

$(\text{cond}_1 \wedge \text{cond}_2 \wedge \dots) \vee \text{conséq}$   
 $\text{cond}_1 \vee \neg \text{cond}_1 \vee \dots \vee \text{conséq}$

$\equiv \{p_1, p_2\} \vdash q$

image sur CL de Horn :  $\{p_1 \vee \neg p_1\} \Rightarrow \perp$

avant : modus ponens pour produire  $q$  et avoir  $\perp$

arrière : résol. de  $T_1$  avec règle au fait, ensuite applie. récursive sur les cond. de la règle

résol. de CL de Horn  $\times$  CL de Horn :  $T_1 \vee \dots \vee T_n \vee Y$

de contradiction possible entre  $d_1$  de  $H$ ,  $T_1 \vee \dots \vee T_n \vee X$

$X \neq T_X \Rightarrow$  procédure simplifiée  $T_1 \vee \dots \vee T_n \vee Y$



Traduction d'un problème de Planification en PSC (à partir de la page 1)

Repose sur 2 hypothèses:  
• On connaît la longueur maximale  $l$  du plan, c'est le nombre maximal d'états. → itérative de profondeur  
• On a déterminé toutes les actions (par avance) qui pourraient être nécessaires pour obtenir un plan d'action complet.

Description:  
• Séquence d'états  $S_1, S_2, \dots, S_{n+1}$  avec  $S_{n+1}$  état final qui n'admet plus aucune action.  
• Pour chaque état, le PSC contient 2 types de variables:  
\* Pour chaque action qui pourrait faire partie du plan, il existe une variable qui prendra la valeur vrai si l'action est exécutée dans cet état et faux si elle ne l'est pas.  
\* Pour chaque propriété qui caractérise les états dans le formalisme STRIPS, il existe une variable qui indique si la propriété est vraie ou fausse dans cet état.

Contraintes:  
• variable qui représente une action a des contraintes avec chaque variable qui représente une précondition dans le même état, c'est action  $\Rightarrow$  précondition  
• analogue pour les postconditions et les suppressions de chaque action  
• condition initiales  
• buts (= contraintes sur les variables du dernier état)  
• axiomes de cadres exprimés sous forme de contraintes (= si var. d'état pas touchée par une action, alors sa valeur au prochain état doit rester inchangée)  
• mutex entre toutes paires d'action tel que l'un nécessite la précondition de l'autre  
ex: a, a précond. p  
a, a post cond.  $\neg p$  | exécution simultanée

Exemple: Planifier avec PSC (missionnaires)

3 types d'acteurs: B, H, et M; C, et C2  
2 types d'actions: "transporter" g.d. et d.g.  
Proposition du Pair de Mouton:  
g(A), d(A) où A acteur.  
opérateurs du problème de Planif:  
g(B, M, A) où A  $\in$  {M, C, C2}  
d(B, M) incohérence de permettre C de revenir... (éviter les "boucles")

Conditions initiales:  
g(B) = g(M) = g(C) = g(C2) = True  
Conditions finales:  
d(B) = d(M) = d(C) = d(C2) = True  
Mutex de proposition:  
[ g(A), g(A) ] pour tout A (acteur)

Mutex d'opérateurs  
Pour chaque paire d'opérateurs distincts  $op_1$  et  $op_2$ , si les deux opérateurs ont un acteur en commun, on a le mutex: {  $op_1, op_2$  }  
qui traduit le fait qu'un bateau ne peut pas contenir deux équipages différents en même temps, et aussi qu'un même équipage ne peut se trouver sur deux bateaux différents en même temps.

5) mutex de propositions:  $\forall S, i, i' : 1 \leq i \leq n$   
g(A, S, i) NAND d(A, S, i)  
6) mutex d'opérateurs: de la même manière que pour les mutex de propositions:  $op_1(S, i) \text{ NAND } op_2(S, i)$

Planification linéaire est constituée d'une séquence d'états  $S_1, S_2, \dots, S_n$  où chaque  $S_i$  est défini par des propositions qui sont vraies ou fausses au début de l'état, un ensemble d'opérateurs qui sont exécutés pendant cet état, et des propositions qui sont vraies ou fausses à la fin de cet état.

Formalisme de STRIPS: OPERATEUR (X):

PRÉCONDITION(X) = ...  
DELETE(D) = ...  
ADD(A) = ...

