

## Objectifs du cours

Extraction de Connaissances à partir de Données  
 Fouille de Données  
 Apprentissage Artificiel  
 Classification - Clustering

Knowledge Discovery from Data  
 Data Mining  
 Machine Learning  
 Classification - Clustering

2018

Gérard Dray  
 gerard.dray@mines-ales.fr

Knowledge Discovery from Data (KDD)  
 Extraction de Connaissances à partir de Données (ECD)  
 Classification - Clustering

Data Mining (DM)  
 Fouille de Données (FD)  
 Classification - Clustering

Mythes et réalités  
 Domaines d'application  
 Méthodes - modèles - outils  
 Mise en œuvre

## Organisation du cours

Introduction

Bases du KDD et du DM


Bases de l'analyse des données  
 Analyse factorielle  
 Classification  
 Clustering  
 Logique floue

Réseaux de neurones artificiels

Conclusion

## Une histoire ancienne


- Jean-François Champollion 1821



« Au cours du règne du jeune qui a succédé à son père, Seigneur des diadèmes, très glorieux, qui a établi l'Égypte et a été pieux envers les dieux, triomphant sur ses ennemis et ramenant la paix et la vie civilisée aux hommes, Seigneur des Cérémonies des Trente années, semblable à Ptah le Grand, un roi comme Ra, grand roi des pays Supérieur et Inférieur, progéniture des Dieux Philopatores, approuvé par Ptah, à qui Ra a donné la victoire, l'image vivante d'Amun, fils de Ra, PTOLEMÉE, VIVRA A JAMAIS, BIEN-AIMÉ DE PTAH, dans la neuvième année, quand le fils Aetos d'Aetos était prêtre d'Alexandrie, et les Dieux Soteris, et les Dieux Adelphoi, et les Dieux Evergetoi, et les Dieux Philopatores et le Dieu Epiphane Eucharistos; fille Pyrrha de Philinos qui est Athiopharos de Berenike Euergetis, fille Arcia de Diogenes qui est Kanepharos d'Arinoe Philadelphos, fille Irene de Ptolémée qui est Prêtresse d'Arinoe Philopator; les quatrièmes du mois de Xandikos, d'après les Égyptiens les 18e Mekhir ... »

