

Agents qui apprennent à partir d'exemples

<http://www.grappa.univ-lille3.fr/grappa/index.php3?info=apprentissage>

- Introduction
- La problématique
- Méthodes symboliques
 - Arbres de décision
- Méthodes non symboliques ou adaptatives
 - Réseaux de neurones

1

Définitions

- Π : la population
- D : l'ensemble des descriptions
- $Cl = \{1, \dots, c\}$ l'ensemble des classes
- $X : \Pi \rightarrow D$: fonction qui associe une description à chaque élément de la population
- $Y : \Pi \rightarrow \{1, \dots, c\}$: fonction de classement qui associe une classe à tout élément de la population.
- Une fonction $C : D \rightarrow Cl$ est appelée **fonction de classement** ou **procédure de classification**

Le but de l'apprentissage est de rechercher une procédure de classification $C : D \rightarrow Cl$ telle que $C \circ X = Y$ ou plutôt telle que $C \circ X$ soit une bonne approximation de Y .

3

Apprentissage à partir d'exemples

L'approche probabiliste. Exemple: Établir un diagnostic dans le domaine médical.

- Il faut être capable d'associer le nom d'une maladie à un certain nombre de symptômes présentés par des malades
- Les **malades** forment la population.
- Les **symptômes** sont les descriptions des malades.
- Les **maladies** sont les classes.
- On suppose qu'il y a un **classement correct**, c.-à-d. une application qui associe à tout malade une maladie.
- **Apprendre** à établir un diagnostic: Associer une maladie à une liste de symptômes de sorte que cette association corresponde au classement correct défini ci-dessus.

2

Définition

- A_1, \dots, A_n : Ensembles d'attributs logiques, symboliques ou numériques qui sont de domaines D_1, \dots, D_n .
- $D = D_1 \times D_2 \dots \times D_n$.
- Exemples:
 - Patient est décrit par:
 - * Ensemble de symptômes
 - * Suite de mesures: Température, etc.
 - Un client est décrit par l'ensemble des données: âge, sexe, etc.
- Comment exprimer le fait que $C \circ X$ est une bonne approximation de Y ?

4

Bonne approximation

- $C \circ X$ est une bonne approximation de Y si $C \circ X$ est rarement différente de Y
- On suppose l'existence d'une distribution de probabilités sur Π et on dit que $C \circ X$ est rarement différent de Y , si il est peu probable qu'ils diffèrent.
- Soient Π probabilisé, P la probabilité définie sur Π et D discret. Définitions:
 - $P(d) = P(X^{-1}(d))$: probabilité qu'un élément de Π ait d pour description.
 - $P(k) = P(Y^{-1}(k))$: probabilité qu'un élément de Π soit de classe k .
 - $P(d/k) = P(X^{-1}(d)/Y^{-1}(k))$: probabilité qu'un élément de classe k ait d pour description.
 - $P(k/d) = P(Y^{-1}(k)/X^{-1}(d))$: probabilité qu'un élément ayant d pour description soit de classe k .
 - Formule de Bayes:
$$P(k/d) = \frac{P(d/k)P(k)}{P(d)}$$

On connaît $P(d)$, $P(k)$ et $P(d/k)$ pour tout $d \in D$ et $k \in \{1, \dots, c\}$.

Comment choisir C ?

5

$C_{vraisemblance}$

- Attribuer à une description d la classe pour laquelle cette observation est la plus probable si on observe d
- Pour l'exemple: *riche* pour propriétaire de répondeur, \overline{riche} pour les autres.
- Problème:
 - Supposons $Cl = \{employe\ Telecoms, medecins, ouvriers\}$ et $P(repondeur/employe\ Telecoms) = 1$.
 - $C_{vraisemblance}$ donne pour propriétaire d'un répondeur toujours *employe Telecoms*.

