

Théorie des fonctions de croyance: application en reconnaissance de formes et en fusion d'informations

Thierry Denœux

Université de Technologie de Compiègne
HEUDIASYC, UMR CNRS 6599
<http://www.hds.utc.fr/~tdenoeux>

SCATI : Théorie et applications des fonctions de croyance
pour les systèmes de vision
3 décembre 2010



Qu'est-ce que la TFC ?

Historique

- La théorie des fonctions de croyance (TFC) : un cadre formel pour le calcul et le raisonnement **à partir d'informations partielles (incertaines, imprécises)**.
- Autres dénominations : théorie de Dempster-Shafer, théorie de l'évidence, Modèle des Croyances Transférables.
- Introduit par Dempster (1968) et Shafer (1976), développé par Smets dans les années 1980 et 1990.

Qu'est-ce que la TFC ?

Relation avec les approches classiques

- La théorie des fonctions de croyance étend à la fois les approches **ensembliste** and **probabiliste** de représentation des incertitudes.
- Une fonction de croyance peut être vue comme
 - un **ensemble généralisé** et
 - une **mesure non additive** ;
- Extension de notions
 - **probabilistes** (conditionnement, marginalisation) et
 - **ensemblistes** (intersection, union, inclusion, etc.).

Qu'est-ce que la TFC ?

Applications

- Inférence statistique (Dempster, 1968) ;
- Systèmes experts (1980-) ;
- **Fusion d'informations** (1990-) ;
- **Classification, apprentissage, reconnaissance de formes** (2000-).

Plan

- 1 Théorie des fonctions de croyance
 - Concepts fondamentaux
 - Règle de Dempster
 - Règle prudente et extensions
- 2 Applications
 - Classification
 - Classification multi-label
 - Fusion adaptative de classifieurs

Outline

- 1 Théorie des fonctions de croyance
 - Concepts fondamentaux
 - Règle de Dempster
 - Règle prudente et extensions
- 2 Applications
 - Classification
 - Classification multi-label
 - Fusion adaptative de classifieurs

Fonction de masse

Définition

- Soit Ω un ensemble fini de réponses possibles à une certaine question : **cadre de discernement**.
- Une **fonction de masse (normalisée)** sur Ω est une fonction $m : 2^\Omega \rightarrow [0, 1]$ telle que $m(\emptyset) = 0$ et

$$\sum_{A \subseteq \Omega} m(A) = 1.$$

- Les parties A de Ω t.q. $m(A) > 0$ sont appelées **éléments focaux** de m .

Fonction de masse

Interprétation

- Une fonction de masse m modélise un **élément d'évidence** sur une variable X à valeur dans Ω .
- $m(A)$ s'interprète comme une mesure de la croyance **allouée exactement** à l'hypothèse $X \in A$, et à aucune hypothèse plus spécifique.

Fonction de masse

Cas particuliers

- Fonction de masse **catégorique** :

$$m(A) = 1 \text{ for some } A \subseteq \Omega$$

→ équivalente à un **ensemble**. La **fonction de masse vide**, correspondant à $A = \Omega$, représente l'ignorance totale.

- Fonction de masse **bayésienne** :

$$m(A) > 0 \Rightarrow |A| = 1$$

→ équivalent à une **distribution de probabilité**.

- Dans le cas général, une fonction de masse peut donc être vue comme :
 - un ensemble généralisé ;
 - une distribution de probabilité généralisée.



Exemple

- Un meurtre a été commis. Il y a 3 suspects :
 $\Omega = \{Pierre, Jean, Marie\}$.
- Un témoin a vu le meurtrier s'enfuir, mais il est myope et peut seulement attester que c'était un homme. On sait que le témoin est ivre 20 % du temps.
- Représentation de l'élément d'évidence :


$$m(\{Pierre, Jean\}) = 0.8,$$

$$m(\Omega) = 0.2$$

- La masse 0.2 n'est pas allouée à $\{Marie\}$, car le témoignage n'accuse absolument pas Marie !