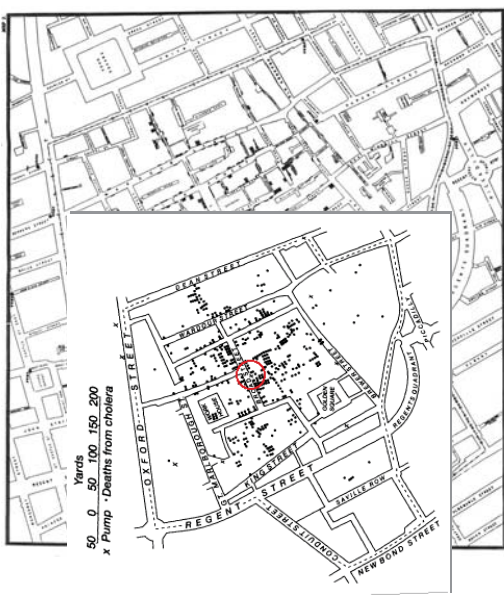
# Une histoire ancienne

- John Snow 1854



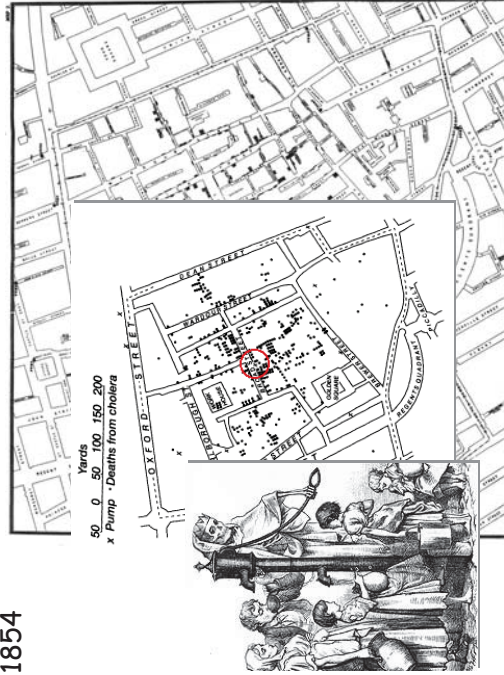
# Une histoire ancienne

- John Snow 1854



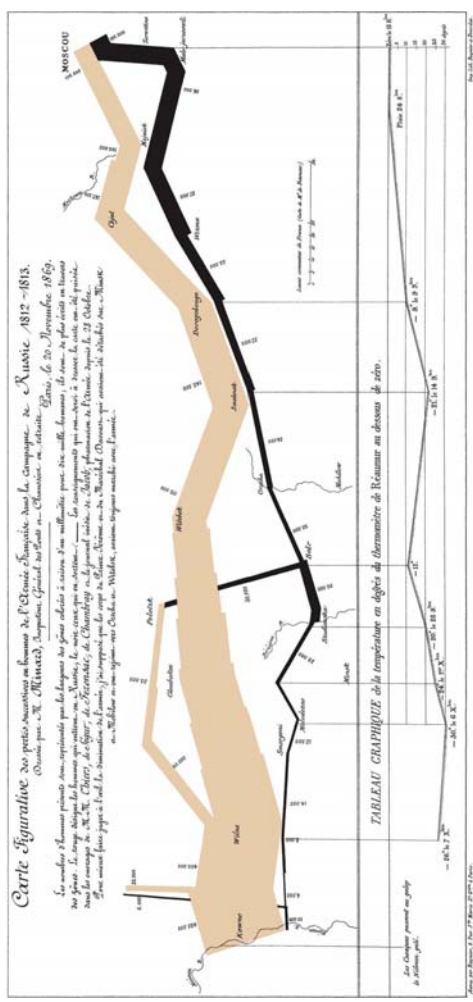
# Une histoire ancienne

- John Snow 1854



# Une histoire ancienne

- Charles Joseph Minard 1869



## Une histoire ancienne

« Instead of trying to produce a programme to simulate the adult mind, why not rather try to produce one which simulates the child's ? If this were then subjected to an appropriate course of education one would obtain the adult brain. »

Turing 1963




## Data Mining

- Définition

« The non-trivial process of identifying valid, novel, potentially usefull and ultimately understandable patterns in data »

Fayyad, Shapiro et Smyth 1996



## 1998 : Une légende urbaine ?



## 1998 : Une légende urbaine ?



# 1998 : Une légende urbaine ?




# 1998 : Une légende urbaine ?



## En 2015

Le phénomène Big data (Données Massives) est considéré comme l'un des grands défis informatiques de la décennie 2010-2020



Volume = Quantité : de terabytes à zettabytes  
 Vitesse = Traitement par lots ou en flux temps réel  
 Variété = Structurées, Semi-structurées et non-structurées  
 Vérocité = confiance en l'information

Le mouvement de l'open data considère les données publiques comme un bien commun



## En 2015

Internet des objets

Quantified Self



By 2016

4.9 million

patients worldwide will use remote health monitoring devices, such as cardiac monitors, that transmit data directly without use of a smartphone or computer hub

3 million

patients worldwide will use a remote monitoring device that uses a smartphone as a hub to transmit information

142 million

healthcare and medical app downloads (up from 33 million in 2012)

Sources:  
 1. Big Insight, 2012  
 2. Juniper Research, 2012



Caisse nationale de l'assurance maladie : plus d'un milliard de demandes de remboursement par an