7

Exemple

- Π : la population française
- Un attribut logique: **répondeur**
- L'espace de description: $\{repondeur, \overline{repondeur}\}$
- Deux classes: $\{riche, \overline{riche}\}$
- Informations:

classe k	<i>riche</i>	\overline{riche}
$P(k)$	0.4	0.6
$P(repondeur/k)$	0.8	0.45

- C_{maj} : Attribuer à chaque description la classe majoritaire (ici: \overline{riche})

6

C_{Bayes}

- Attribuer à une description d la classe k qui maximise la probabilité $P(k/d)$ qu'un élément ayant d pour description soit de classe k .
- $P(k/d)$ peut être estimée en utilisant la formule de Bayes
- On choisit la classe k qui maximise le produit $P(d/k)P(k)$.
- Exemple:
 - $P(repondeur/riche)P(riche) = 0.8 \times 0.4 = 0.32$
 - $P(repondeur/riche)P(riche) = 0.2 \times 0.4 = 0.08$
 - $P(repondeur/\overline{riche})P(\overline{riche}) = 0.45 \times 0.6 = 0.27$
 - $P(repondeur/\overline{riche})P(\overline{riche}) = 0.55 \times 0.6 = 0.33$
- Ici: $C_{vraisemblance} = C_{Bayes}$
- Cas spécial: classes équiprobables
 \Rightarrow toujours $C_{vraisemblance} = C_{Bayes}$

8

Comparaison

- On définit l'**erreur** $E(d)$ comme la probabilité qu'un élément de Π de description d soit mal classé par C

- $E(d) = P(Y \neq C/X = d)$

- L'**erreur de classification**

$$E(C) = \sum_{d \in D} E(d)P(X = d)$$

- Pour l'exemple:

- $E(C_{maj}) = 0.4$

- $E(C_{vraisemblance}) = E(rep)P(rep) + E(\overline{rep})P(\overline{rep}) = P(\overline{riche}/rep)P(rep) + P(riche/\overline{rep})P(\overline{rep}) = P(rep/riche)P(riche) + P(\overline{rep}/riche)P(riche) = 0.27 + 0.08 = 0.35$

- **Théorème:** La règle de décision de Bayes est celle dont l'erreur de classification est minimale

9

Classification supervisée

- Apprentissage supervisé/non supervisé
- Choix du langage de description - définir les attributs susceptibles pertinents
- Langage de description $D = D_1 \times D_2 \times \dots \times D_n$ fixé. \vec{x}, \vec{y} sont des éléments de D , les classes $\{1, \dots, c\}$ fixées
- On suppose une loi de probabilité P sur D fixée mais inconnue.
- On suppose une loi de probabilité conditionnelle $P(./.)$ fixée mais inconnue.
- Échantillon S de m exemples $(\vec{x}, c(\vec{x}))$ tirés selon $P(./.)$ définie par $P(\vec{x}, y) = P(\vec{x})P(y/\vec{x})$.
- Problème de **classification supervisée**: Inférer une fonction de classement dont l'erreur de classification est petite.
- Parfois il faut pondérer les erreurs.

11

Remarques

- Si une fonction de classement est correcte, alors $E(C_{Bayes}) = 0$
- Une fonction de classement correcte existe, ssi la probabilité que des individus appartenant à des classes différents aient des descriptions identiques est nulle.
- Dans ce cas, le problème est dit **déterministe**.
- Très rare en pratique:
 - Généralement les paramètres descriptifs dont on dispose ne sont pas suffisants pour classifier correctement tout.
 - Les données sont généralement inexactes.
- Il faut connaître les probabilités (difficiles à estimer).

10

Bien classer et bien prédire

- Exemple d'une procédure de classification:
 - On mémorise tous les exemples de l'échantillon d'apprentissage dans une table.
 - Lorsqu'une nouvelle description est présentée au système, on recherche dans la table.
 - Si on trouve la description, on sort le résultat correspondant
 - Sinon, on choisit une classe au hasard.
- Cette procédure ne fait pas d'erreur sur les exemples.
- Mais son **pouvoir prédictif** est faible.
- Objectif: Une procédure de classification devrait dépasser au moins le pouvoir prédictif de la procédure **majoritaire**.

12

Erreur réelle et apparente

- L'erreur réelle est l'erreur de classification $E(C)$
- L'erreur apparente est définie par:
 - S un échantillon de taille m
 - C une procédure de classification
 - taux d'erreur apparent sur S est $E_{app}(C) = \frac{err}{m}$ où err est le nombre d'exemples de S mal classés par C .
- Il faut minimiser $E(C)$ mais l'apprenant ne connaît que $E_{app}(C)$ sur S .
- $E_{app}(C)$ tend vers $E(C)$ pour des échantillons de plus en plus grands.

