

# Fusion de données images segmentées à l'aide du formalisme de Dempster Shafer

Michèle ROMBAUT

LM2S-UTT, IUT de Troyes  
12 Rue Marie Curie, BP2060, 10010 TROYES CEDEX, France  
Michele.Rombaut@univ-troyes.fr

**Résumé** – Ce papier présente une méthode de classification d'objets non supervisée à l'aide du formalisme de Dempster Shafer, classification basée sur la fusion de données numériques de type différent ou provenant de sources différentes. Pour un attribut donné de l'objet, on ne dispose d'aucune information sur la caractérisation des classes ainsi que du nombre de classes a priori, mais l'on dispose d'un grand nombre de mesures non classées. Une première classification est faite pour chaque attribut, et à chaque classe on associe la confiance (masse d'évidence) pour que l'objet considéré appartienne effectivement à cette classe. En réalisant une extension des distributions de masses aux espaces de discernement associés aux différents attributs, on peut faire une fusion des informations pour obtenir une classification finale tenant compte de tous les attributs.

**Abstract** – This paper presents a method of non supervised classification based on the numerical data fusion with the Dempster Shafer's formalism. For a particular attribut of an object, there is no information about the classes. A first classification is done for each attribut, and for each class a confidence (mass of evidence) is associated. Then, an extension of these distributions of mass to the combination of the frames of discernment is made for the different attributs. After that, a Dempster's combination of these new distributions can be made in order to get a classification taking into account all the attributs of the objects.

## 1 Position du problème

Il s'agit de donner un avis sur l'appartenance d'un objet  $\mathcal{O}$  à une classe  $C$  particulière, c'est à dire de quantifier la confiance que l'on peut avoir sur l'appartenance de cet objet à la classe considérée en prenant en compte la mesure des différents attributs de cet objet. Dans cet article, on dispose de deux observations de cet objet correspondant soit à deux attributs numériques différents, soit deux mesures différentes du même attribut numérique (par deux capteurs différents par exemple). La méthode peut être étendue à un nombre plus important d'attributs. Dans de nombreux cas, la décision est généralement prise à partir de seuils définis sur l'histogramme des mesures [1] ou sur des paramètres tels que la distance, la similarité ou autres [2]. Souvent, la confiance dans la décision n'est pas modélisée. Quand elle l'est, c'est par une probabilité, une possibilité, ou une mesure d'évidence [3].

Cette étude est basée sur les travaux de A. Dromigny [4], où chacune des classes est modélisée dans l'histogramme par une Gaussienne. Dans le cadre des travaux présentés ici, la confiance sur l'appartenance de l'objet aux différentes classes est modélisée par une distribution de masse d'évidence [5].

Pour réaliser la classification pour chaque attribut, on dispose d'observations similaires de nombreux objets pour lesquels on n'a aucune information concernant leur classe. Il s'agit donc bien de classification non supervisée.

Les différentes classes possibles  $C_i$  sont inconnues, c'est à dire qu'on ne connaît ni leur nombre, ni leur caractérisation en fonction des attributs qui sont mesurés. On suppose que ces derniers sont judicieusement choisis, c'est à

dire qu'ils apportent de l'information sur au moins quelques unes des classes possibles. Les informations peuvent être complémentaires et/ou redondantes.

Pour illustrer la méthode, on prendra l'exemple de deux images dont les modalités d'observation sont différentes. Les objets à classer sont les pixels et les attributs numériques utilisés sont les niveaux de gris. Il s'agit de faire la segmentation de l'image en ne prenant en compte que les niveaux de gris, et donc pas leur position dans l'image. Cette méthode peut être généralisée pour d'autres attributs de type différents, ou même d'autres objets.

## 2 Classification par rapport à un attribut

Une première classification des objets est réalisée pour chaque attribut. L'objectif est de déterminer les classes  $C_i$  auxquelles peuvent appartenir les objets et définir la confiance que l'on peut avoir sur l'appartenance d'un objet à ces classes. La confiance est modélisée par une distribution de masse pour chaque valeur de l'attribut. La méthode utilisée est largement présentée dans [6], on en rappelle ici les grands principes.

On dispose d'un ensemble de mesures de l'attribut  $x$  prenant des valeurs dans  $\Omega_x = [x_{min}, x_{max}]$  sur les différents objets observés  $\mathcal{O}$ , et donc de l'histogramme  $h(x)$  de ces mesures sur cet espace de définition. La figure 1 représente une image originale formée de 5 classes dont deux sont très proches en terme de niveau de gris, et son histogramme.