## En 2015

## En 2015

Comme personne ne peut maîtriser tous les processus technologiques, la première étape d'un projet analytique sera de créer une équipe. « *Informaticiens et statisticiens ne parlent pas le même langage. Ils devront pourtant créer un modèle, tout mesurer, expérimenter, tester encore et toujours. Puis trouver de nouveaux modèles. Avec le risque de créer un modèle complexe que personne ne comprendra !* »


La complexité tient souvent dans l'étendue des volumes de données à traiter. C'est pourquoi, pour amortir les coûts, les acteurs de l'analytique doivent créer de l'automatisation. Un point de vue auquel adhère Josh Wills, qui se veut cependant prudent : « *Optimiser un modèle ne se traduit pas toujours par l'optimisation du business. Nous ne croyons que dans la production, mais il existe un gap entre le business model et machine model.* »

Source : <http://www.silicon.fr/josh-wills-deta-scientist-chez-cloudera-82387.html>

4/1/2013

## En 2015

Josh Wills, 'data scientist' chez Cloudera



Qu'est-ce qu'un data scientist ?

« *Je suis d'abord un 'nerd des maths' qui trouve que la visualisation c'est cool !* », nous a affirmé Josh Wills. Pour lui, un data scientist doit d'abord passer beaucoup de temps à nettoyer la donnée. « *Plus propre elle sera, plus efficace sera l'analytique. Nous devons penser à résoudre des problèmes et à basculer les données dans un environnement opérationnel. Je passe mon temps à essayer de multiples idées, à paralléliser tout ce que je fais, à trouver des solutions en 6 mois contre plusieurs années auparavant, et à réaliser des recherches reproductibles.* »

Source : <http://www.silicon.fr/josh-wills-deta-scientist-chez-cloudera-82387.html>

4/1/2013

## En 2015

Un métier en devenir

Selon l'étude McKinsey « *Global Institute Big Data Report* », de 140.000 à 190.000 postes de data scientist devraient être créés aux États-Unis, principalement dans la santé. « *Les outils sont là, mais les gens ne savent pas les utiliser, ni établir les passerelles pour cela. Toutes les universités dans le monde devraient avoir un cursus data scientist* ».

Quant aux difficultés qu'il rencontre dans l'exercice de son métier, Josh Wills les exprime sans ambages : « *Le volume est un problème, le rythme de changement l'est également. Tout le monde a des problèmes d'ETL. Et nous n'avons pas besoin de programmeurs Java...* », probablement un retour d'expérience malheureux... Et comment démarrer un projet ? « *La recherche est le premier 'use case' d'Hadoop, car toute information a un document.* »

Source : <http://www.silicon.fr/josh-wills-deta-scientist-chez-cloudera-82387.html>

4/1/2013

# En 2015

Un métier qui n'a pas de prix... pour le moment !

Notre dernière question portera sur le prix d'un data scientist sur le marché ? « *Le prix dépend de l'activité. Par exemple dans la pub c'est très cher, mais ce n'est pas défini* ». Et de nous rappeler qu'une rémunération peut être indexée à un résultat, comme par exemple à un chiffre d'affaires réalisé à la suite d'une analyse...