13

Le classifieur naïf de Bayes

- $C_{Bayes}(d) = \underset{k \in \{1, \dots, c\}}{\operatorname{argmax}} P(k/d) = \underset{k \in \{1, \dots, c\}}{\operatorname{argmax}} P(d/k)P(k)$
- $P(d/k)$ et $P(k)$ sont inconnues: $C_{Bayes}(\vec{d}) = \underset{k \in \{1, \dots, c\}}{\operatorname{argmax}} P((d_1, \dots, d_n)/k)P(k)$
- Pour remplacer $P((d_1, \dots, d_n)/k)$ et $P(k)$ par des estimations faites sur l'échantillon S on estime $P(k)$ par $\hat{P}(k)$, la proportion d'éléments de classe k dans S .
- L'estimation de $P((d_1, \dots, d_n)/k)$ est difficile. On fait l'hypothèse simplificatrice: les valeurs des attributs sont indépendantes connaissant la classe: $P((d_1, \dots, d_n)/k) = \prod_{i \in \{1, \dots, n\}} P(d_i/k)$
- On estime $P(d_i/k)$ par $\hat{P}(d_i/k)$ (proportion d'éléments de k ayant valeur d_i pour l'attribut i) $C_{NaiveBayes}(d) = \underset{k \in \{1, \dots, c\}}{\operatorname{argmax}} \prod_{i \in \{1, \dots, n\}} \hat{P}(d_i/k) \times \hat{P}(k)$
- Facile à mettre en oeuvre, fourni un seuil de performance pour les autres méthodes

15

Les méthodes de classification supervisée

- Problème difficile:
 - On ne connaît pas les lois de probabilité
 - L'espace de recherche (fonction de classement) est énorme
 - L'échantillon est petit
- Le classifieur naïf de Bayes
- Méthodes paramétriques et non paramétriques
- Minimiser l'erreur apparente
- Choix de l'espace des hypothèses
- Estimer l'erreur réelle
 - Utilisation d'un ensemble Test
 - Re-échantillonnage

14

Méthodes paramétriques et non paramétriques

- Méthodes paramétriques
 - On suppose que la loi de probabilité fait partie d'une famille paramétrée de distributions
 - On essaie d'estimer les paramètres (par exemple: la moyenne et l'écart-type pour la distribution normale)
- Méthodes non paramétriques
 - On fait aucune hypothèse
- étudiées en Statistique

16

Minimiser l'erreur apparente

- L'erreur apparente est une version très optimiste de l'erreur réelle
- Il y a beaucoup de fonctions de D dans $\{1, \dots, c\}$. C'est impossible de toutes les explorer.
- On peut limiter la recherche d'une fonction à un espace d'hypothèses \mathcal{C}
- Éviter des hypothèses trop spécialisées, exemples:
 - Si l'espace d'hypothèses n'est pas restreint, on pourrait toujours choisir la procédure de classification donné comme exemple avec erreur apparente nulle.
 - Recherche d'une fonction polynôme dont la courbe représentative passe par n points.
 - Programme qui traduit un texte de 2000000 pages de l'anglais vers le français et comporte 4000000 pages de code.

17

Choix d'un espace d'hypothèse

- Souvent on a des suites d'ensembles de procédures de classification $\mathcal{C}_1 \subseteq \mathcal{C}_2 \subseteq \dots \mathcal{C}_k \subseteq \dots$ où k est une mesure de complexité du système d'apprentissage liée à la capacité.
- On essaie de trouver k de sorte que $C_{k,emp}$ ait le plus faible erreur réelle possible.
- On peut minimiser l'erreur apparente en complexifiant de plus en plus l'espace de recherche.
- Exemple: Pour la recherche d'une fonction polynôme dont la courbe représentative passe par n points on choisit comme espace d'hypothèse les polynômes de degré k de plus en plus grand.

