



Apprentissage de Fonctions de Croyance à partir de Dissimilarités

Thierry Denœux

Université de Technologie de Compiègne

HEUDIASYC (UMR CNRS 6599)

<http://www.hds.utc.fr/~tdenoeux>



Problèmes posés

- **Similarité/dissimilarité, distance** : notions premières en perception, reconnaissance de formes, apprentissage
- Soient :
 - n objets o_1, \dots, o_n
 - Une **matrice de dissimilarités** $D=(d_{ij})$, $d_{ij} \in \Delta$ entre ces n objets
 - d_{ij} = dissimilarité entre les objets i et j
- Les dissimilarités (distances) peuvent être **calculées à partir d'attributs** décrivant chacun des objets, ou être **observées directement** (analyse sensorielle par exemple).
- Propriétés :
 - Symétrie : $d_{ij}=d_{ji}$
 - (Inégalité triangulaire : Si $d_{ik} \leq d_{ij}+d_{jk} \rightarrow$ matrice de distances)



Problèmes posés (suite)

- Les n objets sont répartis en **K classes** (catégories)
 $\Omega = \{\omega_1, \dots, \omega_K\}$
- Deux cas :
 - On dispose d'une information concernant la classe des n objets de la base d'apprentissage (issus d'une population), et on cherche à en déduire une **règle de classement de nouveaux objets issus de la même population** → **apprentissage complètement ou partiellement supervisé**
 - On ne dispose pas d'information sur l'appartenance des objets aux classes ; on cherche à inférer **l'appartenance des objets aux classes** à partir d'hypothèses sur la forme des classes et de la matrice de dissimilarités → **apprentissage non supervisé**



Cas 1 : apprentissage supervisé

- Les données :
 - Matrice de dissimilarités $D=(d_{ij})$, $d_{ij} \in \Delta$
 - n fonctions de masses (« étiquettes crédibilistes ») $m^\Omega\{c_i\}$, $i=1, \dots, n$ sur $\Omega=\{\omega_1, \dots, \omega_K\}$, relatives à la classe c_i de chaque objet o_i .
- Problème :
 - Déterminer une fonction de masse $m^\Omega\{c_0\}$ relative à la classe d'un nouvel objet dont on connaît les dissimilarités d_{o_1}, \dots, d_{o_n} par rapport aux n objets de la base.



Cas particuliers

- Etiquetage

- Précis et certain :

- $m^\Omega\{c_i\}$ certaines : $\forall i, \exists k, m^\Omega\{c_i\}(\{\omega_k\})=1$

- Ensembliste :

- $m^\Omega\{c_i\}$ catégoriques : $\forall i, \exists A \subseteq \Omega, m^\Omega\{c_i\}(A)=1$

- Probabiliste :

- $m^\Omega\{c_i\}$ bayésiennes

- Possibiliste :

- $m^\Omega\{c_i\}$ consonantes

- ...



Cas 2 : apprentissage non supervisé

- Les données :
 - Matrice de dissimilarités $D=(d_{ij})$, $d_{ij} \in \Delta$
- Hypothèse :
 - chaque objet appartient à une classe parmi $\Omega=\{\omega_1, \dots, \omega_K\}$
- Problème :
 - Trouver n masses $m^\Omega\{c_i\}$, $i=1, \dots, n$ sur Ω , caractérisant l'appartenance des n objets aux K classes → **partition crédale**



Partition crédale : exemple

A	$m^{\Omega}\{c_1\}(A)$	$m^{\Omega}\{c_2\}(A)$	$m^{\Omega}\{c_3\}(A)$	$m^{\Omega}\{c_4\}(A)$	$m^{\Omega}\{c_5\}(A)$
\emptyset	0	0	0	0	0
$\{\omega_1\}$	0	0	0	0.2	0
$\{\omega_2\}$	0	1	0	0.4	0
$\{\omega_1, \omega_2\}$	0.7	0	0	0	0
$\{\omega_3\}$	0	0	0.2	0.4	0
$\{\omega_1, \omega_3\}$	0	0	0.5	0	0
$\{\omega_2, \omega_3\}$	0	0	0	0	0
Ω	0.3	0	0.3	0	1



