'un traitement ultérieur (tels que compression adaptative, identification de zones dans les images médicales, etc.). Enfin la méthodologie, présentée dans ce papier, peut être applicable à n'importe quelle base d'images. L'utilisateur de ce produit peut générer son propre classifieur, en utilisant une autre base d'images personnelles. De même, nous pensons qu'elle pourrait être utilisable dans le cas des images 3D.

BIBLIOGRAPHIE

- [1]- Haralick R.M., Shanmugam K., et Dinstein I., "Textural features for image classification", *IEEE Trans. on Syst., Man, Cybern.*, vol. SMC-3, Nov. (1973), pp. 610-621.
- [2]- Galloway M.M., "Texture classification using gray level run lengths", *Computer Graphics and Image Processing*, vol. 4, Juin (1975), pp. 172-179.
- [3]- Maloigne C., Smolarz A., Bouvier J.M., "Caractérisation de biscuits extrudés par des méthodes statistiques d'analyse de texture", *Traitement du signal*, vol. 6, N°3, (1989), pp.929-948.
- [4]- Liu S.S. et Jernigan M.E., "Texture analysis and discrimination in additive noise", *Computer vision, graphics and image processing*, vol. 49, (1990), pp. 52-67.
- [5]- Weszka J.S., Dyer C.R. et Rosenfeld A., "A comparative study of texture measures for terrain classification", *IEEE Trans. on Syst., Man, Cybern.*, vol. SMC-6, Avril (1976), pp. 269-285.
- [6]- Siew L.H., Hodgson R.M., Wood E.J., "Texture measures for carpet wear assessment", *IEEE Trans. on Patter., Anal., and Mach. Intell.*, Vol. 10, N°1, Janvier (1988), pp. 92-105.
- [7]- Dupont F., "Analyse d'images et reconnaissance des formes: application à l'identification automatique des défauts de surface sur toles décapées", Thèse de Doctorat, INSA de Lyon, (1994), 208 p.
- [8]- He D., Wang L., "Détection des contours de texture d'images numériques", *Int. J. Remote Sensing*, Vol.12, N°3, (1991), pp. 651-657.
- [9]- MASSIC 1, "Statistical analysis and clustering of images in the data base", AIM, Bruxelles MASSIC 1 Report, project number A2009, July (1993), 36 p.
- [10]- Haralick R.M., "Statistical and structural approaches to texture", *IEEE Proc.*, Vol. 67, N°5, (1979), pp.786-804.
- [11]- Sun C., Wee W.G., "Neighboring gray level dependance matrix for texture classification", *Computer Vision, Graphics and Image Processing*, Vol. 23, (1983), pp. 341-352.
- [12]- Cover T., Hart P.E., "Nearest neighbour pattern classification", *IEEE Trans. on Information Theory*, vol. 13, (1967), pp. 21-27.
- [13]- Diday E., Lemaire J., Pouget J., Testu F., "Eléments d'analyse de données", Paris, Dunod, (1982), 464 p.
- [14]- Duda R.O., Hart P.E., "Pattern classification and scene analysis", New York, Wiley, 220 p.
- [15]- Celeux G., "Analyse discriminante sur variable continue", INRIA, collection didactique, (1990), 188 p. □
- [1]- Haralick R.M., Shanmugam K., et Dinstein I., "Textural