19

Minimiser l'erreur apparente

- On prend un espace d'hypothèses \mathcal{C} . Soit C_{opt} la procédure optimale de \mathcal{C} .
- Problème difficile: approcher C_{opt}
- On peut choisir C_{emp} qui minimise l'erreur apparente
- Mais on ne peut pas à la fois sélectionner un classifieur à l'aide d'un ensemble d'apprentissage et juger sa qualité avec le même ensemble.
- On utilise un ensemble test

18

Estimer l'erreur réelle

- Utilisation d'un ensemble Test
 - On partitionne l'échantillon en un ensemble d'apprentissage S et un ensemble test T
 - La répartition est faite aléatoirement.
 - On génère une procédure de classification C en utilisant S .
 - On estime avec $\hat{E}(C)$ l'erreur réelle $E(C)$. $\hat{E}(C)$ est donné par l'erreur apparente de C mesurée sur l'ensemble test T

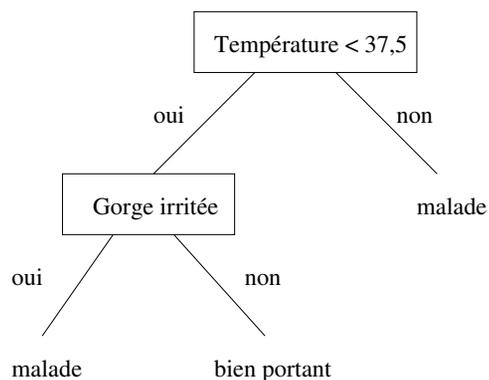
$$\hat{E}(C) = \frac{\#malclasses(T)}{\#T}$$

- Techniques de re-échantillonnage
 - On divise l'échantillon en k parties. On fait k sessions d'apprentissage en utilisant $k - 1$ parties pour apprendre et une partie pour tester.

20

Les arbres de décision

- Apprentissage symbolique
- On cherche une procédures de classification compréhensible
- Exemple:



21

Les arbres de décision

- À chaque arbre, on associe naturellement une procédure de classification.
- À chaque description est associée une seule feuille de l'arbre.
- La procédure de classification représenté par un arbre correspond à des règles de décision.
- Exemple:
 - SI Température < 37,5 ET gorge irritée ALORS malade
 - SI Température < 37,5 ET gorge non irritée ALORS malade
 - SI Température \geq 37,5 ALORS malade

23

Les arbres de décision

- Un **arbre de décision** est un arbre au sens informatique
- Les noeuds sont repérés par des positions $\in \{1, \dots, p\}^*$, où p est l'arité maximale des noeuds.
- Les noeuds internes sont les **noeuds de décision**.
- Un noeud de décision est étiqueté par un **test** qui peut être appliqué à chaque description d'un individu d'une population.
- Chaque test examine la valeur d'un unique attribut.
- Dans les arbres de décision binaires on omet les labels des arcs.
- Les feuilles sont étiquetées par une classe.

22

Construire des arbres de décision

- Étant donné un échantillon, on veut construire un arbre
- échantillon S , classes $\{1, \dots, c\}$, arbre t
- À chaque position p de t correspond un sous-ensemble de S qui contient les éléments de S qui satisfont les tests de la racine jusqu'à p .
- On définit pour chaque p :
 - $N(p)$ = le cardinal de l'ensemble des exemples associé à p
 - $N(k/p)$ = le cardinal de l'ensemble des exemples associé à p de classe k
 - $P(k/p) = N(k/p)/N(p)$ = la proportion d'éléments de classe k à la position p

24

Exemple

- L'arbre de décision de l'exemple.
- On dispose d'un échantillon de 200 patients.
- 100 sont malades et 100 bien portants.
- Répartition (M malades, S bien portants):

	gorge irrité	gorge non irrité
température < 37,5	(6 S, 37 M)	(91 S, 1 M)
température ≥ 37,5	(2 S, 21 M)	(1 S, 41 M)

- On a:
 - $N(11) = 43$, (11 est la position de l'arbre qui correspond à la feuille plus à gauche)
 - $N(S/11) = 6$, $N(M/11) = 37$, $P(S/11) = \frac{6}{43}$, $P(M/11) = \frac{37}{43}$

25

Exemple (suite)

- On construit l'arbre d'une façon descendante
- On choisit un test, on divise l'ensemble d'apprentissage S et on réapplique récursivement l'algorithme.
- On initialise avec l'arbre vide.
- Des 8 éléments de S , 3 sont de classe oui et 5 de classe non.
- S est caractérisé par (3, 5).
- Si le noeud n'est pas déjà **terminal** on choisit un test.
- Ici il y a 4 choix (M,A,R,E)