Cas particuliers

- Chaque $m^\Omega \{c_i\}$ certaine \rightarrow **partition nette**
- Chaque $m^\Omega \{c_i\}$ bayésienne \rightarrow **partition floue**

$$u_{ik} = m^\Omega \{c_i\}(\{\omega_k\}), \quad \forall i, k$$

$$\sum_{k=1}^K u_{ik} = 1$$

- Chaque $m^\Omega \{c_i\}$ consonante (éléments focaux emboîtés) \rightarrow **partition possibiliste**

$$u_{ik} = pl^{\Omega_i}(\{\omega_k\})$$



Résumé

	Connu	Inconnu
Problème 1	$D = (d_{ij})$ $m^{\Omega}\{c_1\}, \dots, m^{\Omega}\{c_n\}$ d_{01}, \dots, d_{0n}	$m^{\Omega}\{c_0\}$
Problème 2	$D = (d_{ij})$	$m^{\Omega}\{c_1\}, \dots, m^{\Omega}\{c_n\}$




Solution du problème 1

- Nécessité de définir un modèle traduisant une **connaissance a priori** (même rudimentaire) sur les classes
- Soient deux objets o_i et o_j quelconques, de classes c_i et c_j . **Soit S la proposition $c_i=c_j$**
- On suppose connues les fonctions suivantes (identiques quels que soient i et j) :

$$d \rightarrow pl^{\Delta} \{d_{ij}\} [S](d) \quad \text{[fonction de plausibilité intra-classe]}$$

$$d \rightarrow pl^{\Delta} \{d_{ij}\} [\neg S](d) \quad \text{[fonction de plausibilité inter-classe]}$$

Fonctions de plausibilité inter et intra-classes





Application du GBT

- Soit $\Theta = \{S, \neg S\}$
- On connaît $pl^\Delta\{d_{ij}\}[S](d)$, $pl^\Delta\{d_{ij}\}[\neg S](d)$, $\forall d \in \Delta$
- On cherche $m^\Theta\{c_i, c_j\}[d_{ij}=d]$
- **Théorème de Bayes généralisé (TBG) :**

$$m^\Theta\{c_i, c_j\}[d_{ij} = d](A) = \prod_{\theta \in A} pl^\Delta\{d_{ij}\}[\theta](d) \times \prod_{\theta \in \bar{A}} (1 - pl^\Delta\{d_{ij}\}[\theta](d)), \quad \forall A \subseteq \Theta$$



Application du GBT (suite)

$$\begin{aligned}m^{\ominus}\{c_i, c_j\}[d_{ij} = d](\{S\}) &= pl[S](d)(1 - pl[\neg S](d)) \\m^{\ominus}\{c_i, c_j\}[d_{ij} = d](\{\neg S\}) &= pl[\neg S](d)(1 - pl[S](d)) \\m^{\ominus}\{c_i, c_j\}[d_{ij} = d](\Theta) &= pl[\neg S](d)pl[S](d) \\m^{\ominus}\{c_i, c_j\}[d_{ij} = d](\emptyset) &= (1 - pl[S](d))(1 - pl[\neg S](d))\end{aligned}$$

■ Interprétation :

- $pl[S](d) \approx 1$ et $pl[\neg S](d) \approx 0 \rightarrow m[d_{ij}=d]\{c_i, c_j\}(\{S\}) \approx 1$
- $pl[S](d) \approx 0$ et $pl[\neg S](d) \approx 1 \rightarrow m[d_{ij}=d]\{c_i, c_j\}(\{\neg S\}) \approx 1$
- $pl[S](d) \approx 1$ et $pl[\neg S](d) \approx 1 \rightarrow m[d_{ij}=d]\{c_i, c_j\}(\Theta) \approx 1$
- $pl[S](d) \approx 0$ et $pl[\neg S](d) \approx 0 \rightarrow m[d_{ij}=d]\{c_i, c_j\}(\emptyset) \approx 1$




