

Fusion d'informations dans le cadre de la théorie des fonctions de croyance

Thierry Denœux¹

¹Université de Technologie de Compiègne
HEUDIASYC (UMR CNRS 6599)

GDR ISIS

« Gestion de l'incertain et Fusion d'Informations »
9 octobre 2008



Problématique de la fusion d'informations

- **Fusion d'informations** = combinaison d'informations issues de plusieurs sources en vue de déterminer la valeurs de certaines variables.
- Cela suppose que les sources délivrent une **information partielle** (imprécise et/ou incertaine) sur les variables d'intérêt.
- Il est donc nécessaire de définir des formalismes suffisamment **généraux** pour représenter et combiner tous types d'informations susceptibles d'être rencontrés.
- Les problématiques de la fusion de l'information et de la **gestion de l'incertain** (au sens large) sont donc fortement liées.

Typologie des imperfections de l'information

- Soit X une variable à valeurs dans Ω (domaine, cadre de discernement).
- Un élément d'information sur X peut être représenté sous forme d'un couple (**valeur**, **confiance**) :
 - l'élément "valeur" correspond à un sous-ensemble de Ω ;
 - l'élément "confiance" exprime un jugement sur la validité de l'information.
- L'élément d'information est
 - **imprécis** si "valeur" n'est pas un singleton de Ω ;
 - **incertain** si l'élément "confiance" exprime un doute sur la véracité de l'information.

Exemple

- Soit X = la température de la pièce
- "Il fait entre 15 et 25 degrés" = $([15, 25], \text{certain}) \rightarrow$ élément d'information **certain et imprécis**.
- "Il est plausible qu'il fasse 20 degrés" = $(20, \text{plausible}) \rightarrow$ élément d'information **incertain et précis**.
- "Il fait probablement entre 15 et 25 degrés" = $([15, 25], \text{probable}) \rightarrow$ élément d'information **incertain et imprécis**.

Formalismes classiques

1 Théorie de ensembles

- Calcul par intervalle, estimation à erreur bornée
- Modélise bien l'imprécision mais n'exprime aucune notion d'incertitude
- Peu robuste et excessivement conservative

2 Théorie des probabilités

- Modélise l'incertitude aléatoire (variabilité dans une population ou au cours des répétitions d'une expérience aléatoire).
- N'exprime pas de notion d'imprécision.

Théorie des fonctions de croyance

- Introduite par Dempster (1968) et Shafer (1976), puis développée par Smets (**Modèle des Croyances Transférables**) à partir de 1978.
- Généralise à la fois la théorie des ensembles et la théorie des probabilités :
 - Une fonction de croyance peut être vue comme un **ensemble généralisé** ou comme une **mesure non additive**
 - Extension de notions probabilistes (conditionnement, marginalisation) et ensemblistes (intersection, union, inclusion, etc.)
- La combinaison des informations (éléments d'évidence) occupe une place centrale dans la théorie : nombreuses applications en fusion d'informations.

Plan de la présentation

- 1 Théorie des fonctions de croyance
 - Concepts fondamentaux
 - Fusion d'informations
 - Décomposition canonique et règle prudente
- 2 Principes de construction de fonctions de croyance
 - Affaiblissement
 - Théorème de Bayes généralisé
 - Fonction de croyance prédictive

Fonction de masse de croyance

- Soit Ω un ensemble fini, domaine d'un variable X .
- Fonction de masse de croyance : $m : 2^\Omega \rightarrow [0, 1]$ telle que

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

- Tout sous-ensemble A de Ω tel que $m(A) > 0$ est appelé **ensemble focal**.
- Interprétation : m représente
 - Un élément d'évidence relatif à la valeur de X .
 - Un état de connaissance (croyance) induit par cet élément d'évidence.

Cas particuliers

- m peut être vue comme :
 - Une famille d'ensembles pondérés $\{(A_i, m(A_i)), i = 1, \dots, r\}$.
 - Une distribution de probabilité généralisée (masses distribuées sur 2^Ω et non sur Ω).
- Cas particuliers :
 - $r = 1$: fonction de masse **catégorique** (\sim ensemble). On note m_A la fonction de masse catégorique d'ensemble focal A .
 - $|A_i| = 1, i = 1, \dots, r$: fonction de masse **bayésienne** (\sim distribution de probabilité).

Fonctions de croyance et de plausibilité

- Fonction de croyance :

$$bel(A) = \sum_{\substack{B \subseteq A \\ B \not\subseteq \bar{A}}} m(B) = \sum_{\emptyset \neq B \subseteq A} m(B), \quad \forall A \subseteq \Omega$$

(**degré de croyance** (support) en l'hypothèse " $X \in A$ ")

- Fonction de plausibilité :

$$pl(A) = \sum_{B \cap A \neq \emptyset} m(B), \quad \forall A \subseteq \Omega$$

(degré maximal de croyance **susceptible** d'être alloué à A après intégration de nouvelles informations)

- $bel \leq pl$.

