

Module Master Recherche

Apprentissage et Fouille

Michele Sebag — Balazs Kegl — Antoine Cornuéjols
<http://tao.lri.fr>

17 décembre 2007

Pour quoi faire

- ▶ Prédiction
pannes, maladies, achats, préférences,...
- ▶ Compréhension
facteurs de risque, analyse de survie
- ▶ Interaction
les jeux ; “Super-Google”
- ▶ Optimisation—Conception
apprendre pour décider

Machine Learning – Apprentissage Artificiel

Data Mining – Fouille de Données

Le contexte international

L'idéal le siècle des connaissances

La réalité des spécialistes, dialogue difficile
le savoir-faire : des traces dans les données

Le besoin la gestion humaine des connaissances
ne passe pas à l'échelle

L'opportunité les données sont accessibles

OBJECTIF

fournir [à l'expert]
des connaissances nouvelles, utiles, valides

L'une des 10 technologies émergentes du 21^e siècle

Le contexte, Master Informatique Paris-Sud

Autres modules ayant un rapport

- ▶ Traitement statistique de l'information
- ▶ Représentation des connaissances
- ▶ Algorithmes d'évolution et robotique

Ce module

- ▶ Théorie
- ▶ Etudes de cas
- ▶ Présentations d'articles 10 mn / volontaires

Examen

- ▶ Questions de cours
- ▶ Au choix:
 - ▶ Exposé (présentation orale + résumé) d'un article
 - ▶ Projet (algos, données, comparaison, rapport)

Plan du Module

Etudes de cas — domaines

- | | |
|---------------------------------|--|
| 1. Skicat | arbres de décision |
| 2. Reconnaissance de caractères | apprentissage d'ensembles,
boosting |
| 3. Autonomic Computing | apprentissage non supervisé
streaming |
| 4. Expérience Auger | approches génératives |
| 5. Netflix | filtrage collaboratif |
| 6. MoGo | apprentissage en-ligne |
| 7. Robotique | reduction de dimension
apprentissage par renforcement |
| 8. Satisfaction de contraintes | apprentissage relationnel |

Quelques bonnes adresses

- ▶ Où sont les cours :
<http://tao.lri.fr/tiki-index.php?page=Courses>
- ▶ Module Traitement Statistique de l'Information
<http://www.limsi.fr/Individu/allauzen/wiki/index.php/TSI07>
- ▶ Les cours (transparents) d'Andrew Moore
<http://www.autonlab.org/tutorials/index.html>
- ▶ Les cours (videos) de PASCAL
<http://videolectures.net/pascal/>
- ▶ Les tutoriels de NIPS Neuro Information Processing Systems
<http://nips.cc/Conferences/2006/Media/>
- ▶ Des questions intéressantes
<http://hunch.net/>

Plan de ce cours

1. Introduction, définitions, objectifs
2. Méthodologie
3. Classification
4. Etude de cas : SKICAT

Introduction

Fouille de données, une définition...

Fayyad et al. 1996

Automatic extraction of
novel, useful and valid knowledge
from large sets of data.

des connaissances { nouvelles
utiles
valides

...imprécise...
% au sens commun
pour qui
un pb multi-critères

Domaines d'application

Domaine

But : Modélisation

Phénomènes physiques modélisation et contrôle de process

Applications industrielles, sciences expérimentales, calcul numérique

Phénomènes sociaux + confidentialité

Hôpitaux, Assurances, Banques, ...

Phénomènes individuels + dynamique rapide

Consumer Relationship Management

User Modelling

PASCAL : <http://www.pascal-network.org>

Définitions


Exemple

- ▶ ligne : exemple/
cas/individus/transactions
- ▶ colonne : attribut/
fea-
ture/variables/items
- ▶ (optionnel) : attribut
classe