Fonctions de croyance et de plausibilité

Definitions



$$bel(A) = \sum_{\emptyset \neq B \subseteq A} m(B)$$

$$pl(A) = \sum_{B \cap A} m(B),$$

$$pl(A) \geq bel(A), \quad \forall A \subseteq \Omega.$$

Fonctions de croyance et de plausibilité

Interprétation et cas particuliers

- Interprétations :
 - $bel(A)$ = degré de croyance en A , justifié par l'élément d'évidence considéré.
 - $pl(A)$ = borne supérieure du degré de croyance susceptible d'être alloué à A après prise ne compte de nouvelles informations.
- Cas particuliers :
 - Si m est bayésienne, $bel = pl$ (mesure de probabilité).
 - Si les éléments focaux sont emboîtés, pl est une mesure de possibilité, et bel est la mesure de nécessité duale.

Outline

- 1 Théorie des fonctions de croyance
 - Concepts fondamentaux
 - Règle de Dempster
 - Règle prudente et extensions
- 2 Applications
 - Classification
 - Classification multi-label
 - Fusion adaptative de classifieurs

Définition

- Soient m_1 et m_2 deux fonctions de masse sur Ω modélisant deux éléments d'évidence **indépendants**. Comment les combiner ?
- **Règle de Dempster** :

$$(m_1 \oplus m_2)(A) = \begin{cases} \frac{1}{1-K} \sum_{B \cap C = A} m_1(B)m_2(C) & \text{si } A \neq \emptyset \\ 0 & \text{si } A = \emptyset \end{cases}$$


avec $K = \sum_{B \cap C = \emptyset} m_1(B)m_2(C)$: **degré de conflit**.

Exemple

- On a $m_1(\{Pierre, Jean\}) = 0.8$, $m_1(\Omega) = 0.2$.
- Nouvel élément d'évidence : le meutrier est blond, confiance=0.6 $\rightarrow m_2(\{Jean, Marie\}) = 0.6$, $m_2(\Omega) = 0.4$.

	$\{Pierre, Jean\}$ 0.8	Ω 0.2
$\{Jean, Marie\}$ 0.6	$\{Jean\}$ 0.48	$\{Jean, Marie\}$ 0.12
Ω 0.4	$\{Pierre, Jean\}$ 0.32	Ω 0.08

Justification



- Chaque m_i induite par une mesure de probabilité P_i sur un ensemble Θ_i (interprétations), et une application $\Gamma_i : \Theta_i \rightarrow 2^\Omega$.
- Si les interprétations θ_1 et θ_2 sont vraies, alors il faut croire $X \in \Gamma_1(\theta_1) \cap \Gamma_2(\theta_2)$.
- L'indépendance de m_1 et m_2 correspond à l'indépendance de P_1 et P_2 .

Propriétés

- Commutativité, associativité.
- Élément neutre : fonction de masse vide.
- Généralisation de l'**intersection** : si m_A et m_B sont des fonctions de masse catégoriques et $A \cap B \neq \emptyset$, alors

$$m_A \oplus m_B = m_{A \cap B}$$

- Généralisation du **conditionnement probabiliste** : si m est bayésienne et m_A catégorique, alors $m \oplus m_A$ est la fonction de masse bayésienne correspondant au conditionnement de m par A .

Décomposition canonique

Fonction de masse simple

- Le plus souvent, un élément d'évidence se modélise sous forme d'une fonction de masse simple de la forme :

$$\begin{aligned}m(A) &= 1 - w \\m(\Omega) &= w,\end{aligned}$$

avec $A \neq \emptyset$, $A \subset \Omega$ et $w \in [0, 1]$.

- Notation : A^w .
- Propriété : $A^{w_1} \oplus A^{w_2} = A^{w_1 w_2}$.