Extension à Ω^2

- $\Theta = \{S, \neg S\}$ est un grossissement de Ω^2
 $S \equiv \{(\omega_1, \omega_1), \dots, (\omega_K, \omega_K)\} \subseteq \Omega^2$
- Extension de $m^\Theta\{c_i, c_j\}[d]$ à Ω^2


$$\begin{aligned} m^\Theta\{c_i, c_j\}[d](\{S\}) &\rightarrow m^{\Omega^2}\{c_i, c_j\}[d](S) &&\triangleq \alpha_S \\ m^\Theta\{c_i, c_j\}[d](\{\neg S\}) &\rightarrow m^{\Omega^2}\{c_i, c_j\}[d](\neg S) &&\triangleq \alpha_{\neg S} \\ m^\Theta\{c_i, c_j\}[d](\Theta) &\rightarrow m^{\Omega^2}\{c_i, c_j\}[d](\Omega^2) &&\triangleq \alpha_\Theta \\ m^\Theta\{c_i, c_j\}[d](\emptyset) &\rightarrow m^{\Omega^2}\{c_i, c_j\}[d](\emptyset) &&\triangleq \alpha_\emptyset \end{aligned}$$

Extension à Ω^2 (suite)





Combinaison avec $m^\Omega\{c_i\}$



$$m^\Omega\{c_0\}[e_i] = \left(m^{\Omega^2}\{c_0, c_i\}[d_{0i}] \odot m^\Omega\{c_i\} \right)^{\downarrow\Omega} \{c_0\}$$

avec $e_i = (d_{0i}, m^\Omega\{c_i\})$.



Résultat

$$m^{\Omega^2}\{c_0\}[e_i] = f(m^{\Omega^2}\{c_i\}, \alpha_S, \alpha_{\neg S}, \alpha_{\Theta}, \alpha_{\emptyset})$$

$$m^{\Omega}\{c_0\}[e_i](\emptyset) = \alpha_{\emptyset}(1 - m^{\Omega}\{c_i\}(\emptyset)) + m^{\Omega}\{c_i\}(\emptyset)$$

$$m^{\Omega}\{c_0\}[e_i](A) = \alpha_S m^{\Omega}\{c_i\}(A), \quad \forall A, 0 < |A| < |\Omega| - 1$$

$$m^{\Omega}\{c_0\}[e_i](A) = \alpha_S m^{\Omega}\{c_i\}(A) + \alpha_{\neg S} m^{\Omega}\{c_i\}(\bar{A}), \\ \forall A, |A| = |\Omega| - 1$$


$$m^{\Omega}\{c_0\}[e_i](\Omega) = \alpha_{\Theta}(1 - m^{\Omega}\{c_i\}(\emptyset)) + \alpha_S m^{\Omega}\{c_i\}(\Omega) \\ + \alpha_{\neg S} \sum_{B \subseteq \Omega, |B| > 1} m^{\Omega}\{c_i\}(B)$$

Combinaison sur l'ensemble d'apprentissage


$$m^{\Omega}\{c_0\}[\mathcal{A}] = \bigodot_{i=1}^n m^{\Omega}\{c_0\}[e_i]$$

avec $\mathcal{A} = (e_1, \dots, e_n)$.

Cas particulier 1



Cas particulier 1 (suite)





Cas particulier 1 (suite)

$$m^{\Omega}\{c_0\}[e_i](A) = \alpha_S m^{\Omega}\{c_i\}(A), \quad \forall A, 0 < |A| < |\Omega|$$

$$m^{\Omega}\{c_0\}[e_i](\Omega) = 1 - \alpha_S + \alpha_S m^{\Omega}\{c_i\}(\Omega)$$


avec $\alpha_S = 1 - pl^{\Delta}[\neg S](d_{0i})$.