age	employe	education	educ	marital	...	job	relation	race	gender	hour	country	wealth
39	State_gov	Bachelors	13	Never_mar...	...	Adm_clerk	Not_in_fan	White	Male	40	United_States	poor
51	Self_emp	Bachelors	13	Married	...	Exec_mani	Husband	White	Male	13	United_States	poor
39	Private	HS_grad	9	Divorced	...	Handlers_c	Not_in_fan	White	Male	40	United_States	poor
54	Private	11th	7	Married	...	Handlers_c	Husband	Black	Male	40	United_States	poor
28	Private	Bachelors	13	Married	...	Prof_speci	Wife	Black	Female	40	Cuba	poor
38	Private	Masters	14	Married	...	Exec_mani	Wife	White	Female	40	United_States	poor
50	Private	9th	5	Married_sp...	...	Other_ser	Not_in_fan	Black	Female	16	Jamaica	poor
52	Self_emp	HS_grad	9	Married	...	Exec_mani	Husband	White	Male	45	United_States	rich
31	Private	Masters	14	Never_mar...	...	Prof_speci	Not_in_fan	White	Female	50	United_States	rich
42	Private	Bachelors	13	Married	...	Exec_mani	Husband	White	Male	40	United_States	rich
37	Private	Some_coll	10	Married	...	Exec_mani	Husband	Black	Male	80	United_States	rich
30	State_gov	Bachelors	13	Married	...	Prof_speci	Husband	Asian	Male	40	India	rich
24	Private	Bachelors	13	Never_mar...	...	Adm_clerk	Own_child	White	Female	30	United_States	poor
33	Private	Assoc_acc	12	Never_mar...	...	Sales	Not_in_fan	Black	Male	50	United_States	poor
41	Private	Assoc_voc	11	Married	...	Craft_repa	Husband	Asian	Male	40	MissingV	rich
34	Private	7th_8th	4	Married	...	Transport	Husband	Amer_Indi	Male	45	Mexico	poor
26	Self_emp	HS_grad	9	Never_mar...	...	Farming_fi	Own_child	White	Male	35	United_States	poor
33	Private	HS_grad	9	Never_mar...	...	Machine_c	Unmarried	White	Male	40	United_States	poor
38	Private	11th	7	Married	...	Sales	Husband	White	Male	50	United_States	poor
44	Self_emp	Masters	14	Divorced	...	Exec_mani	Unmarried	White	Female	45	United_States	rich
41	Private	Doctorate	16	Married	...	Prof_speci	Husband	White	Male	60	United_States	rich
:	:	:	:	:	:	:	:	:	:	:	:	:

Espace des instances $\mathcal{X}$

- ▶ Propositionnel :
 $\mathcal{X} \equiv \mathbb{R}^d$
- ▶ Relationnel : ex.
chimie.



molécule alanine

Apprentissage supervisé / non supervisé

Base d'apprentissage $\mathcal{E}$

Apprentissage supervisé

- ▶ $\mathcal{E} = \{(x_i, y_i), x_i \in \mathcal{X}, y_i \in \mathcal{Y}, i = 1 \dots n\}$
 - ▶ Classification : $\mathcal{Y}$ fini (ex, nom de maladie)
 - ▶ Régression : $\mathcal{Y} \subseteq \mathbb{R}$ (ex, durée de survie)
- ▶ Espace des hypothèses $\mathcal{H} : \mathcal{X} \rightarrow \mathcal{Y}$
 - ▶ Choisir $\mathcal{H}$ sélection de modèle
 - ▶ Evaluer $h \in \mathcal{H}$ $score(h)$
 - ▶ Choisir h^* dans $\mathcal{H}$ $argmax score(h)$

Apprentissage non supervisé

- ▶ $\mathcal{E} = \{x_i, x_i \in \mathcal{X}, i = 1 \dots n\}$
- ▶ Objectif : clustering (distance ou similarité)
- ▶ Idem : analyse de données exploratoire

Extraction de régularités

Base d'apprentissage $\mathcal{E}$

variables/items booléens

Extraction d'itemsets fréquents

- ▶ Input : seuil de fréquence ϵ
- ▶ Output : tous les sous-ensembles d'items $I = i_1, \dots, i_t$ tq

$$\frac{|\{I \subseteq x_i\}|}{n} > \epsilon$$

Règles d'association

- ▶ Input : seuil de fréquence ϵ , seuil de confiance δ
- ▶ Output : toutes les règles $I \Rightarrow J$ tq

$$\frac{|\{I \subseteq x_i\}|}{n} > \epsilon \quad \frac{|\{(I \cup J) \subseteq x_i\}|}{|\{I \subseteq x_i\}|} > \delta$$

Extraction de régularités (2)

Exemple

- ▶ Base de données
Tickets de caisse dans un supermarché
Dossiers clients d'une compagnie d'assurances
- ▶ Itemsets fréquents
 $I = \{ \textit{Vendredi}, \textit{bière}, \textit{couches} \}$
 $I = \{ \textit{Pain}, \textit{beurre}, \textit{confiture} \}$
- ▶ Règles d'association
 $\textit{Vendredi}, \textit{couches} \Rightarrow \textit{bière}$
 $\textit{Pain}, \textit{beurre} \Rightarrow \textit{Confiture}$

Sources de difficulté

Qualité des données / de la représentation

- Bruit ; données manquantes
- + Attributs pertinents Feature extraction
- Données structurées : spatio-temporelles, relationnelles, textes, videos ..