Décomposition canonique

Fonction de masse séparable

- Une fonction de masse (normalisée) est dite **séparable** si elle s'obtient comme résultat de la combinaison par la règle de Dempster de fonctions de masse simples :

$$m = \bigoplus_{A \subseteq \Omega} A^{w(A)}$$

- La fonction $w : A \rightarrow w(A)$ est une représentation alternative de m .
- Généralisation possible dans le cas d'une fonction de masse quelconque (w est alors à valeurs dans \mathbb{R}_+).



Outline

1 Théorie des fonctions de croyance

- Concepts fondamentaux
- Règle de Dempster
- Règle prudente et extensions

2 Applications

- Classification
- Classification multi-label
- Fusion adaptative de classifieurs



Motivations

- La règle de Dempster suppose l'**indépendance des sources d'information**.
- Dans beaucoup de situations, les sources ne peuvent être considérées comme indépendantes :
 - Experts partageant certaines informations ;
 - Classifieurs entraînés sur des bases d'apprentissage identiques ou non disjointes ;
 - Informations échangées dans un réseau mobile (fusion distribuée), etc.
- Nécessité de disposer de règles de combinaison tolérant la **dépendance** et la **redondance** des informations combinées.

Notions préliminaires

Principe d'engagement minimal

- Principe d'engagement minimal :
Lorsque plusieurs fonctions de croyance sont compatibles avec un ensemble de contraintes, la **moins informative** doit être choisie.
- Que signifie « plus ou moins informative » ?
- Plusieurs définitions :

$$m_1 \sqsubseteq_{pl} m_2 \Leftrightarrow pl_1 \leq pl_2$$

$$m_1 \sqsubseteq_w m_2 \Leftrightarrow w_1 \leq w_2$$



Notions préliminaires

Opérateurs conjonctifs et disjonctifs

- Soient m_1 et m_2 deux fonctions de masse sur Ω issues de 2 sources.
- Un opérateur de combinaison fusionne m_1 et m_2 en une nouvelle fonction de masse $m_{1*2} = m_1 * m_2$ (nouvel état de connaissance).
- L'opérateur $*$ est
 - **conjonctif** si m_{1*2} est **plus informative** que m_1 et m_2 .
 - **disjonctif** si m_{1*2} est **moins informative** que m_1 et m_2 .
- Le choix d'un opérateur conjonctif suppose que les sources soient toutes deux fiables.
- Combinaison disjonctive : stratégie prudente (l'une au moins des deux sources est fiable).

Règle conjonctive prudente

Principe

- Un agent reçoit deux fonctions de masse m_1 et m_2 issues de sources fiables.
- Soit m_{12} la fct de masse représentant son état de connaissance après réception de m_1 et m_2 .
- m_{12} doit être plus informative que m_1 et m_2 . Formellement : $m_{12} \in \mathcal{S}(m_1) \cap \mathcal{S}(m_2)$, avec $\mathcal{S}(m) =$ ens. des fcts de masse plus informatives que m (au sens d'un certain ordre).
- Principe d'engagement minimal : on choisit dans $\mathcal{S}(m_1) \cap \mathcal{S}(m_2)$ la fonction de masse la moins informative (si elle existe).

Règle conjonctive prudente

Définition

- Il est possible de définir une règle conjonctive prudente en prenant comme relation d'inclusion la relation \sqsubseteq_w .
- On obtient alors l'opérateur suivant :

$$m_1 \odot m_2 = \bigoplus_{A \subset \Omega} A^{w_1(A) \wedge w_2(A)},$$

avec $\wedge = \text{minimum}$.

Règle prudente

Propriétés

- Commutative, associative
- **Idempotente** : $\forall m, m \otimes m = m$
- Distributivité de \oplus par rapport à \otimes : $\forall m_1, m_2, m_3$

$$(m_1 \oplus m_2) \otimes (m_1 \oplus m_3) = m_1 \oplus (m_2 \otimes m_3).$$

L'élément d'évidence m_1 n'est compté qu'une fois !