Choix des variables:  
V  $S_i$ ,  $\bullet$  g(A, S, i) = True  $\Leftrightarrow$  A est sur la rive gauche à la fin de  $S_{i-1}$  / au début de  $S_i$   
d(A, S, i) = True  $\Leftrightarrow$  "droite"

Contraintes (6 types):  
1) Contraintes sur l'état initial: g(B, S0) = g(M, S0) = g(C, S0) = g(C2, S0) = True  
2) Contraintes sur l'état final: On "devine" le nbr d'états requis...  
d(B, S5) = d(M, S5) = d(C, S5) = d(C2, S5) = True  
3) Contraintes pré/post-conditions des opérateurs:  
Pour chaque état  $S_i$  avec  $i=0..n$  et chaque opérateur op:  
• pour chaque proposition prop qui est une postcondition de l'opérateur op:  
 $op(S_i) \Rightarrow \text{Prop}(S_{i+1})$   
• pour chaque proposition prop qui est une précondition de l'opérateur op:  
 $op(S_i) \Rightarrow \text{prop}(S_i)$   
4) contraintes PSC corresp. aux axiomes de cadres:  
Pour chaque proposition prop:  
• si  $\text{prop}(S_i) = \text{False}$  et  $\text{prop}(S_{i+1}) = \text{True}$ , alors pour au moins un opérateur op qui a prop comme postcondition, on a  $op(S_i) = \text{True}$   
• si  $\text{prop}(S_i) = \text{True}$  et  $\text{prop}(S_{i+1}) = \text{False}$ , ... qui a prop comme postcondition négative, on a  $op(S_i) = \text{True}$

Exemple 103

• données: 1 grand, allongé, rouge, piquant  
2 petit, allongé, rouge, piquant  
3 petit, rond, vert, piquant  
4 grand, rond, vert, piquant  
5 petit, allongé, jaune, piquant  
6 petit, rond, rouge, piquant

Incertitude sur la classification qui reste dans le cas où rouge est vrai:  $H(C|\text{rouge}=\text{vrai}) =$   
$$= - \sum_{v \in \{p, r\}} \Pr(v|\text{rouge}=\text{vrai}) \cdot \log(\Pr(v|\text{rouge}=\text{vrai}))$$
  
$$= -0.66 \log_2(0.66) - 0.33 \log_2(0.33)$$
  
$$= 0.92 \text{ bit}$$
  
même résultat pour  $H(C|\text{rouge}=\text{faux})$   
entropie moyenne  $\rightarrow$  moyenne pondérée  
$$H(C|\text{rouge}) = H(C|\text{rouge}=\text{vrai}) \cdot \Pr(\text{rouge}=\text{vrai}) + H(C|\text{rouge}=\text{faux}) \cdot \Pr(\text{rouge}=\text{faux})$$
  
$$= 0.5 \cdot 0.92 + 0.5 \cdot 0.92 = 0.92 \text{ bit}$$

Ce qu'on donne les étapes:  
1) a, b, c, d, e, f  
grand, petit ouvert: incert. moyenne restante: 1 bit  
rouge, allongé au rouge: 0.92 bit  
jaune: 0.81 bit  $\Rightarrow$  choisir jaune  
2) a, b, c, d, f  
grand ou petit: 0.955 bit  
rouge ou allongé: 0.554 bit  
rouge ou vert: 0.935 bit  $\Rightarrow$  choisir rouge  
3) a, d, f  
grand ou petit: 0.66 bit  $\Rightarrow$  choisir vert  
rouge ou vert: 0.66 bit (aléatoire)  
4) c, d  
grand ou petit: 0.6 bit  $\Rightarrow$  petit

Diagnostic: Quels sont les candidats valides?  $H_0$  = Boîte du Système  
comportement défectueux:  $H_0 \cup \text{OBS} \vdash \perp$   
2 versions:  
- le candidat explique les observations: (diag. médical p-eu)  
 $H_0 \cup \text{AND} \vdash \text{OBS}$   
- le candidat rend les observations consistantes: (diag. par exclusion)  
 $(H_0 - \text{CAN}) \cup \text{OBS} \not\vdash \perp$  (diag. auto)  
Le candidat valide

SVM: maximiser la séparation des exemples  $\Rightarrow$  choisir  $w$  ty:  
• toutes les instances positives:  $d \geq b_0$   
• négatives:  $d \leq -b_0$   
• Soit maximale