Un capteur ne peut être parfait, on définit donc son

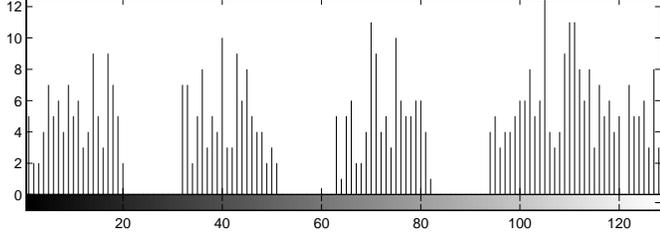
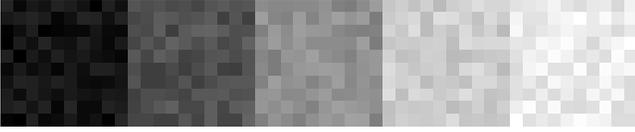


FIG. 1: Image originale et son histogramme

erreur de précision  $\epsilon$  par l'intervalle de précision associé à la valeur de mesure  $x$  :  $I_x = [x - \epsilon, x + \epsilon]$ . Cela signifie que si l'on mesure  $x$ , la vraie valeur de l'attribut se situe dans  $I_x$ .

La première phase de la méthode consiste à calculer l'histogramme des intervalles de précision  $I_x$  en définissant  $h(I_x) = \sum_{x \in I_x} h(x)$ . La figure 2 représente l'histogramme de ses intervalles de précision pour  $\epsilon = 4$ . On voit clairement que, compte tenu de l'imprécision des mesures, on ne pourra discerner que 4 classes.

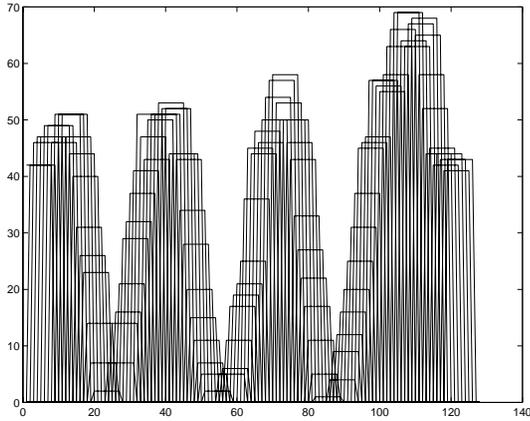


FIG. 2: Histogramme des intervalles de précision

On détermine donc les classes  $C_i$  définies par un intervalle  $I_{C_i}$  sur  $\Omega_x$  en cherchant les minima de l'histogramme qui correspondent aux bornes des classes. Quand un minimum entre deux classes  $C_i$  et  $C_j$  est trouvé, on mémorise la valeur de l'histogramme  $h(I_x)$ , puis on crée une nouvelle classe composée  $C_{i,j} = C_i \cup C_j$  qui est définie par l'intervalle  $I_{C_{i,j}}$ . Il est à noter qu'à la fin de la décomposition  $I_{C_{i,j}} \neq I_{C_i} \cup I_{C_j}$ . L'ensemble  $\Omega_C$  des classes ainsi obtenues correspond à l'espace de discernement, et  $\mathcal{F} = \{C_{i,j}\} \subset 2^{\Omega_C}$  est l'ensemble des classes (composées et singleton). Dans l'exemple proposé, on trouve les classes présentées dans le tableau 1.

À la fin de la décomposition, à chaque valeur de  $x$  correspond un ensemble de classes  $\mathcal{F}^x = \{C_i^x\}$  qui forme les

TAB. 1: Classes de l'exemple

Classe	Intervalle	$h(I_x)$ max	$h(I_x)$ min
$C_1$	[88, 128]	69	11
$C_2$	[58, 87]	58	11
$C_3$	[26, 55]	53	14
$C_4$	[1, 25]	51	14
$C_{3,4}$	[1, 56]	14	7
$C_{1,2}$	[57, 128]	11	7
$C_{1,2,3,4}$	[1, 128]	7	0

éléments focaux de la distribution de masse  $m^x$  associée à la valeur  $x$  telles que  $I_1^x \subset I_2^x \subset \dots \subset I_n^x$ . La masse  $m^x(C_i)$  associée à chacune de ces classes  $C_i$  est proportionnelle à la différence entre les valeurs minimum et maximum de l'histogramme  $h(I_x)$  dans l'intervalle  $I_{C_i}$ .