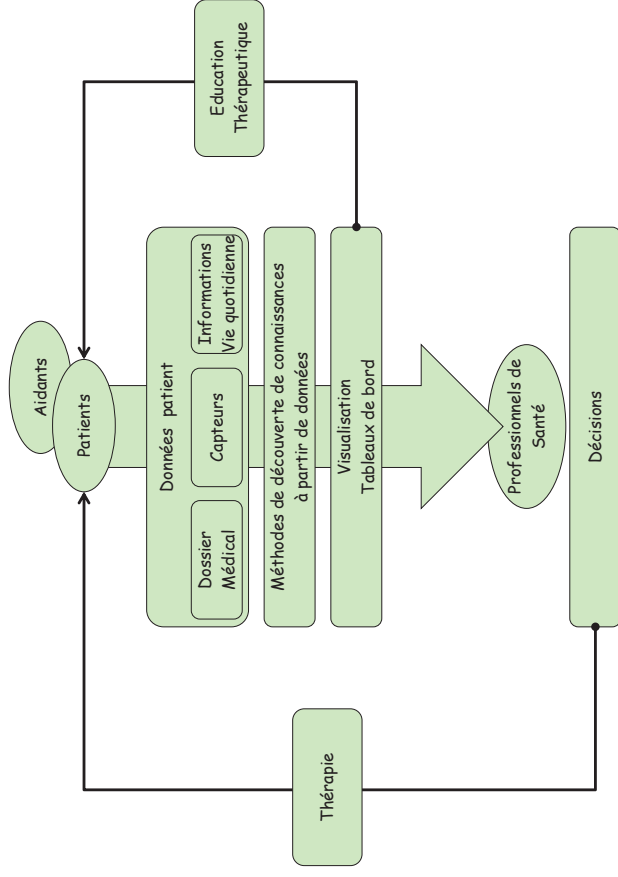
Ses yeux se mettent alors à briller. Les bons data scientists (et les data scientists eux-mêmes) sont une denrée rare, et pour quelques années encore avant que les cursus de formation ne crachent leurs diplômés, formés mais inexpérimentés.

Quant aux développeurs et autres consultants informatiques qui prétendent à l'expertise du statisticien pour exploiter les Big data, la concurrence ne sera pas rude avant longtemps. Ce n'est pas pour rien que Josh Wills nous quitte en conservant l'éclat brillant de ses yeux et son sourire entendu.

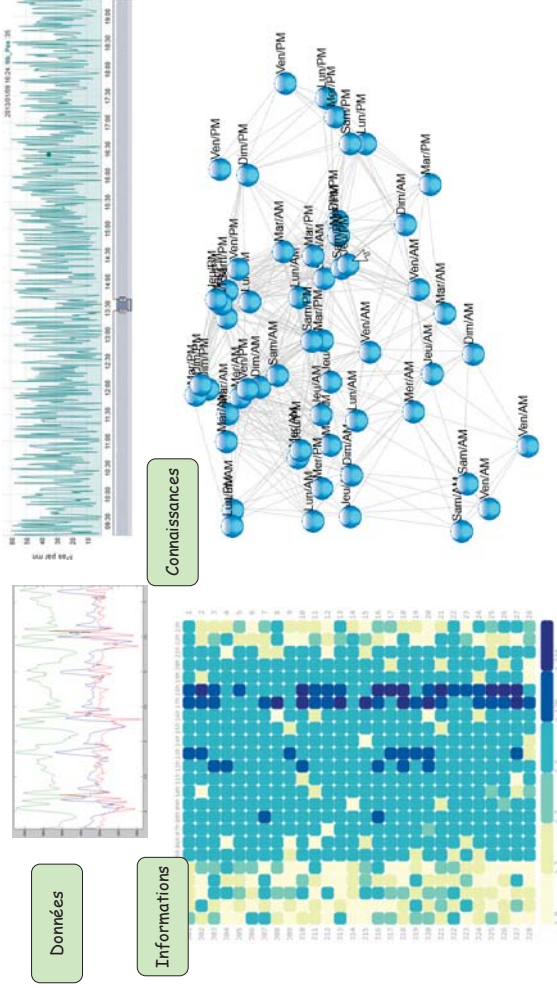
Il se murmure même chez Cloudera que le million de dollars en rémunération d'une mission de data scientist n'a rien d'extravagant au vu du service rendu. Les IT ont encore de quoi nous faire rêver...