Relations entre m , bel et pl

- Relations :

$$bel(A) = pl(\Omega) - pl(\bar{A}), \quad \forall A \subseteq \Omega$$

$$m(A) = \begin{cases} \sum_{\emptyset \neq B \subseteq A} (-1)^{|A|-|B|} bel(B), & A \neq \emptyset \\ 1 - bel(\Omega) & A = \emptyset \end{cases}$$

- m , bel et pl sont donc **trois représentations équivalentes** d'un même élément d'information.

Relations d'inclusion

- Soient m_1 et m_2 deux fonctions de masse sur Ω .
- En quel sens peut-on dire que m_1 est **plus informative** que m_2 ?
- Cas particulier :
 - Soient m_A et m_B deux fonctions de masse catégoriques.
 - m_A est plus informative (au sens large) que m_B ssi $A \subseteq B$.
- Généralisation à des fonctions de masse quelconques ?

Inclusion faible

- m_1 plus informative (riche) que m_2 **au sens des plausibilités** (noté $m_1 \sqsubseteq_{pl} m_2$) si

$$pl_1(A) \leq pl_2(A), \quad \forall A \subseteq \Omega.$$

- Propriétés :
 - Généralise l'inclusion : $m_A \sqsubseteq_{pl} m_B \Leftrightarrow A \subseteq B$.
 - Plus grand élément : m_Ω t.q. $m_\Omega(\Omega) = 1$ (fonction de masse vide).

Inclusion forte

- m_1 est une **spécialisation** de m_2 (noté $m_1 \sqsubseteq_s m_2$) si m_1 s'obtient à partir de m_2 en répartissant chaque masse $m_2(B)$ entre des sous-ensembles de B :

$$m_1(A) = \sum_{B \subseteq \Omega} S(A, B) m_2(B), \quad \forall A \subseteq \Omega,$$

avec $S(A, B) =$ proportion de $m_2(B)$ transférée à $A \subseteq B$.

- S : matrice de spécialisation.
- Propriétés :
 - Généralise l'inclusion
 - Plus grand élément : m_Ω .
 - $m_1 \sqsubseteq_s m_2 \Rightarrow m_1 \sqsubseteq_{pl} m_2$.

Principe d'engagement minimal

Définition (Principe d'engagement minimal)

*Lorsque plusieurs fonctions de croyance sont compatibles avec un ensemble de contraintes, la **moins informative** (au sens d'un certain ordre) doit être choisie.*

- Exemple : On sait seulement que $p_l(A) = 0$.
- La fonction de masse la moins informative (au sens de \sqsubseteq_{p_l} et \sqsubseteq_s) vérifiant cette contrainte et $m_0(\bar{A}) = 1$. Elle vérifie $p_l(A) = 0$ et $p_l(B) = 1$ pour tout $B \not\subseteq A$.

Plan de la présentation

- 1 **Théorie des fonctions de croyance**
 - Concepts fondamentaux
 - **Fusion d'informations**
 - Décomposition canonique et règle prudente
- 2 Principes de construction de fonctions de croyance
 - Affaiblissement
 - Théorème de Bayes généralisé
 - Fonction de croyance prédictive

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 $m_{1*2} = m_1 * m_2$ qui traduit notre nouvel état de connaissance après avoir pris en considération les deux 2 sources.
- 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).

Conditionnement

- Soient deux fonctions de masse m et m_B avec $m_B(B) = 1$ pour $B \subset \Omega$.
- Etat de connaissance après fusion conjonctive de m et m_B ? Soit $m[B]$ le résultat de la combinaison.
- Contraintes :
 - $pl[B](\bar{B}) = 0$.
 - $m[B] \sqsubseteq_s m$.
- Principe d'engagement minimal : solution la moins informative au sens de \sqsubseteq_{pl} :

$$m[B](A) = \sum_{\{C \mid C \cap B = A\}} m(C).$$



Propriétés

- Généralisation de l'**intersection** : $m_A[B] = m_{A \cap B}$.
- Généralisation du **conditionnement probabiliste** :
 - Si $m(\emptyset) > 0$, soit m^* la fonction de masse normalisée

$$m^*(A) = \frac{m(A)}{1 - m(\emptyset)}.$$

- Expression du conditionnement normalisé :

$$pl[B]^*(A) = \frac{pl(A \cap B)}{pl(B)}$$

- Si m est bayésienne, $pl = P$: on retrouve le conditionnement probabiliste.



Plausibilité, communalité

- Interprétation de $pl(A)$:
 - $pl(A) = belA = \max_B bel[B](A)$
 - **degré maximal de croyance** susceptible d'être alloué à A après conditionnement.
- Fonction de **communalité** : soit $q : 2^\Omega \rightarrow [0, 1]$ définie par $q(A) = mA$:
 - Masse attachée au plus grand ensemble possible (**degré d'ignorance**) après conditionnement par A .
 - Autre expression

$$q(A) = \sum_{B \supseteq A} m(B).$$

- Nouvelle relation d'inclusion : $m_1 \sqsubseteq_q m_2$ si $q_1 \leq q_2$.