Coefficient d'affaiblissement = $pl^{\Delta}[\neg S](d_{0i})$ fonction croissante de d_{0i}
→ les exemples les plus proches (similaires) sont les plus informatifs

Méthode introduite "empiriquement" dans :


T. Denoeux. A k -nearest neighbor classification rule based on Dempster-Shafer theory. *IEEE Transactions on Systems, Man and Cybernetics*, 25(05):804-813, 1995.

Cas particulier 2





Cas particulier 2 (suite)





Cas particulier 2 (suite)

$$m^{\Omega}\{c_0\}[e_i](\overline{\{\omega_k\}}) = \alpha_{\neg S} m^{\Omega}\{c_i\}(\{\omega_k\}), \quad \forall \omega_k \in \Omega$$


$$m^{\Omega}\{c_0\}[e_i](\Omega) = 1 - \alpha_{\neg S} + \alpha_{\neg S} \sum_{B \subseteq \Omega, |B| > 1} m^{\Omega}\{c_i\}(B)$$

avec $\alpha_{\neg S} = 1 - pl^{\Delta}[S](d_{0i})$.

Coefficient « d'affaiblissement » = $pl^{\Delta}[S](d_{0i})$ fonction décroissante de d_{0i} → les exemples les plus éloignés sont les plus informatifs



Exemple





Mise en œuvre pratique

- Définir pour $pl^\Delta[S]$ et $pl^\Delta[\neg S]$ des familles de fonctions paramétrées
- Exemple :
 - $pl^\Delta[S](d) = \exp(-\gamma_S d)$
 - $pl^\Delta[\neg S](d) = 1 - \exp(-\gamma_{\neg S} d)$
- Optimisation des paramètres par minimisation d'une fonction d'erreur

$$E(\gamma_S, \gamma_{\neg S}) = \sum_{i=1}^n C(m^{\Omega}\{c_i\}[\mathcal{A} \setminus e_i], m^{\Omega}\{c_i\})$$

Exemple : classification de signaux

EEG




- Pb : discriminer les **complexes K** du signal de fond dans des signaux EEG enregistrés pendant le sommeil (Richard, 1998).
- Complexe K = forme transitoire, utile pour l'étiquetage des stades de sommeil et le diagnostic en psychiatrie.
- Problèmes :
 - **Absence de critère objectif** : étiquetage des données par un panel d'experts ;
 - **Absence de consensus** entre les experts.

Détection de Complexes K

étiquetage
subjectif
par 5 experts

0 = onde delta
1 = complexe K





Données EEG

- K=2 classes, 64 variables (\rightarrow distance euclidienne)
- données étiquetées par 5 experts
- n=200 exemples d'apprentissage, 300 exemples de test.

k	k -ppv	k -ppv pondérés	MCT (étiquetage majoritaire)	MCT (étiquetage incertain)
9	0.30	0.30	0.31	0.27
11	0.29	0.30	0.29	0.26
13	0.31	0.30	0.31	0.26

Solution du problème 2

(apprentissage non supervisé)

- Données : matrice $D=(d_{ij})$ de dissimilarités entre n objets (données de proximités)
- Objectif : Associer à chaque objet une fonction de masse $m^\Omega\{c_i\}$ sur un ensemble de classes $\Omega=\{\omega_1,\dots,\omega_K\}$ défini a priori.
- Les n fonctions de masse $\{m^\Omega\{c_i\}, i=1,\dots,n\}$ constituent une **partition crédale** des n objets.