Sur la figure 3, on voit sur le premier graphe les distributions de masse sur les 4 classes singleton et sur le deuxième graphe, celles sur les classes composées.

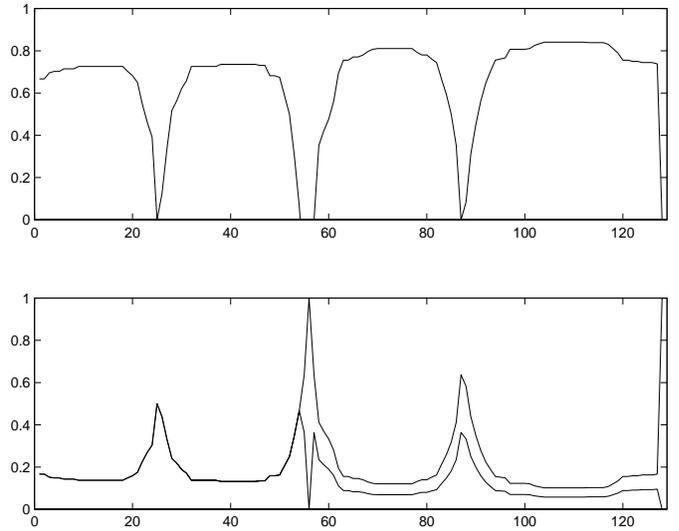


FIG. 3: Distribution de masses des classes singleton et des classes composées

Pour une mesure  $x$  faite sur l'objet  $\mathcal{O}$ , on obtient une distribution  $m^x$  définie sur  $\mathcal{F}$ . On peut affecter à l'objet  $\mathcal{O}$  la classe ayant le maximum de plausibilité, par exemple. Cette classification est faite pour chaque attribut de l'objet  $\mathcal{O}$ . On a représenté sur la figure 4 le résultat de la classification. Les pixels blancs sont ceux dont la classe ayant la plausibilité maximale est une classe composée.

### 3 Mise en correspondance

On dispose maintenant de deux sources d'information. Par la méthode présentée ci-dessus, on obtient deux espaces de discernement  $\Omega_C^1$  et  $\Omega_C^2$ .

#### 3.1 Méthode classique

Quand on veut combiner deux distributions de masses  $m_1$  et  $m_2$  définies sur des espaces de discernement diffé-

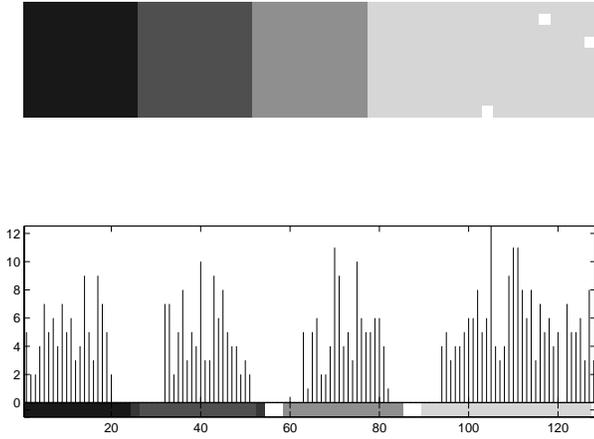


FIG. 4: *Classification des pixels*

rents  $\Omega_C^1$  et  $\Omega_C^2$ , il faut d'abord faire leur extension sur  $\Omega_C^{1,2} = \Omega_C^1 \times \Omega_C^2$ , afin qu'elles aient même espace de discernement. Par exemple, la masse étendue de l'hypothèse  $C_i \in \Omega_C^1$  est  $m_{1,2}(C_i^1, \Omega_C^2) = m_1(C_i^1)$ .

Cette méthode a l'inconvénient majeur d'accentuer l'explosion combinatoire qui est déjà le point faible de la théorie de Dempster Shafer.

### 3.2 Simplification de $\Omega_C^i$

Pour chaque attribut  $x$ , certaines classes composées peuvent n'être élément focal d'aucune des distributions de masse  $m^x$  pour tous les  $x \in \Omega_x$ . Ils peuvent donc éliminés. Dans l'exemple donné ci-dessus, quelque soit  $x$ ,  $m^x(C_1, C_3) = 0$ . La classe composée  $C_1, C_3$  n'est élément focal d'aucune distribution de masse.