Règle de Dempster : hypothèses

- Soit $*$ un opérateur de fusion conjonctif, tel que

$$m_1 * m_2 = S_1 \cdot m_2, \quad m_1 * m_2 = S_2 \cdot m_1,$$

S_1 et S_2 étant des opérateurs de spécialisation.

- Hypothèses :
 - **Indépendance** : S_1 ne dépend pas de m_2 , S_2 ne dépend pas de m_1 .
 - Généralisation du conditionnement : $m_1 * m_B = m[B]$.
 - Commutativité : $m_1 * m_2 = m_2 * m_1$.
- Solution : **règle de Dempster**.

Règle de Dempster

Définition (Règle de combinaison de Dempster)

$$\begin{aligned}\forall A \subseteq \Omega, \quad (m_1 \oplus m_2)(A) &= \sum_{B \subseteq \Omega} m_1[B](A) m_2(B), \\ &= \sum_{B \cap C = A} m_1(B) m_2(C).\end{aligned}$$

Propriétés :

- commutativité, associativité.
- élément neutre : m_Ω
- $(q_1 \oplus q_2) = q_1 \cdot q_2$
- $(m_1 \oplus m_2)(\emptyset) \geq 0$: **degré de conflit.**

Règle disjonctive

Définition (Règle disjonctive)

$$\forall A \subseteq \Omega, \quad (m_1 \oplus m_2)(A) = \sum_{B \cup C = A} m_1(B) m_2(C).$$

Propriétés :

- commutativité, associativité.
- élément neutre : m_\emptyset
- Soit $b = bel + m(\emptyset)$ (fonction d'implicabilité). On a :

$$(b_1 \oplus b_2) = b_1 \cdot b_2$$

Choix d'une règle

- Les règles \oplus et \otimes supposent que les sources d'information sont **distinctes** (la même information n'est pas comptée deux fois). Si cette hypothèse n'est pas vérifiée : **règle prudente**.
- La règle conjonctive suppose que les deux sources sont fiables : produit une information de plus en plus précise, mais génère du conflit.
- La règle disjonctive suppose que l'une au moins des sources est fiable. Ne génère pas de conflit mais produit une information de moins en moins précise.

Gestion du conflit

- Un conflit important révèle souvent (toujours ?) un **problème de modélisation** :
 - Crédit excessif accordé à certaines sources ;
 - Hypothèse d'indépendance des sources non vérifiée ;
 - Cadre de discernement non exhaustif, etc...
- Approches :
 - Revenir sur la modélisation de l'information ;
 - Utiliser des règles **robustes** (résultat cohérent en cas de conflit).

Règle de Dubois et Prade

- Définition :

$$(m_1 *_{DP} m_2)(A) = \sum_{B \cap C = A} m_1(B)m_2(C) + \sum_{\{B \cap C = \emptyset, B \cup C = A\}} m_1(B)m_2(C), \quad \forall A \neq \emptyset$$

$$(m_1 *_{DP} m_2)(\emptyset) = 0.$$

- Propriétés :

- $m_1 *_{DP} m_2 = m_1 \odot m_2$ si $(m_1 \odot m_2)(\emptyset) = 0$,
- $m_1 *_{DP} m_2 = m_1 \cup m_2$ si $(m_1 \odot m_2)(\emptyset) = 1$.
- Commutative mais **non associative**.

Plan de la présentation

- 1 Théorie des fonctions de croyance
 - Concepts fondamentaux
 - Fusion d'informations
 - Décomposition canonique et règle prudente
- 2 Principes de construction de fonctions de croyance
 - Affaiblissement
 - Théorème de Bayes généralisé
 - Fonction de croyance prédictive

Fonction de masse simple

- Définition : m est une **fonction de masse simple** si elle est de la forme

$$m(A) = 1 - w_A$$

$$m(\Omega) = w_A,$$

avec $A \subset \Omega$ et $w_A \in [0, 1]$.

- Notation : A^{w_A} .
- Propriété : $A^{w_1} \circledast A^{w_2} = A^{w_1 w_2}$.
- Une fonction de masse est dite **séparable** si elle peut s'obtenir comme combinaison de fonctions de masse simples :

$$m = \circledast_{A \subset \Omega} A^{w(A)}$$

Retrait d'information

- Soit $m_{12} = m_1 \circledast m_2$. On a $q_{12} = q_1 \cdot q_2$.
- Supposons qu'on s'aperçoive que m_2 a été ajoutée par erreur.
- Si m_2 est **non dogmatique** ($q(A) > 0, \forall A$), m_1 peut être retrouvée à partir de m_{12} par

$$q_1 = q_{12}/q_2.$$

- On note $m_1 = m_{12} \oslash m_2$.
- Remarque : $m_1 \oslash m_2$ n'est pas toujours une fonction de croyance !