27

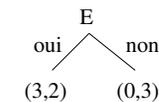
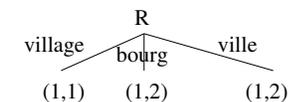
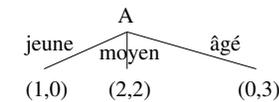
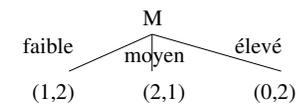
Exemple: Banque

client	M	A	R	E	I
1	moyen	moyen	village	oui	oui
2	élevé	moyen	bourg	non	non
3	faible	âgé	bourg	non	non
4	faible	moyen	bourg	oui	oui
5	moyen	jeune	ville	oui	oui
6	élevé	âgé	ville	oui	non
7	moyen	âgé	ville	oui	non
8	faible	moyen	village	non	non

- M: La moyenne des montants sur le compte
- A: Tranche d'âge du client
- R: Localité de résidence du client
- E: Études supérieures
- I: Consultation du compte par Internet
- On veut construire un arbre de décision pour savoir si un client consulte son compte par Internet.

26

Les 4 choix



Quel test choisir ?

28

Mesurer le degré de mélange des exemples

- Un test est **intéressant** s'il permet une bonne discrimination.
- Une fonction qui mesure le degré de mélange des exemples doit
 - prendre son maximum lorsque les exemples sont équirépartis (ici par exemple (4,4)).
 - prendre son minimum lorsque les exemples sont dans une même classe ((0,8) ou (8,0)).
- Il existe plusieurs fonctions comme cela

• Entropie:

$$Entropie(p) = - \sum_{k=1}^c P(k/p) \times \log_2(P(k/p))$$

• Gini:

$$\begin{aligned} Gini(p) &= 1 - \sum_{k=1}^c P(k/p)^2 \\ &= 2 \sum_{k < k'} P(k/p)P(k'/p) \end{aligned}$$

29

Choisir un test

- Soit f la fonction choisie (Gini ou Entropie par exemple)
- On définit le gain pour un Test choisi.
- n est l'arité du test et P_j la proportion d'éléments de S à la position p qui vont en position p_j (qui satisfont la j -ème branche du Test)

$$Gain(p, T) = f(p) - \sum_{j=1}^n (P_j \times f(p_j))$$

31

Exemple pour attribut E

- $Entropie(\epsilon) = -\frac{3}{8}\log_2\frac{3}{8} - \frac{5}{8}\log_2\frac{5}{8} \simeq 0,954$
- $Entropie(1) = -\frac{3}{5}\log_2\frac{3}{5} - \frac{2}{5}\log_2\frac{2}{5} \simeq 0,970$
- $Entropie(2) = -\frac{0}{3}\log_2\frac{0}{3} - \frac{3}{3}\log_2\frac{3}{3} = 0$
(Attention: On considère $0 \times \log_2(0) = 0$)
- $Gini(\epsilon) = 2 \times \frac{3}{8} \times \frac{5}{8} \simeq 0,469$
- $Gini(1) = 2 \times \frac{3}{5} \times \frac{2}{5} = 0,480$
- $Gini(2) = 2 \times \frac{0}{3} \times \frac{3}{3} = 0$

30

Exemple

- $Gain(\epsilon, M) = Entropie(\epsilon) - (\frac{3}{8}Entropie(1) + \frac{3}{8}Entropie(2) + \frac{2}{8}Entropie(3)) = Entropie(\epsilon) - 0,620$
- $Gain(\epsilon, A) = Entropie(\epsilon) - (\frac{1}{8}Entropie(1) + \frac{4}{8}Entropie(2) + \frac{3}{8}Entropie(3)) = Entropie(\epsilon) - 0,500$
- $Gain(\epsilon, R) = Entropie(\epsilon) - (\frac{2}{8}Entropie(1) + \frac{3}{8}Entropie(2) + \frac{3}{8}Entropie(3)) = Entropie(\epsilon) - 0,870$
- $Gain(\epsilon, E) = Entropie(\epsilon) - (\frac{5}{8}Entropie(1) + \frac{3}{8}Entropie(2)) = Entropie(\epsilon) - 0,607$
- Gain maximal pour A.