Source : <http://www.silicon.fr/josh-wills-deta-scientist-chez-cloudera-82387.html>  
4/1/2013

# Découverte de connaissances à partir de données patient

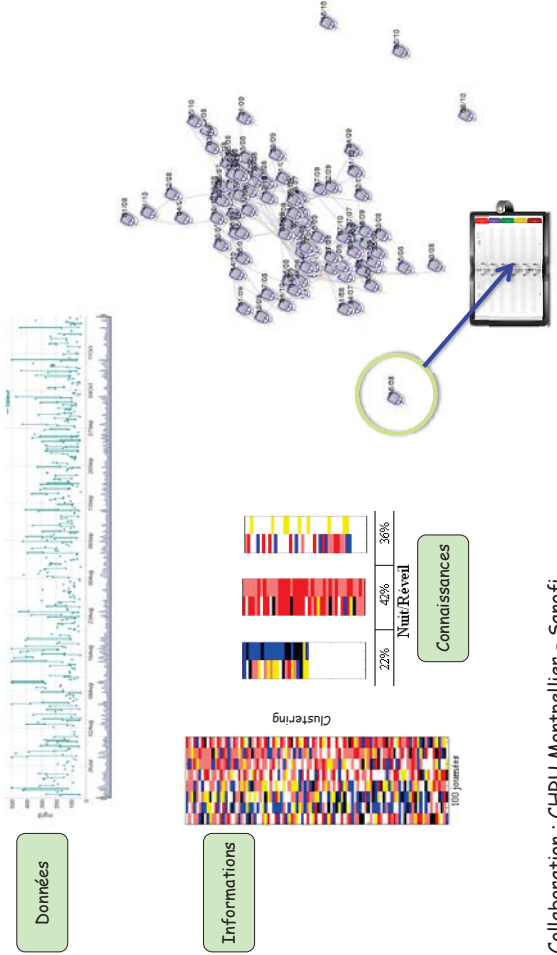


# Activité physique Suivi d'un patient



Collaboration : CHRU Montpellier – Association RAP – Industriels


# Diabète Suivi d'un patient



Collaboration : CHRU Montpellier - Sanofi

## KDD et DM - Pourquoi ?

- **Une avalanche de données**
  - Avancées technologiques pour acquérir et sauvegarder les données
  - Le volume des données sauvegardées double tous les 20 mois
  - L'homme va créer plus d'information dans les deux à trois ans à venir qu'au cours des 40000 dernières années
  - Seulement 10% des données collectées sont analysées



### Solutions :

- Centraliser les données : Datawarehouse - Datamart
- Extraire les connaissances intéressantes (KDD) par des méthodes et des techniques performantes (DM)

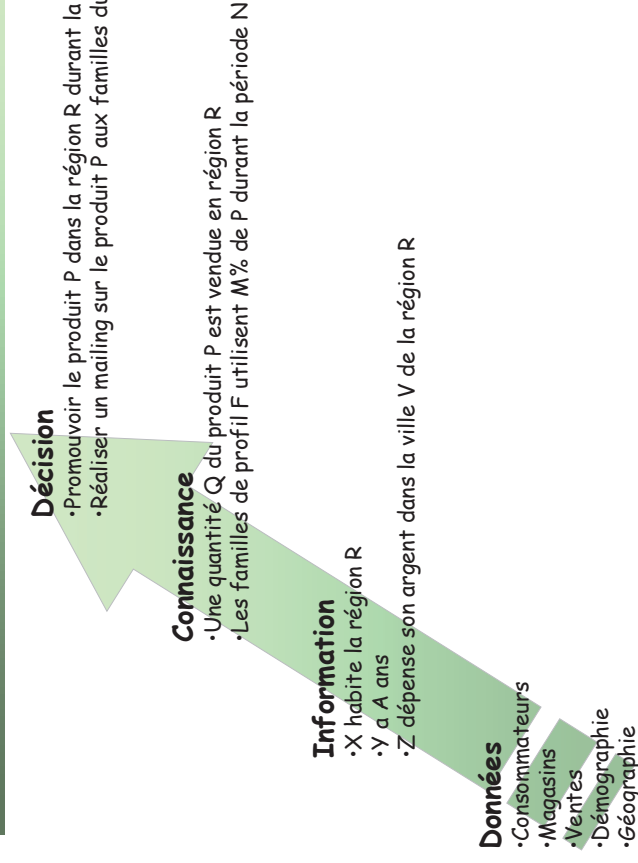
## KDD qu'est-ce que c'est ? un processus !