Décomposition canonique

Théorème (Smets, 1995)

Toute fonction de masse non dogmatique ($m(\Omega) > 0$) peut être décomposée de manière unique sous la forme :

$$m = \left(\bigoplus_{A \subset \Omega} A^{w_C(A)} \right) \otimes \left(\bigoplus_{A \subset \Omega} A^{w_D(A)} \right)$$

avec $w_C(A) \in]0, 1]$, $w_D(A) \in]0, 1]$ et $\max(w_C(A), w_D(A)) = 1$ pour tout $A \subset \Omega$.

- On peut poser $w = w_C/w_D$.
- La fonction $w : 2^\Omega \setminus \Omega \rightarrow \mathbb{R}_+^*$ est une nouvelle **représentation équivalente** d'une fonction de masse non dogmatique (avec bel, pl, q, b).

Propriétés de w

- La fonction w est disponible directement lorsque m est construite par **accumulation de fonctions de masses simples** (cas fréquent).
- Calcul de w à partir de q :

$$\ln w(A) = - \sum_{B \supseteq A} (-1)^{|B|-|A|} \ln q(B), \quad \forall A \subset \Omega.$$

- Règle de Dempster :

$$w_1 \odot w_2 = w_1 \cdot w_2.$$

Relation d'inclusion \sqsubseteq_w

- Soient m_1 et m_2 deux fonctions de masse non dogmatiques. On pose

$$m_1 \sqsubseteq_w m_2 \text{ ssi } w_1 \leq w_2.$$

- Interprétation $m_1 = m_2 \oplus m$ avec m séparable.
- Propriétés :

- $m_1 \sqsubseteq_w m_2 \Rightarrow m_1 \sqsubseteq_s m_2 \Rightarrow \begin{cases} m_1 \sqsubseteq_{pl} m_2 \\ m_1 \sqsubseteq_q m_2, \end{cases}$
- m_Ω est le seul élément maximal de \sqsubseteq_w :

$$m_\Omega \sqsubseteq_w m \Rightarrow m = m_\Omega.$$

Règle 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 : $m_{12} \in \mathcal{S}_x(m_1) \cap \mathcal{S}_x(m_2)$, pour un $x \in \{w, s, pl, q\}$, avec $\mathcal{S}_x(m) =$ ens. des fcts de masse plus informatives que m au sens de \sqsubseteq_x .
- Principe d'engagement minimal : on choisit dans $\mathcal{S}_x(m_1) \cap \mathcal{S}_x(m_2)$ **la fonction de masse la moins informative** au sens de \sqsubseteq_x (si elle existe).

Règle prudente

Définition

Théorème

Soient m_1 and m_2 deux fcts de masse non dogmatiques. L'élément le moins informatif de $\mathcal{S}_w(m_1) \cap \mathcal{S}_w(m_2)$ au sens de \sqsubseteq_w existe et est unique. Il est défini par

$$w_1 \otimes_2(A) = w_1(A) \wedge w_2(A), \quad \forall A \subset \Omega.$$

Définition (Règle prudente)

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

Règle prudente

Définition

Théorème

Soient m_1 and m_2 deux fcts de masse non dogmatiques. L'élément le moins informatif de $\mathcal{S}_w(m_1) \cap \mathcal{S}_w(m_2)$ au sens de \sqsubseteq_w existe et est unique. Il est défini par

$$w_1 \circledast_2(A) = w_1(A) \wedge w_2(A), \quad \forall A \subset \Omega.$$

Définition (Règle prudente)

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

Règle prudente

Propriétés

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

$$(m_1 \otimes m_2) \otimes (m_1 \otimes m_3) = m_1 \otimes (m_2 \otimes m_3), \forall m_1, m_2, m_3.$$

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

- Il existe une règle disjonctive duale de la règle prudente (**règle hardie** \vee).
- Quatre règles fondamentales :

Résumé

sources	distinctes	non distinctes
toutes fiables	\cap	\wedge
au moins une fiable	\cup	\vee

- On peut également définir une **infinité de règles commutatives et associatives** généralisant chacune de ces 4 règles, en se basant sur des **normes et des conormes triangulaires**.



Plan de la présentation

- 1 Théorie des fonctions de croyance
 - Concepts fondamentaux
 - Fusion d'informations
 - Décomposition canonique et règle prudente
- 2 Principes de construction de fonctions de croyance
 - **Affaiblissement**
 - Théorème de Bayes généralisé
 - Fonction de croyance prédictive

Problème posé

- Une source d'information fournit :
 - une valeur
 - un ensemble de valeurs
 - une distribution de probabilité, etc..
- L'information fournie est :
 - non totalement fiable ou
 - non totalement pertinente.
- Exemples :
 - Défaillance possible d'un capteur ;
 - Contexte de la mesure plus ou moins favorable ;
 - Information se rapportant à une situation ou un objet ayant seulement un degré de similarité avec la situation ou l'objet considéré (raisonnement à base de cas).