- Absence d'élément neutre, mais $m_\Omega \otimes m = m$ ssi m est séparable.

Extensions

- La règle de Dempster et la règle prudente s'écrivent sous la forme :

$$m_1 \odotstar m_2 = \bigoplus_{A \subset \Omega} A^{w_1(A) \star w_2(A)},$$

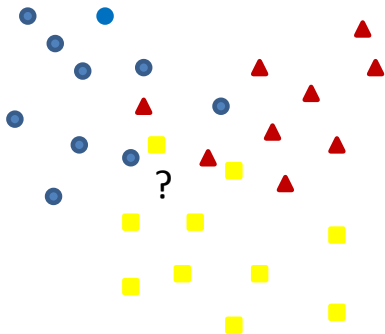
avec $\star =$ produit (Dempster) ou minimum (règle prudente).

- En se restreignant aux fonctions de masse séparables, on peut définir une **infinité de règles** aux comportements intermédiaires entre ceux de \oplus et \wedge , en prenant comme opérateur \star une **norme triangulaire** (famille des t-normes de Frank par exemple).
- Généralisation possible au cas non séparable (Pichon et Denœux, 2009).

Outline

- 1 Théorie des fonctions de croyance
 - Concepts fondamentaux
 - Règle de Dempster
 - Règle prudente et extensions
- 2 Applications
 - Classification
 - Classification multi-label
 - Fusion adaptative de classifieurs

Problème




- Soit une population partitionnée en c groupes ou classes.
- Soit $\Omega = \{\omega_1, \dots, \omega_c\}$ l'ensemble des classes.
- Chaque individu est décrit par :
 - Un vecteur d'attributs $\mathbf{x} \in \mathbb{R}^p$;
 - Une étiquette de classe $y \in \Omega$.
- Problème : étant donné un **ensemble d'apprentissage** $\mathcal{L} = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_n, y_n)\}$, **prédire la classe** d'un nouvel individu décrit par \mathbf{x} .

Approches crédibilistes

- 1 Approche 1 : exprimer les sorties de classifieurs standards sous forme de fonctions de croyance et les **combiner** par la règle de Dempster ou une autre règle ;
- 2 Approche 2 : construction de **classifieurs crédibilistes** basés sur
 - le **théorème de Bayes généralisé** (extension du théorème de Bayes permettant d'exprimer une connaissance partielle sur les distributions des classes et les probabilités a priori) (Denœux et Smets, *IEEE SMC*, 2008) ;
 - les **distances à des voisins ou à des prototypes** : règle des k -ppv crédibiliste (Denœux, *IEEE SMC*, 1995), réseaux de neurones crédibilistes (Denœux, *IEEE SMC*, 2000).

Règle des k -ppv crédibiliste (1/2)



- Soit $\mathcal{N}_k(\mathbf{x}) \subset \mathcal{L}$ l'ensemble des k plus proches voisins de \mathbf{x} dans \mathcal{L} , pour une certaine distance.
- Chaque $\mathbf{x}_i \in \mathcal{N}_k(\mathbf{x})$ peut être considéré comme un élément d'évidence concernant la classe de \mathbf{x} .
- La fiabilité de cet élément d'évidence décroît avec la distance d_i entre \mathbf{x} et \mathbf{x}_i .

Règle des k -ppv crédibiliste (2/2)

- L'élément d'évidence (\mathbf{x}_i, y_i) peut être représenté par

$$m_i(\{y_i\}) = \varphi(d_i)$$

$$m_i(\Omega) = 1 - \varphi(d_i),$$

où φ est une **fonction décroissante** de $[0, +\infty)$ dans $[0, 1]$ telle que $\lim_{d \rightarrow +\infty} \varphi(d) = 0$.


- Les éléments d'évidence correspondant aux k ppv de \mathbf{x} sont combinés par la **règle de Dempster** :

$$m = \bigoplus_{\mathbf{x}_i \in \mathcal{N}_k(\mathbf{x})} m_i.$$


- La fonction φ peut être déterminée de manière heuristique ou sélectionnée parmi une famille $\{\varphi_\theta | \theta \in \Theta\}$ par validation croisée.

