

## Introduction à la classification supervisée

Fabien Torre

Université de Lille

Mercredi 23 septembre 2009

### Historique : la motivation venue des systèmes experts

- Volonté de remplacer les experts humains ;
- mise en place de raisonnements automatiques sur des faits et des règles ;
- mais où trouver les règles ? les demander à l'expert.
- mais l'humain peut difficilement expliciter son expertise (cf. *hiver de l'Intelligence Artificielle*) ;
- on peut simplement lui demander de faire ce qu'il sait faire ;
- l'observer et apprendre.

### La motivation de la découverte (2)

#### Bilan

Découverte scientifique là où il n'y a pas ou peu d'expertise humaine.

Vocabulaire : règles/hypothèses et classifieurs/théorie.

#### À vous de jouer ?

- Loto : prédire le gain d'une grille ?
- football : prédire les résultats.
- etc.

Comment modéliser ces problèmes ?

### Étiquetage des exemples

#### Étiquettes et prédictions possibles : $\mathcal{Y}$

- binaires (-1 et +1) ou discrètes à plus de deux valeurs ;
- continues (*régression*) ;
- plus complexe (*sortie structurée*),

parfois avec une valeur de confiance.

#### Différents étiquetages des exemples

- tous étiquetés : *apprentissage supervisé* ;
- aucun étiqueté : *apprentissage non supervisé* ;
- un peu des deux : *semi-supervisé* (ex : les pages web) ;
- à la demande : *apprentissage actif* ;
- et aussi *apprentissage par positifs seuls* ! (ex : parents-enfants).

### Exemples de tâches

On veut répondre automatiquement à des questions comme :

- le patient aura-t-il un accident cardio-vasculaire ?
- la molécule que je désire commercialiser est-elle cancérigène ?
- qui est l'auteur de cette page HTML ?
- cette phrase est-elle grammaticalement correcte ?
- quelle sera la taille de cet enfant à l'âge adulte ?

Ne pas écrire des programmes qui répondent à ces questions... mais les découvrir automatiquement, par apprentissage (observation d'exemples et de contre-exemples).

En vue de prédire (classer de nouveaux exemples), on ne peut donc pas apprendre par cœur !

### Aujourd'hui : la motivation de la découverte

- INDANA [Colombet, 2002] :
  - prédiction du risque cardio-vasculaire après un examen minimal ;
  - des économies réalisées...
- Skicat [Fayyad, 1995] :
  - quel secteur du ciel regardé ? plusieurs téraoctets de données ;
  - 40 fois plus d'objets découverts par nuit d'observation, dépasse l'humain sur les objets faiblement lumineux ;
- molécules cancérigènes [Srinivasan et al., 1994] :
  - décider si un produit peut être diffusé, expérimentations de plusieurs années sur des animaux ;
  - bonnes performances, au croisement de plusieurs disciplines.

### Les points à définir

- 1 Ce que l'on veut prédire ;
- 2 modalité d'obtention des exemples ;
- 3 nature des exemples, nature des classifieurs ;
- 4 mode d'évaluation des prédictions ;
- 5 méthode d'apprentissage.

### Arrivée des exemples

Parallèle avec les interactions enseignant-élève.

- Échantillon fixé à l'avance : cadre expérimental,  $A$  un ensemble d'exemples disponibles pour l'apprentissage, éventuellement  $T$  un ensemble de test indépendant de  $A$ .
- obtention incrémentale des exemples :
  - un par un et disponible à l'infini : *modèle de [Gold, 1967]* (influence de l'apprentissage d'une langue par le bébé humain)
  - disponible en nombre polynomial : *PAC, modèle de [Valiant, 1984]* ;
  - soumission d'un exemple et étiquetage par un oracle : *apprentissage actif* ;


### Difficultés possibles dans les exemples

- Bruit dans les données (classes, description) ;
- valeurs manquantes dans les descriptions ;
- déséquilibre de classes ;
- complexité de la description même des exemples (langage  $\mathcal{X}$ ) :
  - vecteur,
  - séquences,
  - arbres,
  - graphes.

### Séquences et IG


Les exemples sont des séquences :

- + :  $\epsilon, aaa, b, abbaa, aaaaa$
- - :  $bba, aab, bbaababa$



Inférence Grammaticale.