Modélisation

- Deux cadres de discernement :
 - fiabilité ou pertinence de la source : $\mathcal{F} = \{F, NF\}$.
 - Domaine Ω de la variable X d'intérêt.
- Une source S fournit une fonction de masse m_S^Ω .
- Éléments d'information disponibles :
 - $pl^{\mathcal{F}}(\{NF\}) = \alpha, pl^{\mathcal{F}}(\{F\}) = 1$.
 - $m^\Omega[F] = m_S^\Omega$.
 - $m^\Omega[NF] = m_\Omega^\Omega$.
- Information induite sur Ω :

$$\alpha m^\Omega = \left(m^{\mathcal{F} \uparrow \Omega \times \mathcal{F}} \circledast m^\Omega[F] \uparrow \Omega \times \mathcal{F} \right) \downarrow \Omega$$

Expression de la solution

$$\begin{aligned}\alpha m^\Omega(A) &= (1 - \alpha)m_S^\Omega(A), \quad \forall A \subset \Omega, \\ \alpha m^\Omega(\Omega) &= (1 - \alpha)m_S^\Omega(\Omega) + \alpha.\end{aligned}$$

- α est appelé **coefficient d'affaiblissement** : ${}^0 m^\Omega = m_S^\Omega$ et ${}^1 m^\Omega = m_\Omega^\Omega$.
- Expression équivalente :

$$\alpha m^\Omega = m_S^\Omega \oplus \emptyset^\alpha.$$

- $\alpha m^\Omega \supseteq_s m_S^\Omega$.

Application en classification

Données du problème

- Soit Ω un ensemble de classes, et

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

où \mathbf{x}_i est un vecteur d'attributs pour l'objet o_i , et m_i^Ω une fonction de masse relative à la classe de l'objet o_i .

- Soit \mathbf{x} le vecteur d'attributs pour un nouvel individu o à classer.
- Problème : Construire une **fonction de masse m^Ω relative à la classe de o .**

Application en classification

Solution

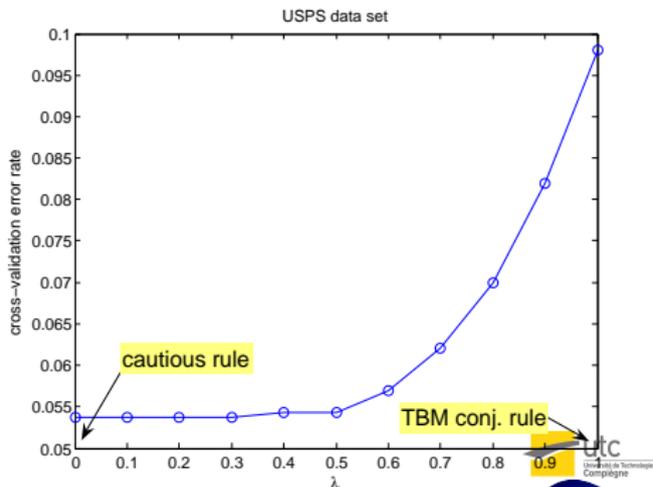
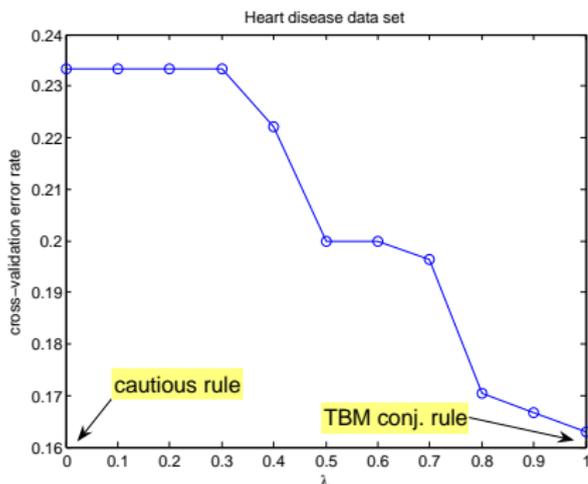
- Hypothèse : soit α_j la plausibilité que o et o_j ne soient pas dans la même classe. On suppose $\alpha_j = \phi(d(\mathbf{x}, \mathbf{x}_j))$, où d est une distance, et ϕ une fonction croissante de \mathbb{R}^+ dans $[0, 1]$.
- Chaque exemple $(\mathbf{x}_i, m_i^\Omega)$ est une source d'information, qui doit être affaiblie avec le coefficient α_j .
- Les n fonctions de masse sont ensuite combinées conjonctivement par \odot (exemples indépendants) ou \oslash (exemples non indépendants) :

$$m^\Omega = \alpha_1 m_1^\Omega * \dots * \alpha_n m_n^\Omega$$

avec $* \in \{\odot, \oslash, \dots\}$ (ou tout autre opérateur conjonctif).