Résultats (bases UCI)

Données Sonar



Donées Ionosphere



Taux d'erreur de test en fonction de k pour les règles des k ppv avec vote (-), crédibiliste (:), floue (-) et pondérée (-).



Données partiellement supervisées

- Soit un ensemble d'apprentissage de la forme

$$\mathcal{L} = \{(\mathbf{x}_i, m_i), i = 1, \dots, n\}$$

avec

- \mathbf{x}_i le vecteur d'attributs pour l'exemple i , et
- m_i une fonction de masse représentant une **connaissance partielle** sur la classe y_i de l'exemple i .
- Cas particuliers :
 - $m_i(\{\omega_k\}) = 1$ pour tout i : **apprentissage supervisé** ;
 - $m_i(\Omega) = 1$ pour tout i : **apprentissage non supervisé** ;

Règle des k -ppv crédibiliste

Cas de données partiellement supervisées

- Chaque exemple (\mathbf{x}_i, m_i) dans \mathcal{L} représente un élément d'évidence sur y , dont la **fiabilité décroît avec la distance d_i** entre \mathbf{x} et \mathbf{x}_i .
- Chaque fonction de masse m_i est transformée (**affaiblie**) en une fonction de masse m'_i moins informative :

$$m'_i(A) = \varphi(d_i) m_i(A), \quad \forall A \subset \Omega.$$


$$m'_i(\Omega) = 1 - \sum_{A \subset \Omega} m'_i(A).$$

- Les k fonctions de masse sont combinées par la **règle de Dempster** :

$$m = \bigoplus_{\mathbf{x}_i \in \mathcal{N}_k(\mathbf{x})} m'_i.$$

Exemple : données EEG

Signaux EEG codés comme des vecteurs de dimension $p = 64$; $c = 2$ classes : 50 % positifs (complexes K), 50 % négatifs (ondes delta) ; étiquetage par 5 experts.



Résultats

(Denœux and Zouhal, 2001)

- Pour chaque exemple \mathbf{x}_i , les opinions des experts sont modélisées par une fonction de masse m_i .
- $n = 200$ exemples d'apprentissage, 300 exemples de test

k	k -ppv	k -ppv pond.	k -ppv créd.	k -ppv créd. (étiq. 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

Réseau de neurones crédibiliste


- Implémentation de la règle des k -ppv crédibilistes dans un réseau de neurones de type RBF avec r prototypes : $\mathbf{p}_1, \dots, \mathbf{p}_r$.
- Chaque prototype \mathbf{p}_i est caractérisé par des degrés d'appartenance u_{ik} à chaque classe ω_k avec $\sum_{k=1}^C u_{ik} = 1$
- La distance entre \mathbf{x} et \mathbf{p}_i induit une fonction de masse :

$$\begin{aligned}m_i(\{\omega_k\}) &= \alpha_i u_{ik} \exp(-\gamma_i \|\mathbf{x} - \mathbf{p}_i\|^2) \quad \forall k \\m_i(\Omega) &= 1 - \alpha_i \exp(-\gamma_i \|\mathbf{x} - \mathbf{p}_i\|^2)\end{aligned}$$


$$m = \bigoplus_{i=1}^r m_i$$

- Apprentissage des paramètres $\mathbf{p}_i, u_{ik}, \gamma_i, \alpha_i$ à partir des données par minimisation d'une fonction d'erreur.

Architecture




Exemple (fusion de décisions)



- $c = 2$ classes
- Ensemble d'apprentissage ($n = 60$) : $\mathbf{x} \in \mathbb{R}^5, \mathbf{x}' \in \mathbb{R}^3$, distributions normales, conditionnellement indépendantes
- Ensemble de test (conditions opératoires réelles) :
 $\mathbf{x} \leftarrow \mathbf{x} + \epsilon, \epsilon \sim \mathcal{N}(0, \sigma^2 I)$.