Théorie PAC: évaluer la qualité qu'on peut espérer d'un résultat d'apprentissage en fn de sa complexité et # d'exemples fournis  
• Probablement: classif. approx. correcte avec proba  $\delta$   
• Approximativement: proba d'erreur de classif. est  $\leq \epsilon$   
On suppose: N exemples, concept à apprendre parmi  $2^{|I|}$  possibilités  
• algo donne résultat correct sur tous les ex. fournis pour l'apprentissage  
•  $h \in M$  a en tout cas  $\geq \epsilon$   
Proba que  $h$  soit correct sur les N exemples:  
 $\Pr(\text{Correct}(h, N)) \leq (1-\epsilon)^N$   
PAC est solvable  $\Leftrightarrow$  Proba qu'il y ait un  $h$  qui est correct sur N exemples mais a un taux d'erreur  $\geq \epsilon$  sur de nouveaux exemples est  $\leq \delta$ :  $\delta \geq (1-\epsilon)^N$   
Limite sur N pour borne  $\delta_0$  sur  $\delta$ :  
 $N \geq \frac{\ln(\delta_0 / (1-\epsilon))}{\ln(1-\epsilon)}$   
Exemple pour domaine où 10 attributs: il y a au plus  $2^{10} = 1024$  différents attributs  
Donc si on veut  $\epsilon \leq 0.001$  avec proba  $\delta \geq 0.99$ , on doit avoir  $N \geq \frac{\ln(\delta / (1-\epsilon))}{\ln(1-\epsilon)} = 86434$  exemples  
Si on se contente de  $\epsilon \leq 0.05$ : 1680 exemples  
Méthode de bootstrap de l'arbre pour contraindre l'overfitting

Bagging et Boosting:

Bagging: appliquer un certain # n de méthodes d'apprentissage faible, choisies de manière aléatoire, et prendre un vote parmi les classificateurs: si au moins k sur n donnent un résultat positif, alors conclure avec classif. positive, sinon négative.  
Boosting: Construit R classification simple, en divisant chaque fois une distribution de proba des exemples qui met l'accent sur les exemples qui sont mal classés par les classificateurs  $R_i$  précédents.  
• Initialement, tous les exemples ont le même poids  $w_i = 1/n$ . L'algo est une itération pour  $i \in 1..R$ :  
1) for  $i \in 1..n$ ,  $P_i \leftarrow \frac{w_i}{\sum_{i=1}^n w_i}$   
2)  $h_i$ : résultat de la méthode faible avec les exemples et proba  $P_i$   
3) erreur  $\epsilon_i = \sum_{i=1}^n P_i |R(x_i) - c_i|$   
4)  $\beta_i \leftarrow \frac{\epsilon_i}{1-\epsilon_i}$   
5) for  $i \in 1..n$ ,  $w_i \leftarrow w_i \beta_i^{1-|R(x_i)-c_i|}$   
 $R_g(x) = \begin{cases} 1 & \text{si } \sum_{i=1}^R (-\log \beta_i) (R_i(x_i) - 1/2) \geq 0 \\ 0 & \text{sinon} \end{cases}$   
 $\rightarrow$  pour combiner les différents classificateurs.  
Le résultat de la classification est donc:  $R_g(x) = \log(2) R_1(x) + \log(2) R_2(x) + \log(6) R_3(x) - \log(2) + \log(7) + \log(6)$   
$$= 0.69 h_1(x) + 1.35 h_2(x) + 1.8 h_3(x) - 2.22$$
 où  $R_i(x)$  valent 0 ou 1 suivant le cas

Traitement de l'information incertaine: I = Route gelée, H = accident Holmes, W = accident Watson

a)  $P(H|I)$   $I=1$   $I=0$   
 $H=1$   $0.8$   $0.1$   
 $H=0$   $0.2$   $0.9$   
idem pour  $P(W|I)$  et  $P(W)$   
b) Construction de  $P(H)$  et  $P(W)$  par le processus de marginalisation:  
 $P(H=1) = 0.8 \cdot 0.7 = 0.56$   
 $P(H=0) = 0.2 \cdot 0.7 = 0.14$   
 $P(W=1) = 0.9 \cdot 0.3 = 0.27$   
 $P(W=0) = 0.1 \cdot 0.3 = 0.03$   
c) Proba que les routes soient gelées sachant que Watson a eu un accident:  
 $P(I=1|W=1) = \frac{P(W=1|I=1) \cdot P(I=1)}{P(W=1)} = \frac{0.8 \cdot 0.7}{0.27} = 0.95$   
d) Sachant que Watson a eu un accident,  $P(H)$ ?  
 $P(H=1) = 0.8 \cdot 0.95 = 0.76$   
 $P(H=0) = 0.2 \cdot 0.95 = 0.19$   
et donc  $P(H)$  a augmenté!

Théorie de Dempster et Shafer.