Principe de construction

- Soit $M = \{m^\Omega\{c_i\}, i=1, \dots, n\}$ une partition crédale de n objets.
- $\forall i, j$, la fonction de masse jointe sur l'espace produit Ω^2 est obtenue par :

$$m^{\Omega^2}\{c_i, c_j\} = m^\Omega\{c_i\} \otimes m^\Omega\{c_j\}$$

- On a :

$$\begin{aligned} pl^{\Omega^2}\{c_i, c_j\}(S) &= \sum_{\{A \times B \subseteq \Omega^2 \mid (A \times B) \cap S \neq \emptyset\}} m^{\Omega^2}\{c_i, c_j\}(A \times B) \\ &= \sum_{A \cap B \neq \emptyset} m^\Omega\{c_i\}(A) \cdot m^\Omega\{c_j\}(B) \\ &= 1 - K_{ij} \end{aligned}$$

← degré de conflit entre $m^\Omega\{c_i\}$ et $m^\Omega\{c_j\}$



Principe de construction (suite)

- Définition : Soit $M = \{m^\Omega\{c_i\}, i=1, \dots, n\}$ une partition crédale de n objets. M est **compatible avec la matrice $D = (d_{ij})$ des dissimilarités** ssi, $\forall i, j, i', j'$:

$$d_{ij} > d_{i'j'} \Rightarrow K_{ij} \geq K_{i'j'}$$

« Plus deux objets sont proches, plus il est plausible qu'ils appartiennent à la même classe »

- Recherche d'une partition crédale approximativement compatible par minimisation de :

$$I(M, a, b) \triangleq \sum_{i < j} \frac{(aK_{ij} + b - d_{ij})^2}{d_{ij}}$$

- Analogie avec le positionnement multidimensionnel (*multidimensional scaling*)



Mise en oeuvre

- Nombre de paramètres à optimiser : $n 2^K$, pour $n(n-1)/2$ dissimilarités.
- Solutions :
 - réduction des éléments focaux aux singletons $\{\omega_k\}$ ($k=1, \dots, K$), \emptyset , Ω
 - Recherche d'une partition crédale **la plus « informative »** (précise et certaine) possible par ajout d'un terme d'entropie:

$$I' = I + \lambda \sum_{i=1}^n H(m^{\Omega}\{c_i\})$$



Choix d'un critère d'entropie

- Critère de Pal et Bezdek

$$H(m) = \sum_{\{A \in 2^\Omega \setminus \{\emptyset\}, m(A) > 0\}} m(A) \log_2 \left(\frac{|A|}{m(A)} \right) + m(\emptyset) \log_2 \left(\frac{|\Omega|}{m(\emptyset)} \right)$$

- H favorise l'allocation de la masse à un petit nombre d'éléments focaux de faible cardinalité.

Exploitation des résultats

partition crédale
 $\{m^\Omega\{c_i\}, i=1, \dots, n\}$

$m^\Omega\{c_i\}(\emptyset) \approx 1 \rightarrow$ « outlier »
 $m^\Omega\{c_i\}(\Omega) \approx 1 \rightarrow$ « inlier »