Resultats

Taux d'erreur de test : $\mathbf{x} + \epsilon, \epsilon \sim \mathcal{N}(0, \sigma^2 I)$



Outline

- 1 Théorie des fonctions de croyance
 - Concepts fondamentaux
 - Règle de Dempster
 - Règle prudente et extensions
- 2 Applications
 - Classification
 - **Classification multi-label**
 - Fusion adaptative de classifieurs

Classification multi-label

- Dans certaines applications, **les individus peuvent appartenir simultanément à plusieurs classes.**
- Par exemple, en indexation d'images, le contenu d'une image peut être décrit par plusieurs termes tels que : "montagne", "mer", "ville", etc.
- Soit $\Theta = \{\theta_1, \dots, \theta_c\}$ l'ensemble des classes, l'étiquette d'un exemple peut être représentée par une **variable y à valeurs dans $\Omega = 2^\Theta$.**
- L'expression d'une connaissance partielle sur y par une fonction de croyance peut nécessiter la stockage de **2^{2^c} nombres.**

c	2	3	4	5	6	7	8
2^{2^c}	16	256	65536	4.3e9	1.8e19	3.4e38	1.2e77


Grands cadres de discernement

Approche générale

- Principe :
 - 1 Considérer un ordre partiel \leq sur le cadre Ω tel que (Ω, \leq) soit un **treillis**.
 - 2 Définir l'ensemble des propositions comme l'ensemble $\mathcal{I} \subset 2^\Omega$ des **intervalles** du treillis.
 - 3 Définir m, bel, pl, w , etc., comme des **fonctions de \mathcal{I} dans $[0, 1]$** (possible car (\mathcal{I}, \subseteq) est un treillis).
- La cardinalité de \mathcal{I} étant au plus proportionnelle à $|\Omega|^2$, les opérations de la théorie des fonctions de croyance peuvent être effectuées en **temps polynomial** (et non exponentiel comme dans $(2^\Omega, \subseteq)$).

Classification multi-label

- Le **cadre de discernement** est $\Omega = 2^\Theta$, où Θ est l'ensemble des classes.
- L'**ordre naturel** dans 2^Θ est \subseteq , est $(2^\Theta, \subseteq)$ est le treillis booléen des parties de Θ .



Les **intervalles** de $(2^\Theta, \subseteq)$ sont les ensembles de parties de Θ de la forme :

$$[A, B] = \{C \subseteq \Theta \mid A \subseteq C \subseteq B\}$$

pour $A \subseteq B \subseteq \Theta$.

Exemple (diagnostic)

- Soit $\Theta = \{a, b, c, d\}$ un ensemble de défauts.
- Élément d'évidence 1 $\rightarrow a$ est certainement présent et $\{b, c\}$ sont peut-être aussi présents, avec un degré de confiance de 0.7 :

$$m_1(\{\{a\}, \{a, b, c\}\}) = 0.7, \quad m_1(\{\emptyset_\Theta, \Theta\}) = 0.3$$

- Élément d'évidence 2 $\rightarrow c$ est certainement présent et soit $\{a, b\}$ (with confiance = 0.8), soit $\{a, d\}$ (confiance = 0.2) sont peut-être aussi présents :

$$m_2(\{\{c\}, \{a, b, c\}\}) = 0.8, \quad m_2(\{\{c\}, \{a, c, d\}\}) = 0.2$$

Exemple

Combinaison par la règle de Dempster

	$\{\{a\}, \{a, b, c\}\}$ 0.7	$\{\emptyset_\Theta, \Theta\}$ 0.3
$\{\{c\}, \{a, b, c\}\}$ 0.8	$\{\{a, c\}, \{a, b, c\}\}$ 0.56	$\{\{c\}, \{a, b, c\}\}$ 0.24
$\{\{c\}, \{a, c, d\}\}$ 0.2	$\{\{a, c\}, \{a, c\}\}$ 0.14	$\{\{c\}, \{a, c, d\}\}$ 0.06