Événement: Proba  $\in [0,1]$   
la limite inférieure est appelée la crédibilité  
la limite supérieure est appelée la plausibilité  
ex: pluie  $\Rightarrow$  mouille.  
crédibilité de mouille au moins égal à  $P(\text{pluie})$ .  
Cependant,  $P(\text{mouille})$  peut être bcp plus élevé si bcp de causes.  
Plausibilité affectée par les contre-indications à mouille.  
SEC  $\Rightarrow$  mouille.  
Donc plausibilité  $\approx 1 - P(\text{sec})$   
Si causes / Évén. pas indep. devient très vite complexe!

Bonifier (Bourgogne, ? année, 2007): quel est l'élément de la case? Éliminer (Win, ? année)

Proposition de mesure  
Entropie de X étant donnée la mesure de V:  $E(X|V) = \sum_i P(v_j) \sum_i P(x_i | v_j) \log P(x_i | v_j)$   
Probabilité de mesurer la valeur  $h$  pour la variable  $i$ : où  $P_i$ : ensemble des candidats qui prédisent la valeur  $h$  pour la variable  $i$   
 $P(\text{var}_i = \text{val}_i) = \sum_{c \in P_i} p(c) + \sum_{c \notin P_i} p(c)/m$   
c: candidats qui ne donnent aucune valeur pour la mesure  $i$   
Normaliser pour que  $\sum_i P(\text{val}_i) = 1$   
CAN

4/ Stock de bon Bourgogne pour l'année 2007?

Théorie de Dempster et Shafer.  
Événement: Proba  $\in [0,1]$   
la limite inférieure est appelée la crédibilité  
la limite supérieure est appelée la plausibilité  
ex: pluie  $\Rightarrow$  mouille.  
crédibilité de mouille au moins égal à  $P(\text{pluie})$ .  
Cependant,  $P(\text{mouille})$  peut être bcp plus élevé si bcp de causes.  
Plausibilité affectée par les contre-indications à mouille.  
SEC  $\Rightarrow$  mouille.  
Donc plausibilité  $\approx 1 - P(\text{sec})$   
Si causes / Évén. pas indep. devient très vite complexe!

Proposition de mesure

Entropie de X étant donnée la mesure de V:  $E(X|V) = \sum_i P(v_j) \sum_i P(x_i | v_j) \log P(x_i | v_j)$   
Probabilité de mesurer la valeur  $h$  pour la variable  $i$ : où  $P_i$ : ensemble des candidats qui prédisent la valeur  $h$  pour la variable  $i$   
 $P(\text{var}_i = \text{val}_i) = \sum_{c \in P_i} p(c) + \sum_{c \notin P_i} p(c)/m$   
c: candidats qui ne donnent aucune valeur pour la mesure  $i$   
Normaliser pour que  $\sum_i P(\text{val}_i) = 1$   
CAN

Théorie PAC

Théorie PAC: évaluer la qualité qu'on peut espérer d'un résultat d'apprentissage en fn de sa complexité et # d'exemples fournis  
• Probablement: classif. approx. correcte avec proba  $\delta$   
• Approximativement: proba d'erreur de classif. est  $\leq \epsilon$   
On suppose: N exemples, concept à apprendre parmi  $2^{|I|}$  possibilités  
• algo donne résultat correct sur tous les ex. fournis pour l'apprentissage  
•  $h \in M$  a en tout cas  $\geq \epsilon$   
Proba que  $h$  soit correct sur les N exemples:  
 $\Pr(\text{Correct}(h, N)) \leq (1-\epsilon)^N$   
PAC est solvable  $\Leftrightarrow$  Proba qu'il y ait un  $h$  qui est correct sur N exemples mais a un taux d'erreur  $\geq \epsilon$  sur de nouveaux exemples est  $\leq \delta$ :  $\delta \geq (1-\epsilon)^N$   
Limite sur N pour borne  $\delta_0$  sur  $\delta$ :  
 $N \geq \frac{\ln(\delta_0 / (1-\epsilon))}{\ln(1-\epsilon)}$   
Exemple pour domaine où 10 attributs: il y a au plus  $2^{10} = 1024$  différents attributs  
Donc si on veut  $\epsilon \leq 0.001$  avec proba  $\delta \geq 0.99$ , on doit avoir  $N \geq \frac{\ln(\delta / (1-\epsilon))}{\ln(1-\epsilon)} = 86434$  exemples  
Si on se contente de  $\epsilon \leq 0.05$ : 1680 exemples  
Méthode de bootstrap de l'arbre pour contraindre l'overfitting