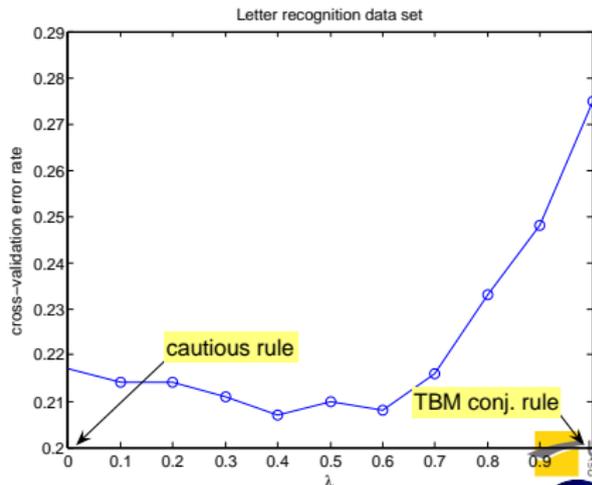
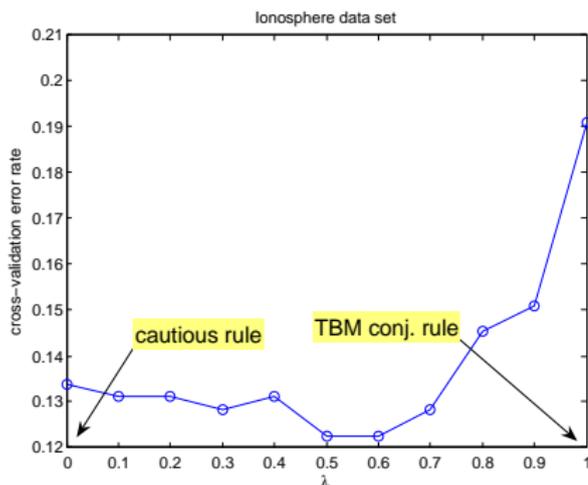
Résultats

Données "Heart disease" and "USPS"



Résultats

Données "Ionosphere" and "Letter recognition"



Généralisation : Affaiblissement contextuel

Modèle

- Modèle plus général de **métaconnaissance sur la fiabilité d'une source** : la fiabilité dépend du contexte (la vraie valeur de X). Exemples :
 - Fiabilité d'un système de détection dépendant de la nature de la cible
 - Compétence d'un médecin dépendant de la nature de la maladie, etc.
- Modèle :
 - Soit $\Theta = \{\theta_1, \dots, \theta_L\}$ une partition de Ω .
 - $pl^{\mathcal{F}}[\theta_\ell](\{NF\}) = \alpha_\ell$, $pl^{\mathcal{F}}[\theta_\ell](\{F\}) = 1$, $\ell = 1, \dots, L$.
 - $m^\Omega[F] = m_S^\Omega$.
 - $m^\Omega[NF] = m_\Omega^\Omega$.

Généralisation : Affaiblissement contextuel

Solution

- Déconditionnement et combinaison de tous les éléments d'information :

$$\alpha m^\Omega = \left(\bigodot_{\ell=1}^L m^{\mathcal{F}}[\theta_\ell] \uparrow^{\Omega \times \mathcal{F}} \bigodot m^\Omega[F] \uparrow^{\Omega \times \mathcal{F}} \right) \downarrow^\Omega,$$

$$\alpha = (\alpha_1, \dots, \alpha_L).$$

- Solution :

$$\alpha m^\Omega = m_S^\Omega \odot m_1^\Omega \odot \dots \odot m_L^\Omega$$

avec $m_\ell^\Omega(\emptyset) = 1 - \alpha_\ell$, $m_\ell^\Omega(\theta_\ell) = \alpha_\ell$, $\ell = 1, \dots, L$.

- On retrouve l'affaiblissement classique quand $\Theta = \{\Omega\}$.
- Possibilité d'apprentissage des α_ℓ à partir de données étiquetées.

Plan de la présentation

- 1 Théorie des fonctions de croyance
 - Concepts fondamentaux
 - Fusion d'informations
 - Décomposition canonique et règle prudente
- 2 Principes de construction de fonctions de croyance
 - Affaiblissement
 - **Théorème de Bayes généralisé**
 - Fonction de croyance prédictive

Théorème de Bayes généralisé (Smets, 1978)

Problème posé

- Deux variables $X \in \Omega_X$ et $\theta \in \Theta = \{\theta_1, \dots, \theta_K\}$.
- Typiquement :
 - X est observable (résultat de mesure),
 - θ est non observable (classe, paramètre inconnu à estimer).
- On sait calculer $p^{I^{\Omega_X}}[\theta_k](\{x\}) = p|_k(x), \forall x, k$.
- On n'a pas d'information a priori sur $\theta : m^\Theta(\Theta) = 1$.
- On observe $X = x$. **Fonction de croyance sur Θ ?**

Théorème de Bayes généralisé (Smets, 1978)

Solution et propriétés

- Solution (conséquence du principe d'engagement minimal) :

$$m^\Theta[x] = \bigoplus_{k=1}^K \overline{\{\theta_k\}}^{pl_k(x)}.$$

- Propriété 1 : **Généralisation du théorème de Bayes** lorsque $pl_k(x) = P(x|\theta_k)$ (information probabiliste) et combinaison avec une masse Bayésienne sur Θ (a priori).
- Propriété 2 : Si X et Y sont **cognitivement indépendantes** conditionnellement à θ :

$$pl_k(x, y) = pl_k(x)pl_k(y), \quad \forall k$$

Alors

$$m^\Theta[x, y] = \bigoplus_{k=1}^K \overline{\{\theta_k\}}^{pl_k(x,y)} = m^\Theta[x] \bigoplus m^\Theta[y].$$