Degrés de croyance dans l'hypothèse que

- Le défaut a est présent :

$$bel(\{\{a\}, \Theta\}) = 0.56 + 0.14 = 0.70 ;$$

- Le défaut d n'est pas présent : $bel(\{\emptyset_\Theta, \overline{\{d\}}\}) =$
 $bel(\{\emptyset_\Theta, \{a, b, c\}\}) = 0.56 + 0.14 + 0.24 = 0.94.$

Classification multi-label

Etiquettes imprécises

- Soit un ensemble d'apprentissage de la forme :

$$\mathcal{L} = \{(\mathbf{x}_1, [A_1, B_1]), \dots, (\mathbf{x}_n, [A_n, B_n])\}$$

où

- $\mathbf{x}_i \in \mathbb{R}^p$ est le vecteur de caractéristiques pour l'exemple i
- A_i est l'ensemble des classes auxquelles appartient **certainement** l'exemple i ;
- B_i est l'ensemble des classes auxquelles appartient **possiblement** l'exemple i .
- Dans un **contexte multi-expert**, A_i peut être l'ensemble des classes affectées à l'exemple i par **tous** les experts, et B_i l'ensemble des classes affectées par **au moins un** expert.



Règle des k -ppv crédibiliste multi-label

Construction des fonctions de masse

- Soit $\mathcal{N}_k(\mathbf{x})$ l'ensemble des k ppv d'un nouvel exemple \mathbf{x} , pour une distance d .
- Soit $\mathbf{x}_i \in \mathcal{N}_k(\mathbf{x})$ avec l'étiquette $[A_i, B_i]$. Cet élément d'évidence peut être décrit par une fonction de masse dans (\mathcal{I}, \subseteq) :

$$m_i([A_i, B_i]) = \varphi(d_i),$$

$$m_i([\emptyset_\Theta, \Theta]) = 1 - \varphi(d_i),$$

où φ est une fonction décroissante de $[0, +\infty)$ ans $[0, 1]$ telle que $\lim_{d \rightarrow +\infty} \varphi(d) = 0$.

- Les k fonctions de masse sont combinées par la règle de Dempster :

$$m = \bigoplus_{\mathbf{x}_i \in \mathcal{N}_k(\mathbf{x})} m_i$$

Règle des k -ppv crédibiliste multi-label

Décision

- Soit \hat{Y} be the **l'ensemble des classes prédites** pour l'exemple \mathbf{x} .
- Pour décider d'inclure ou non chaque classe $\theta \in \Theta$ dans \hat{Y} , on calcule
 - le degré de croyance $bel(\{\{\theta\}, \Theta\})$ dans l'hypothèse que l'ensemble de labels Y contient θ , et
 - le degré de croyance $bel([\emptyset, \overline{\{\theta\}}])$ dans l'hypothèse que l'ensemble de labels Y ne contient pas θ .
- On définit alors \hat{Y} comme

$$\hat{Y} = \{\theta \in \Theta \mid bel(\{\{\theta\}, \Theta\}) \geq bel([\emptyset, \overline{\{\theta\}}])\}.$$

Exemple : données Emotions


Trohidis et al., 2008

- Problème : prédire les émotions engendrées par un morceau de musique.
- 593 morceaux annotés par des juges.
- Six émotions (surprise, joie, calme, tristesse, etc.).
- Chaque morceau décrit par 72 attributs et étiqueté par une ou plusieurs émotions (classes).
- Données partitionnées en un ensemble d'apprentissage de 391 exemples et un ensemble de test de 202 exemples.
- Evaluation des résultats :

$$Acc = \frac{1}{n} \sum_{i=1}^n \frac{|Y_i \cap \hat{Y}_i|}{|Y_i \cup \hat{Y}_i|}$$