Transformation pignistique


partition floue
 $\{BetP^\Omega\{c_i\}, i=1, \dots, n\}$

$$BetP(\omega) = \sum_{\omega \in A} \frac{m(A)}{(1 - m(\emptyset))^{|A|}}$$

Maximum de probabilité
pignistique

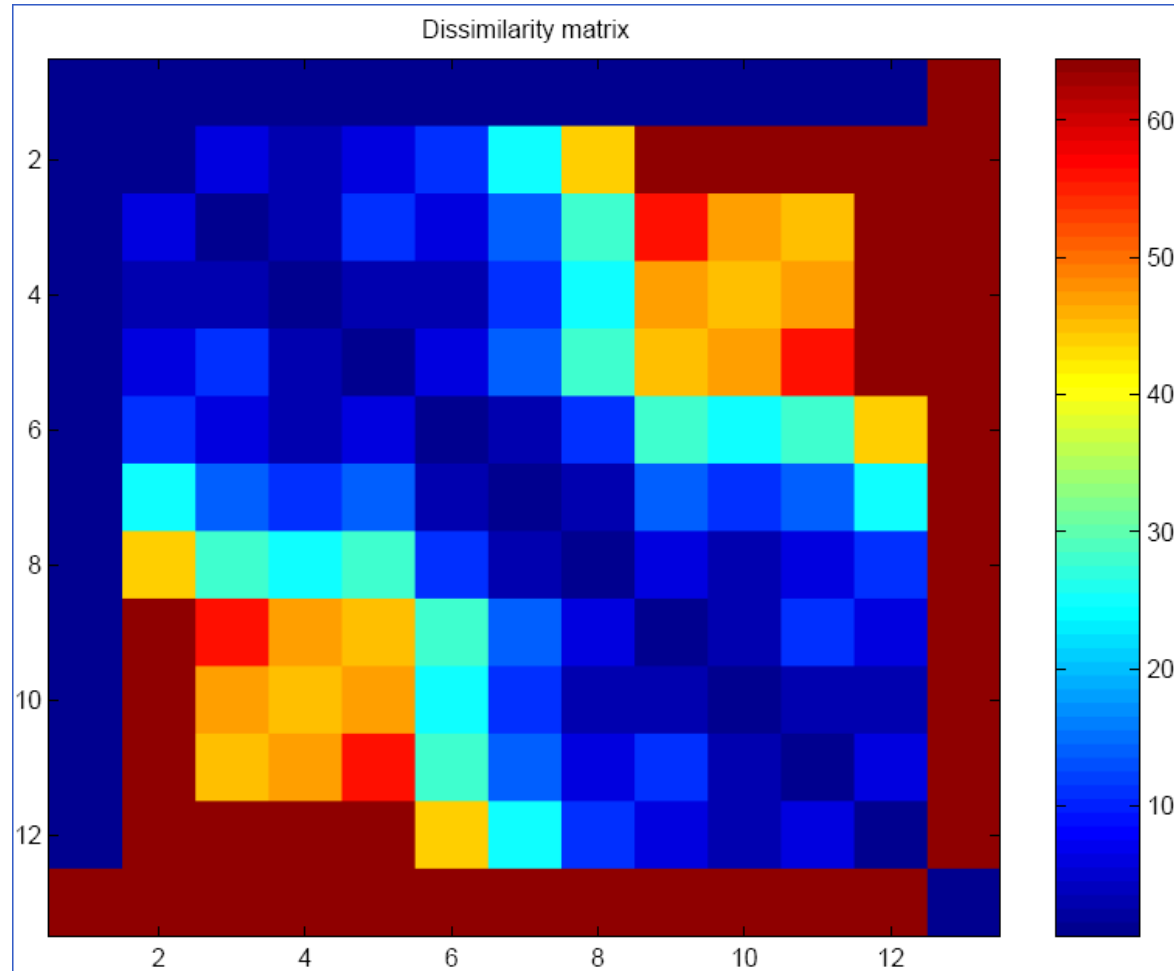
partition nette
 $u_{ik} \in \{0, 1\}$
 $i=1, \dots, n, k=1, \dots, K$

Exemple 1




+ objet 1 similaire à tous les autres objets (« inlier »)


Exemple 1: matrice de dissimilarités




Exemple 1 : résultat (masses)



Exemple 1 : résultat (plausibilités)



Exemple 2 : protéines






Données :

- comparaison structurelle de 213 protéines,
- 4 classes (hémoglobine- α et β , myoglobines, globines hétérogènes).

Protéines (suite)








$$m^{\Omega}\{c_i\}(\emptyset)$$





Exemple 3 : analyse sensorielle

13 produits,
4 descripteurs,
2 juges





Conclusion

- Construction de fonctions de croyance à partir de dissimilarités dans deux cas :
 - Apprentissage **complètement ou partiellement supervisé**
 - Apprentissage **non supervisé**
- Hypothèses explicite sur la « forme des classes » :
 - Fonctions $pl[S]$ et $pl[\neg S]$ en apprentissage supervisé
 - Hypothèse de monotonie entre d_{ij} et $pl(\neg S)$ en apprentissage non supervisé.
- Le formalisme des fonctions de croyance permet :
 - D'exploiter en apprentissage **une information incertaine et imprécise** (étiquetage imprécis par exemple)
 - De traduire le **résultat d'une analyse statistique** des données sous forme **incertaine et imprécise** (partition crédale)