Théorème de Bayes généralisé

Mise en œuvre

- Exemple : Soit X_j un vecteur d'attributs issus d'un capteur j , et $f_k(x_j)$ la densité conditionnelle (estimée) de X_j dans la classe θ_k .
- On peut poser (Appriou, 1991) :

$$pl_k(x_j) = \alpha_{jk} + (1 - \alpha_{jk})\rho_j f(x_j|\theta_k),$$

avec

- ρ_j : coefficient de normalisation
- α_{jk} : coefficient d'affaiblissement traduisant la méconnaissance de la distribution de X_j dans la classe θ_k , dans un contexte opérationnel donné.



Théorème de Bayes généralisé

Mise en œuvre : fusion

- Capteurs indépendants :

$$m^\ominus[x_1, \dots, x_J] = \bigotimes_{j=1}^J m^\ominus[x_j] = \bigotimes_{k=1}^K \overline{\{\theta_k\}}^{\prod_{j=1}^J pl_k(x_j)}.$$

- Capteurs dépendants :

$$m^\ominus[x_1, \dots, x_J] = \bigwedge_{j=1}^J m^\ominus[x_j] = \bigotimes_{k=1}^K \overline{\{\theta_k\}}^{\bigwedge_{j=1}^J pl_k(x_j)}.$$

Plan de la présentation

- 1 Théorie des fonctions de croyance
 - Concepts fondamentaux
 - Fusion d'informations
 - Décomposition canonique et règle prudente
- 2 Principes de construction de fonctions de croyance
 - Affaiblissement
 - Théorème de Bayes généralisé
 - Fonction de croyance prédictive

Fonction de croyance prédictive

Définition

- Soit X une **variable aléatoire** (définie en fonction du résultat d'une expérience **répétable**), de loi \mathbb{P}_X inconnue.
- On a observé un échantillon indépendant, identiquement distribué de X : X_1, \dots, X_n .
- Problème : construire une fonction de croyance $bel^\Omega[X_1, \dots, X_n]$ relative à une prochaine réalisation de X
→ **fonction de croyance prédictive**.
- Exemple : Ayant tiré n_B boules blanches et $n - n_B$ boules noires au cours de n tirages avec remise, fonction de croyance sur la couleur de la prochaine boule tirée.

Fonction de croyance prédictive

Propriétés souhaitées

- Propriété 1 (**principe de Hacking**) :

$$\forall A \subset \Omega, \quad \text{bel}^\Omega[X_1, \dots, X_n](A) \xrightarrow{P} \mathbb{P}_X(A), \text{ as } n \rightarrow \infty,$$

- Propriété 2 (**principe d'engagement minimal**) :

$$\mathbb{P} \left(\text{bel}^\Omega[X_1, \dots, X_n](A) \leq \mathbb{P}_X(A), \forall A \subset \Omega \right) \geq 1 - \alpha.$$

Fonction de croyance prédictive

Solutions

- X v.a. discrète, $\Omega = \{\xi_1, \dots, \xi_K\}$: solution obtenue à partir d'une **région de confiance sur les probabilités**
 $p_k = \mathbb{P}(X = \xi_k)$:

$$\mathbb{P}(P_k^- \leq p_k \leq P_k^+, k = 1, \dots, K) = 1 - \alpha$$

(T. Denoeux. *International Journal of Approximate Reasoning*, 2006).

- X v.a. continue, $\Omega = \mathbb{R}$: solution obtenue à partir d'une **bande de confiance sur la fonction de répartition de X** :

$$\mathbb{P}(F_*(x) \leq F_X(x) \leq F^*(x), \forall x \in \mathbb{R}) = 1 - \alpha.$$

(A. Aregui et T. Denoeux. *Proceedings of ISIPTA '07*, 2007).



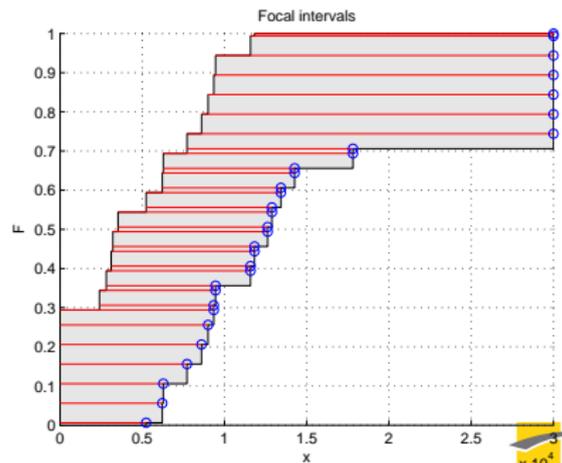
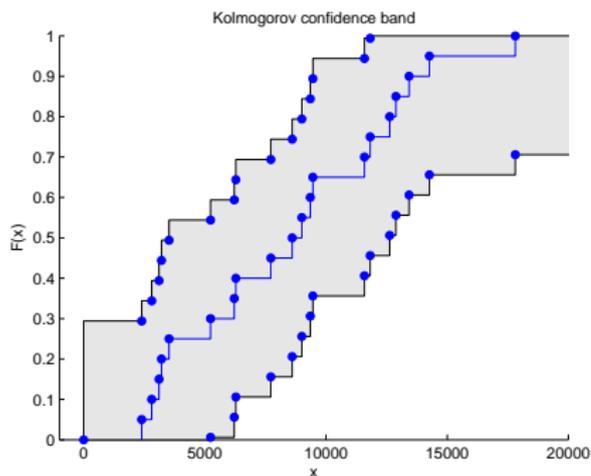
Fonction de croyance prédictive