### 3.3 Méthode de résolution

Si les informations obtenues par les deux sources sont effectivement discriminantes, il est fort probable que certaines classes  $C_i^{1,2}$  de  $\Omega_C^{1,2}$  telles qu'elles ont été définies précédemment ne correspondent à aucun objet, elles n'ont pas de réalité physique. Il faut alors les éliminer ce qui permet d'alléger le processus de combinaison. Ceci est réalisé à l'aide de la matrice de correspondance  $\mathcal{M}$ .

A l'aide de tous les objets  $\mathcal{O}$ , on construit la matrice de correspondance  $\mathcal{M}$  qui permet de définir les liens entre les classes  $C_k^{1,2} = (C_i^{x_1}; C_j^{x_2})$  en mettant un 1 dans  $\mathcal{M}(i, j)$ , ce qui indique que ces deux classes peuvent être mises en correspondance. On crée l'ensemble des classes  $C_k^{1,2}$  de  $\Omega_C^{1,2}$ . Par cette méthode, on a encore simplifié  $\Omega_C^{1,2}$  qui forme le nouvel espace de discernement et donc apporté une solution à l'explosion combinatoire.

La distribution de masse permettant de quantifier la croyance sur l'appartenance de l'objet aux classes de  $\Omega_C^{1,2}$  est obtenue par la combinaison de l'extension des masses  $m^{x_1}$  et  $m^{x_2}$  sur  $\Omega_C^{1,2}$  en fonction de ses attributs  $x_1$  et  $x_2$ . La classification peut être faite en utilisant le maximum de plausibilité.

## 4 Exemple d'illustration de la méthode

La méthode a été testée sur des images de synthèse et des images réelles. Les objets à classer sont les pixels en fonction de leur niveau de gris. La figure 5 donne les deux images originales. Celles-ci ont été segmentées indépendamment en fonction du niveau de gris des pixels figure. Pour chacune d'elles, seulement trois classes ont été détectées (au lieu de 4). Les pixels blancs sont ceux qui ne sont pas classés car ils correspondent à un niveau de gris trop peu représenté. Le résultat de la fusion est présenté sur la figure 7. L'image résultante de la fusion montre qu'une classe de trop a été créée (niveau de gris à 0.5) mais elle est très peu représentée. Les pixels de niveau de gris à 0.1 sont ceux qui ne sont pas classés.

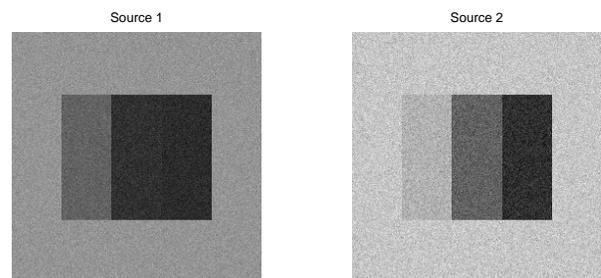


FIG. 5: *Images sources de synthèse*

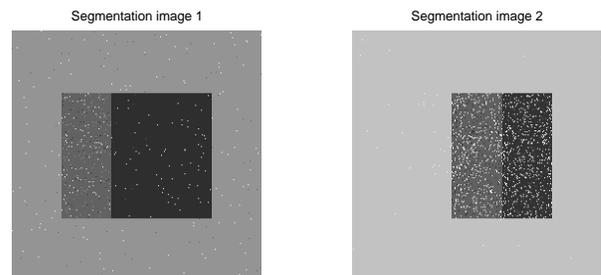


FIG. 6: *Images sources segmentées*

D'autres essais ont été réalisées sur des images réelles. Il s'agit d'images IRM de cerveau prises suivant des modes différents et comportant des lésions. Ces images ont été prêtées par le laboratoire CREATIS à l'INSA de Lyon. La figure 8 correspond aux deux images originales, et la figure 9 est le résultat. Les pixels blancs sont ceux qui pourraient correspondre à une classe caractéristique des lésions.