### Arbres



Problématiques liées aux documents semi-structurés (XML) :

- classification d'arbres et inférence de DTD ;
- extraction n-aire et apprentissage de transformations.

Au croisement de l'IG, de l'ILP et des langages formels d'arbres.

### Évaluations possibles

- La compréhensibilité !
- évaluation théorique, l'erreur en généralisation : probabilité de se tromper en classant un nouvel exemple ;
- modèle de Gold : découverte du concept cible, erreur nulle, à la limite ;
- *probably approximately correct* (PAC) : erreur inférieure à  $\epsilon$  avec une probabilité  $1 - \delta$  après observation d'un nombre polynomial d'exemples ;
- évaluation expérimentale, approximation de l'erreur en généralisation : erreur en apprentissage (calculée sur  $A$ ), erreur de test (calculée sur  $T$ ).

### Vecteurs en attributs-valeurs

Les exemples sont des vecteurs de valeurs discrètes ou continues :

|                  |   |   |
|------------------|---|---|
| ClumpThickness   | 5 | 5 |
| UniformitySize   | 1 | 3 |
| UniformityShape  | 1 | 3 |
| MarginalAdhesion | 1 | 3 |
| BareNuclei       | 1 | 3 |
| BlandChromatin   | 3 | 4 |
| NormalNucleoli   | 1 | 4 |
| Mitoses          | 1 | 1 |
| Conclusion       | B | M |

if ClumpThickness  $\leq$  6.0  
then class B [weight=0.07]

if MarginalAdhesion  $\leq$  8.0  
then class M [weight=0.05]

Méthodes attributs-valeurs (arbres de décision vus en M1).

### Graphes et ILP

Les exemples sont des graphes :



active( $M$ )  $\leftarrow$  atom( $M, A1, carbon, 22$ ),  
atom( $M, A2, carbon, 10$ ),  
bond( $M, A1, A2, 1$ ).

Programmation Logique Inductive.

### Difficultés possibles avec les hypothèses

- garantie de l'existence du concept-cible ?
- cible évoluant dans le temps (*révision de théorie*) ;
- concept disjonctif..
- ... nous cherchons une unique hypothèse de  $\mathcal{H}$ , une disjonction ou un ensemble ?
- complexité de la description même des hypothèses (langage  $\mathcal{H}$ ) :
  - règles ou arbres de décisions,
  - automates ou grammaires,
  - programmes logiques.

### Évaluations expérimentales

- Matrice de confusion calculée sur un ensemble de test :

| Prediction \ Classe | -1 | +1 |
|---------------------|----|----|
| -1                  | vn | fn |
| +1                  | fp | vp |

- à partir de cette matrice :
  - *accuracy* :  $\frac{vp+vn}{vp+vn+fp+fn}$  ;
  - rappel :  $R = \frac{vp}{vp+fn}$  et précision  $P = \frac{vp}{vp+fp}$  ;
  - f-mesure :  $F = 2 \times \frac{P \times R}{P+R}$  ;
  - sensibilité  $Se = R$  et spécificité  $Sp = \frac{vn}{vn+fp}$  ;
- validations croisées et *leave-one-out* ;
- test statistique 5x2cv [Dietterich, 1998].



## Bibliographie II

 Gold, E. M. (1967).  
**Language identification in the limit.**  
*Information and Control*, 10(5) :447–474.

 Srinivasan, A., Muggleton, S., King, R. D., and Sternberg, M. J. E. (1994).  
**Mutagenesis : ILP experiments in a non-determinate biological domain.**  
 In Wrobel, S., editor, *Proceedings of the 4th International Workshop on Inductive Logic Programming*, volume 237 of *GMD-Studien*, pages 217–232. Gesellschaft für Mathematik und Datenverarbeitung MBH.

## Bibliographie III

 Valiant, L. G. (1984).  
**A theory of the learnable.**  
*Communications of the ACM*, 27 :1134–1142.

 Wolpert, D. H. and Macready, W. G. (1995).  
**No free lunch theorems for search.**  
 Technical Report SFI-TR-95-02-010, The Santa Fe Institute.