Exemple

- Durées de vie de 20 roulement :
2398, 2812, 3113, 3212, 3523, 5236, 6215,
6278, 7725, 8604, 9003, 9350, 9460, 11584,
11825, 12628, 12888, 13431, 14266, 17809.
- $X =$ durée de vie d'un roulement. Fonction de croyance sur X ?

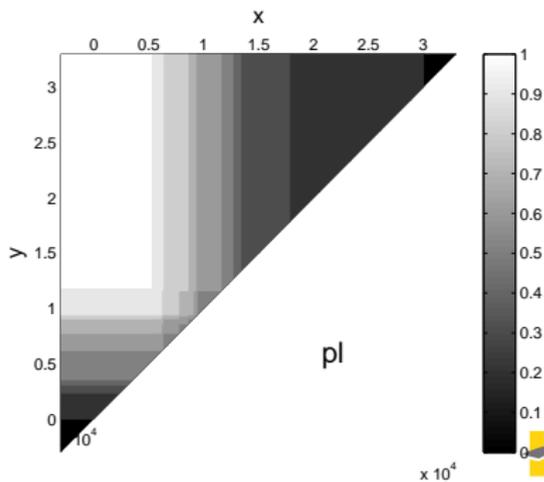
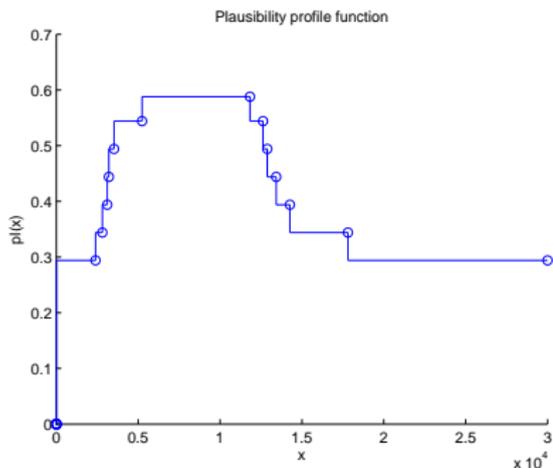
Fonction de croyance prédictive

Bande de confiance de Kolmogorov



Fonction de croyance prédictive

Fonction de plausibilité



Conclusion (1/2)

- La théorie des fonctions de croyance (TFC) est un **formalisme général** qui étend les notions d'ensemble et de distribution de probabilité : représentation simultanée de l'imprécision et de l'incertitude.
- La TFC n'est pas un ensemble de recettes ad hoc : elle peut être construite rigoureusement à partir d'un petit nombre de principes (engagement minimal, Hacking).
- La TFC comporte un grand nombre (une infinité) de **règles de fusion** reposant sur différentes hypothèses relatives à la fiabilité et à l'indépendance des sources :
 - \cap , \cup
 - règle prudente $\hat{\wedge}$ pour la combinaison d'information non indépendantes.

Conclusion (2/2)

- L'**affaiblissement contextuel** permet de représenter dans un même cadre :
 - les informations fournies par des sources ;
 - des métaconnaissances sur la fiabilité (pertinence) de ces sources.
- Existence de méthodes **générales et systématiques** permettant de construire des fonctions de croyance à partir d'informations de natures différentes :
 - similarités,
 - vraisemblances,
 - échantillons statistiques,
 - etc.

Références I

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



T. Denœux.

Conjunctive and Disjunctive Combination of Belief Functions Induced by Non Distinct Bodies of Evidence.
Artificial Intelligence, Vol. 172, pages 234-264, 2008.



D. Mercier, B. Quost et T. Denœux.

Refined modeling of sensor reliability in the belief function framework using contextual discounting.
Information Fusion, Vol. 9, pages 246-258, 2008.



Références II

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



T. Denœux.

Constructing Belief Functions from Sample Data Using Multinomial Confidence Regions.

International Journal of Approximate Reasoning, Vol. 42, Issue 3, Pages 228-252, 2006.



T. Denœux and P. Smets.

Classification using Belief Functions : the Relationship between the Case-based and Model-based Approaches.

IEEE Transactions on Systems, Man and Cybernetics B, Vol. 36, Issue 6, Pages 1395-1406, 2006.