Distribution des données

- + Exemples indépendants, identiquement distribués
- Autres cas: robotique; flots de données; données hétérogènes...

Connaissances a priori

- + Critères d'intérêt
- + Contraintes sur la solution

Sources de difficulté (2)

Critère d'apprentissage

- + Fonction convexe : un seul optimum
- ↘ Complexité : n , $n \log n$, n^2 Passage à l'échelle
- Optimisation combinatoire

H. Simon, 1958:

In complex real-world situations, optimization becomes approximate optimization since the description of the real-world is radically simplified until reduced to a degree of complication that the decision maker can handle.

Satisficing seeks simplification in a somewhat different direction, retaining more of the detail of the real-world situation, but settling for a satisfactory, rather than approximate-best, decision.

Critères, suite

Critères de l'utilisateur

- ▶ Pertinence, Causalité
- ▶ INTELLIGIBILITE
- ▶ Simplicité
- ▶ Stabilité
- ▶ Interactivité, rapidité, visualisation
- ▶ ... Apprentissage de préférences

Sources de difficulté (3)

Crossing the chasm

- ▶ Pas de *killer algorithm*
- ▶ Peu de recommandations a priori

Critères de performance d'un algorithme

- ▶ Consistance

Quand le nombre d'exemples tend vers l'infini
et que le concept cible h^* est dans $\mathcal{H}$
l'algorithme le trouve.

$$\lim_{n \rightarrow \infty} h_n = h^*$$

- ▶ Vitesse de convergence

$$\|h^* - h_n\| = \mathcal{O}(1/n), \mathcal{O}(1/\sqrt{n}), \mathcal{O}(1/\ln n)$$

Contexte

Disciplines et critères


- ▶ Bases/Fouille de Données
Passage à l'échelle ; au plus près des données
- ▶ Statistiques et analyse de données
Modèles prédéfinis ; évaluation
- ▶ Apprentissage artificiel
Connaissances du domaine ; représentations complexes
- ▶ Optimisation
problèmes bien ou mal posés
- ▶ Interface Homme Machine
Pas de solution finale : un dialogue
- ▶ Calcul hautes performances
Données réparties, confidentialité

Plan de ce cours

1. Introduction, définitions, objectifs
2. Méthodologie
3. Classification
4. Etude de cas : SKICAT

Data Mining: A KDD Process

- Data mining: the core of knowledge discovery process.



Méthodologie


Les étapes

- | | |
|-----------------------------------|-------------------------------------|
| 1. Collecte des données | expert, DB |
| 2. Nettoyage | stat, expert |
| 3. Sélection | stat, expert |
| 4. Fouille / Apprentissage | |
| ▶ Description | <i>Qu'y a-t-il ds les données ?</i> |
| ▶ Prédiction | <i>Décider sur un cas</i> |
| ▶ Agrégation | <i>Prendre une décision globale</i> |
| 5. Visualisation | chm |
| 6. Evaluation | stat, chm |
| 7. Recherche de nouvelles données | expert, stat |

Un processus itératif en fonction

des attentes, des données initiales, et des connaissances a priori.

Data Mining and Business Intelligence



Données / Applications

- ▶ Données propositionnelles
80% des applis.
- ▶ Données spatiales, temporelles
alarmes, gisements, accidents
- ▶ Données relationnelles
chimie, biologie
- ▶ Données semi-structurées
texte, Web
- ▶ Données multi-media
images, sons, films,...

Plan de ce cours

1. Introduction, définitions, objectifs
2. Méthodologie
3. Classification
4. Etude de cas : SKICAT

Classification, Problème posé

INPUT

$\sim P(x, y)$

$$\mathcal{E} = \{(x_i, y_i), x_i \in \mathcal{X}, y_i \in \{0, 1\}, i = 1 \dots n\}$$

ESPACE des HYPOTHESES

$$\mathcal{H} \quad h : \mathcal{X} \mapsto \{0, 1\}$$

FONCTION de PERTE

$$\ell : \mathcal{Y} \times \mathcal{Y} \mapsto \mathbb{R}$$

OUTPUT

$$h^* = \arg \max \{score(h), h \in \mathcal{H}\}$$

Classification, critères

Erreur en généralisation

$$Err(h) = E[\ell(y, h(x))] = \int \ell(y, h(x)) dP(x, y)$$

Erreur empirique

$$Err_e(h) = \frac{1}{n} \sum_{i=1}^n \ell(y_i, h(x_i))$$

Borne

risque structurel

$$Err(h) < Err_e(h) + \mathcal{F}(n, d(\mathcal{H}))$$

$d(\mathcal{H})$ = dimension de VC de $\mathcal{H}$, voir après

Dimension de Vapnik Cervonenkis

Principe

Soit $\mathcal{H}$ un ensemble d'hypothèses: $\mathcal{X} \mapsto \{0, 1\}$

Soit $x_1, \dots, x_n$ un ensemble de points de $\mathcal{X}$.