32

Généralités

- Idée: Diviser récursivement et le plus efficacement possible les exemples de l'ensemble d'apprentissage par des tests définis à l'aide d'attributs, jusqu'à ce qu'on obtienne des sous-ensembles ne contenant (presque) que des exemples appartenant à une même classe.
- On a besoin des trois opérations suivantes:
 - Décider si un noeud est terminal.
 - Sélectionner un test à associer à un noeud.
 - Affecter une classe à une feuille

33

Généralités

- Arbre de décision **parfait**.
- Il n'existe pas toujours.
- Le **meilleur** arbre est l'arbre parfait le plus petit.
- L'algorithme précédent ne remet jamais en cause un choix effectué.
- L'erreur réelle peut être importante.
- En pratique, on construit l'arbre et ensuite on **élague**.

35

Algorithme générique

entrée: langage de description, échantillon S

Début

```
Initialiser à l'arbre vide,
  la racine est le noeud courant
```

```
répéter
```

```
  Décider si le noeud courant est terminal
```

```
  Si le noeud est terminal alors
```

```
    Affecter une classe
```

```
  sinon
```

```
    Sélectionner test et créer sous-arbre
```

```
    Passer au noeud suivant non-exploré
```

```
  jusqu'à obtenir un arbre de décision
```

Fin

34

L'algorithme CART

- génère un arbre de décision binaire
- Langage de représentation: attributs binaires, qualitatifs, continus
- Attribut binaire: test binaire
- Attribut qualitatif: tout test qui partitionne en deux classes
- Attribut continu: infinité de tests possibles
- On suppose prédéfini un ensemble de tests binaires.
- Échantillon S , ensemble test T .

36

La phase d'expansion

- entrée: ensemble d'apprentissage A
- On utilise la fonction $Gini$
- Décider si un noeud est terminal:
Un noeud p est terminal si $Gini(p) \leq i_0$ ou $N(p) \leq n_0$, où i_0 et n_0 sont des paramètres à fixer.
- Sélectionner un test à associer à un noeud:
Soit p une position et T un test. P_g (resp. P_d) est la proportion d'éléments qui vont sur le noeud $p1$ (resp. $p2$).

$$\Delta(p, T) = Gini(p) - (P_g \times Gini(p1) + P_d \times Gini(p2))$$

On choisit le test qui maximise $\Delta(p, T)$

- affecter une classe à une feuille:
On choisit la classe majoritaire.

37

L'algorithme C4.5

- Langage de représentation: comme CART mais des ensembles de tests n -aires.
- Décider si un noeud est terminal: p est terminal si tous les éléments associés à ce noeud sont dans une même classe où si on ne peut sélectionner aucun test.
- Sélectionner un test:
 - On envisage seulement les tests qui ont au moins deux branches contenant au moins deux éléments (ces paramètres peuvent être modifiés).
 - On choisit le test qui maximise le gain en utilisant la fonction entropie.
 - La fonction $Gain$ privilégie les attributs ayant un grand nombre de valeurs. On la modifie:

$$GainRatio(p, T) = \frac{Gain(p, T)}{Splitinfo(p, T)}$$
 avec $Splitinfo(p, T) = - \sum_{j=1}^n P'(j/p) \times \log_2(P'(j/p))$
 où n est l'arité et $P'(j/p)$ la proportion des éléments présents à p prenant la j -ème valeur du test T .

39

La phase d'élagage

- On construit une suite d'arbre et choisit celui minimisant l'erreur apparent sur T .
- La suite est donnée par $t_0 t_1 \dots t_k$ (avec t_0 l'arbre obtenu dans la phase d'expansion et t_k une feuille)
- On construit t_{i+1} à partir de t_i en utilisant A comme suit:
- On calcule $g(p) = \frac{\Delta_{app}(p)}{|u_p|-1}$ où u_p est le sous-arbre de t_i en position p et

$$\Delta_{app}(p) = \frac{MC(p) - MC(u_p)}{N(p)}$$

où $N(p)$ est le nombre d'exemples de A associés à p , $MC(p)$ le nombre d'exemples mal-classés à p si on élague t_i en position p et $MC(u_p)$ le nombre d'exemples associés à p mal classés par u_p . On choisit la position qui minimise $g(p)$.

- Choix final: On choisit l'arbre dans la suite qui minimise l'erreur apparente de T .

38

C4.5

- Affecter une classe à une feuille:
On attribue la classe majoritaire. S'il n'y a pas d'exemples on attribue la classe majoritaire du père.
- Phase d'élagage
- Améliorations:
 - Attributs discrets
 - Attributs continus
 - Valeurs manquantes

40