Résultats



Outline

- 1 Théorie des fonctions de croyance
 - Concepts fondamentaux
 - Règle de Dempster
 - Règle prudente et extensions
- 2 Applications
 - Classification
 - Classification multi-label
 - Fusion adaptative de classifieurs

Problème

- Soient q sources (classifieurs) fournissant des fonctions de masse $m_{(1)}, \dots, m_{(q)}$ sur Ω .
- Différents cas :
 - Attributs différents (capteurs différents, etc.) ;
 - Ensembles d'apprentissages différents (disjoints ou non) ;
 - Algorithmes d'apprentissages différents, etc.
- Problème : comment combiner les sorties des classifieurs ?


Choix d'une règle de combinaison

- Hypothèses sur l'**indépendance** des sources :
 - Classifieurs indépendants :

$$m_{\oplus} = m_{(1)} \oplus \dots \oplus m_{(q)}$$

- Classifieurs dépendants :
 - Règle prudente : $m_{\odot} = m_{(1)} \odot \dots \odot m_{(q)}$
 - Autre règle ?
- Comment apprendre une **règle optimale** ?
- B. Quost, M.-H. Masson, T. Denœux. Classifier fusion in the Dempster-Shafer framework using optimized t-norm based combination rules. *International Journal of Approximate Reasoning* (à paraître en 2011).

Approche 1 : optimisation d'une règle unique




- Combinaison par une règle de la forme

$$m_1 \mathbb{T}_s m_2 = \bigoplus_{A \subset \Omega} A^{w_1(A) \mathbb{T}_s w_2(A)}$$

où \mathbb{T}_s est une **t-norme** dépendant d'un paramètre s .

- Détermination de s par **minimisation d'un critère d'erreur**.

Approche 2 : optimisation de deux règles



- Regroupement des classifieurs selon un **critère de distance** entre fonctions de masse (distance de Jousselme).
- Combinaison par deux règles : **intra-groupe** et **inter-groupes**.
- **Optimisation simultanée** de ces deux règles par apprentissage (validation croisée).

Résultats

données	Satimage	Segment	Vowel	Waveform
Dempster	24.45	17.91	<u>57.36</u>	16.90
OPT1 (\hat{s})	21.80	<u>15.16</u>	59.52	15.22
OPT2 (\hat{s}_w, \hat{s}_b)	<u>21.69</u>	<u>15.16</u>	59.52	<u>15.19</u>
règle prudente	21.80	<u>15.16</u>	59.52	16.59
moyenne	28.92	23.74	59.96	20.52

Conclusion

- La théorie des fonctions de croyance constitue un **cadre très général** (englobant les formalismes ensembliste et probabiliste) pour la représentation et la manipulation d'informations imparfaites.
- Ce cadre est adapté à la résolution de problèmes complexes en **reconnaissance de formes**, particulièrement ceux impliquant :
 - Des **informations imparfaites** (données partiellement supervisées, capteurs peu fiables, etc.) ;
 - Une combinaison d'informations **objectives** (données) et **subjectives** (opinions d'experts, perceptions) : intégration d'informations a priori en classification, appréciation du contexte par des experts, etc. ;
 - Des **sources d'informations multiples** (fusion multi-capteurs, combinaison multi-experts, méthodes d'ensemble en classification supervisée ou non).



Problèmes ouverts

- 1 Développer des **stratégies de fusion** sophistiquées incluant
 - de **nouvelles règles de combinaison** permettant la fusion d'informations dépendantes et/ou partiellement inconsistantes ;
 - des **méta-connaissances** sur la qualité (fiabilité) des sources d'information.
- 2 Nouveaux problèmes en RdF et en apprentissage :
 - **Apprentissage de préférences** (définition de fonctions de croyance sur des ensembles de relations de préférence) ;
 - **Apprentissage à partir de données incertaines** (attributs ou étiquettes de classes).

Références

Articles et sources Matlab disponibles à l'adresse :

`http://www.hds.utc.fr/~tdenoeux`

MERCI!