Si, $\forall (y_i)_{i=1}^n \in \{0, 1\}^n, \exists h \in \mathcal{H} / h(x_i) = y_i$,

$\mathcal{H}$ pulvérise $\{x_1, \dots, x_n\}$

Exemple: $\mathcal{X} = \mathbb{R}^p$

$d(\text{hyperplans de } \mathbb{R}^p) = p + 1$

Rq: si $\mathcal{H}$ pulvérise $\mathcal{E}$, $\mathcal{E}$ ne nous apprend rien...

Définition

$$d(\mathcal{H}) = \max\{n / \exists (x_1, \dots, x_n) \text{ pulvérisé par } \mathcal{H}\}$$

Classification, termes d'erreur

Biais

Biais ($\mathcal{H}$): erreur de la meilleure hypothèse h^* de $\mathcal{H}$

Variance

Variance de h_n en fonction de $\mathcal{E}$

Erreur d'optimisation

négligeable à la petite échelle
prend le dessus à la grande échelle


(Google)

Espace d'hypothèses

Hypothèses numériques

► Fonctions linéaires


$$h(x) = 3x_1 + 2.17x_2 - 5x_3$$



Hypothèses numériques, 2


Réseaux neuronaux

$$S(x) = \text{sigma}(w_1z_1 + w_2z_2 + \dots + w_pz_p + w_0)$$



Muti-layer perceptron

$$\text{avec } \text{sigma}(X) = \frac{1}{1+e^{-X}}$$



Hypothèses discrètes

Formules booléennes

- Conjonctions

Panne si $\neg$ Essence

Malade si ($Temperature > 39.5$)


- Liste de décision

$L_1 \wedge L_2 \dots$	Panne
$L'_1 \wedge L'_2 \dots$	non Panne
$\dots$	
default	non Panne

Arbres de décision

C4.5 (Quinlan 86)

- ▶ Parmi les algorithmes les plus utilisés
- ▶ Facile
 - ▶ à comprendre
 - ▶ à implémenter
 - ▶ à utiliser
 - ▶ et peu cher en temps calcul
- ▶ J48, Weka



Arbres de décision, 2

Principe

1. Pour $\mathcal{E} = \{(x_i, y_i)_{i=1}^n, x_i \in \mathbb{R}^n, y_i \in \{0, 1\}\}$
 - Si $\mathcal{E}$ monoclasse ($\forall i, j, y_i = y_j$), stop
 - Si n trop petit, stop
 - Sinon, trouver l'attribut att le plus informatif
2. Pour toute valeur val de att
 - Considérer $\mathcal{E}_{val} = \mathcal{E} \cap [att = val]$.
 - Goto 1.

Critère gain d'information

$$\begin{aligned}p &= Pr(Class = 1 | att = val) \\ I([att = val]) &= -p \log p - (1 - p) \log (1 - p) \\ I(att) &= \sum_i Pr(att = val_i) I([att = val_i])\end{aligned}$$

Complexité

Quantité d'information d'un attribut


$$n \ln n$$

Pour construire un noeud

$$p \times n \ln n$$

Arbres de décision, 3

Table de contingence



Limitations

- ▶ Cas du XOR
- ▶ Attributs avec de nombreuses valeurs
- ▶ Attributs numériques
- ▶ Overfitting

Limitations

Attributs numériques

- ▶ Ordonner les valeurs $val_1 < \dots < val_t$
- ▶ Calculer QI ($[att < val_i]$)
- ▶ $QI(att) = \max_i QI([att < val_i])$


XOR

Biaiser la distribution des exemples

Limitations, 2

Overfitting

- ▶ Le but n'est pas de coller aux données d'apprentissage
- ▶ ... mais d'être bon en général
- ▶ Il faut ajuster le compromis empirique/généralité
- ▶ Comment : Validation croisée



Validation croisée

Principe

- ▶ Découper $\mathcal{E}$ en 10 sous-ensembles $\mathcal{E}_i$ stratifiés
- ▶ $\mathcal{E}^i = \mathcal{E} \setminus \mathcal{E}_i$
- ▶ Apprendre $h_i(param)$ à partir de $\mathcal{E}^i$
- ▶ $score_i(param)$: Evaluer $h_i(param)$ sur $\mathcal{E}_i$
- ▶ $score(param) = \sum_{i=1}^{10} score_i(param)$