## 5 Conclusion

La méthode proposée se décompose en deux étapes, une première étape de segmentation mono-attribut. Celle-ci a la particularité de prendre explicitement en compte la précision du capteur par l'intermédiaire des intervalles de précision. La grandeur de ces intervalles est définie par l'expertise dont on dispose sur le capteur et sur les connais-

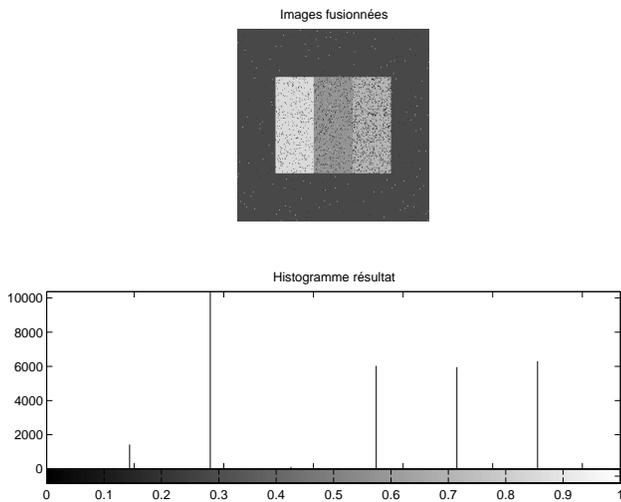


FIG. 7: Image segmentée résultat de la fusion

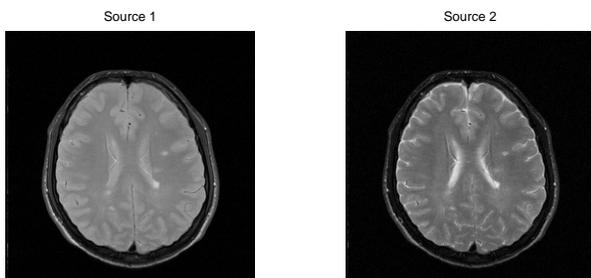


FIG. 8: Images originales

sances a priori que l'on peut avoir sur les classes d'objets à caractériser. La définition des classes à partir de l'histogramme des intervalles de précision permet de modéliser le doute sur l'appartenance d'un objet à une classe. En effet, dès que le nombre d'éléments devient trop faible (inférieur à la vallée entre deux classes), un objet est considéré appartenir à l'union des deux classes considérées. Pour une valeur d'attribut donnée, la distribution de masse pour chaque classe est faite au prorata des éléments de cette classe dans l'histogramme.

La deuxième partie de l'algorithme consiste à fusionner ces distributions de masse définies sur des espaces de dis-

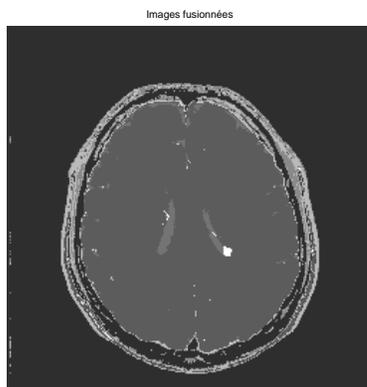


FIG. 9: Image résultat de la fusion

cernement différents. Pour éviter l'explosion combinatoire, on propose de simplifier l'espace de discernement d'une part grâce au fait que pour une valeur d'attribut les classes éléments focaux sont emboîtées, et d'autre part parce que les attributs sont censés caractériser au moins partiellement les classes d'objets.

Des résultats satisfaisants ont été obtenus sur des données images réelles ou de synthèse, en prenant uniquement les niveaux de gris comme attribut de pixel. La méthode peut être utilisée sur tout type d'objet et tout type d'attribut numérique.

Dans le domaine du traitement d'image, on dispose pour chaque pixel d'une distribution de masse sur les différentes classes possibles. Il serait intéressant d'affiner cette classification en prenant en compte, pour chaque pixel, la connaissance que l'on a sur les pixels voisins, c'est à dire la distribution de masse associée. On pourra par exemple s'inspirer des champs de Markov.

## Références

- [1] B. W. Silverman. Density estimation for statistics and data analysis. In Chapman & Hall, editor, *Monographs on statistics and applied probability 26*. Springer Verlag, 198.
- [2] H. Bandemer and W. Nather. Fuzzy data analysis. In *Series B: Mathematical and statistical methods*. Theory and decision library, Kluwer Academic Publishers, 1992.
- [3] H. Maitre I. Bloch. Fusion de données en traitement d'images: modèles d'information et décisions. *Traitement du signal*, 11(6):435–446, 1994.
- [4] A. Dromigny-Badin. *Fusion d'images via la théorie de l'évidence en vue d'applications médicales et industrielles*. Thèse de 3e cycle, INSA de Lyon, 6 Mai 1998.
- [5] G. Shafer. *A mathematical theory of evidence*, volume 2702. Princeton University Press, 1976.
- [6] M. Rombaut. Evidence classification using histogram of a measurement. *Engineering Applications of Artificial Intelligence*, 1999. soumis.