Retenir $param^* = \operatorname{argmax}\{score(param)\}$

Plan de ce cours


1. Introduction, définitions, objectifs
2. Méthodologie
3. Classification
4. Etude de cas : SKICAT

U. M. Fayyad, S. G. Djorgovski, and N. Weir. 1996
Jet Propulsion Lab., Caltech

- ▶ Quel secteur du ciel regarder ?
- ▶ Térabytes de données
- ▶ Classification : étoiles, étoiles radiantes, galaxies, artefacts
- ▶ Arbres de décision
- ▶ Nb étoiles découvertes/nuit d'observation

Gain d'un facteur 40

The SKICAT System



SKICAT, 2

Objectif final

catalogue du ciel

objets d'un ordre de grandeur moins brillants

Caltech, release 93

$\approx 40,000$ volumes

Le problème

trop nombreux candidats : artefacts ?



3 Téra bytes.

tera Terrorbytes

Skicat, 3

L'opportunité

- ▶ photos à haute précision (longue mise au point)
- ▶ ... permettant l'étiquetage par les experts
- ▶ photos à basse précision
- ▶ ... inutilisable par les experts



Skicat, 4

Variabilité

entre géologues
pour un même géologue

Critère

non pas la vérité absolue
des performances de même ordre



Skicat, 5

Mise en œuvre

apprentissage % photos de mise au point.
pré-traitement

- ▶ brillance, surface, voisinage,...
- ▶ extraction d'un échantillon
- ▶ analyse en composantes principales
- ▶ recodage

Plus d'informations:

http://www.astro.caltech.edu/~george/dposs/DPOSS_III.pdf

Skicat, fin

Impact

Automate a task $\approx$ tens of man years.

Provide a consistent and objective means for a comprehensive analysis of a scientifically important data set.

Achievements

94% classification accuracy

Classified objects: one magnitude fainter than previously

200% increase in size of data usable in analysis.


Exceeds human ability in classifying faint objects, solution achieved automatically using learning algorithms on astronomer-provided training data.

Skicat, fin, 2

The classification rules produced by the inductive learning techniques form an objective, repeatable, examinable basis for classifying sky objects.

Since the automated approach allows us to classify faint sky objects that cannot be processed visually or by traditional computational techniques, the content of the catalog produced from the survey is increased by three-fold, since the majority of objects in each image are faint.

The training data for faint sky objects was obtained by examining a limited set of higher resolution CCD images covering minute portions of the survey. The learning algorithms are trained to predict the class (only obtainable by humans from higher resolution images) based on measurements from the survey. We thus classify objects that have to date not been classifiable by known techniques.



A posteriori

Fayyad, nov. 2003


Personne ne connaissait les données mieux que les astronomes (30 ans).

Mais le concept (une fois résolu) fait intervenir 8 variables/attributs parmi 40.

DARPA Challenge - 2005



Vision de près



2

[

Apprentissage en ligne et Bootstrap





Fig. 2. Real-time generated map of the vehicle vicinity.

The left image shows close-range map as generated by the laser scanners. Red cells are occupied by obstacles, white cells are drivable and grey cells are (as yet) unknown. The black quadrangle is fit into the known empty area and shipped to the computer vision algorithm as training data for drivable road surface.

The right image shows a long-range map as generated by the computer-vision algorithm described in this paper. It can be seen that the road detection range is in this case about 70m, as opposed to only 22m using lasers.

Vitesse



Plus de détails:

<http://robots.stanford.edu/papers/dahlkamp.adaptvision06.pdf>

Le but de la collecte

Les données sont-elles collectées pour l'analyse ?

Usage dérivé, reformulation des données.

Passage à l'échelle

efficacité quand les données ne tiennent pas en mémoire

données (même aléatoires) de grande taille

⇒ contiennent des motifs réguliers.

critères statistiques → comportement asymptotique

besoin de mesures de qualité

Avec du recul

Vision

DM elevates the way we interact with DB

like to see three buttons:

What's new

What's interesting

Predict for me

Myth

DM pervasive; Large datawarehouses; Companies know how

Integrated view

Success means invisibility

Maps findings to actions

Integrating domain knowledge: no AI-hard: deep and narrow.

Technical challenges

- ▶ How does the data grow ? Not iid. specially with time.
- ▶ Explain how, when, why, a model fails.
- ▶ Tuning: complex/understandable
- ▶ Interestingness (common sense)
- ▶ Scalability/integration DBMS / sampling / abstractions
- ▶ Interaction / Visualisation