- **Sélection et traitement des données pour :**
  - La modélisation de phénomènes réels
  - La mise en évidence de caractéristiques essentielles
- **Le Data Mining est un composant majeur du processus de KDD**
  - Développement de modèles prévisionnels et explicatifs
  - Découverte automatique de caractéristiques

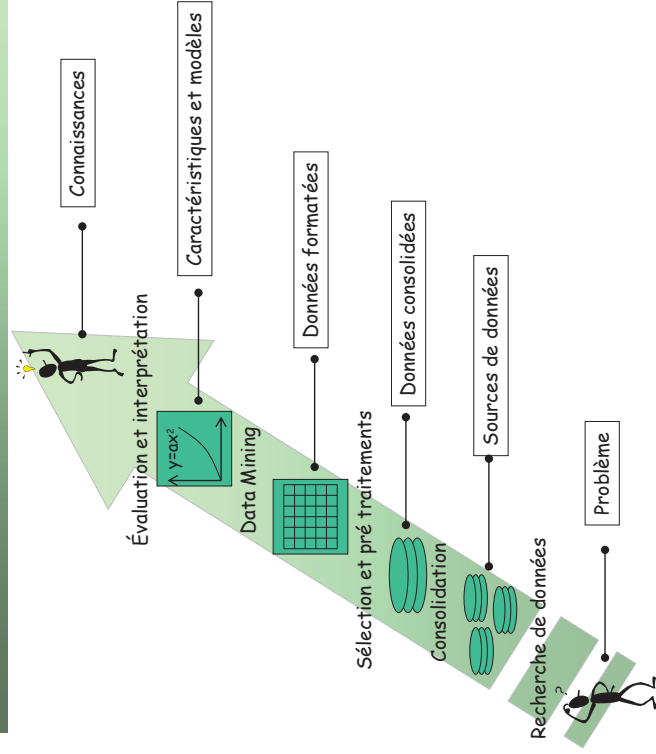
## Problèmes et approches du KDD

- **Problèmes**
  - Identification de données pertinentes
  - Représentativité des données
  - Recherche de caractéristiques et/ou modèles valides
- **Approches**
  - Top-down : déduction par experts
  - Interactive : visualisation des données (OLAP : On Line Analytical Processing)
  - Bottom-up : induction à partir des données (Data Mining)


## KDD - La démarche



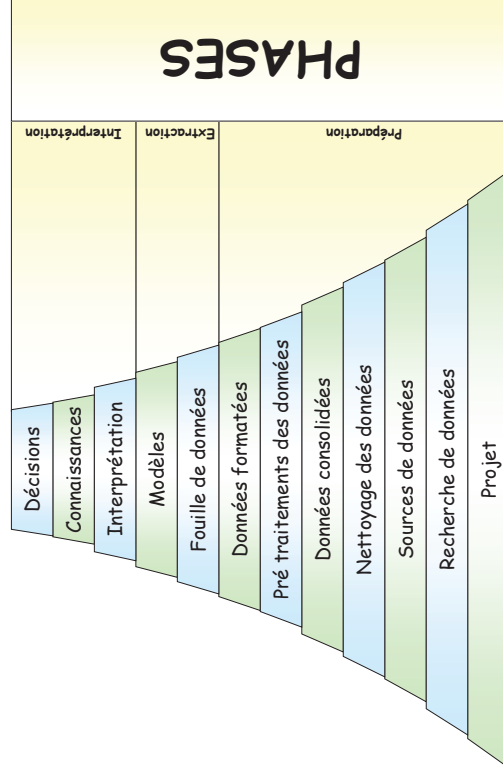
# KDD - Le processus



# KDD - Le processus

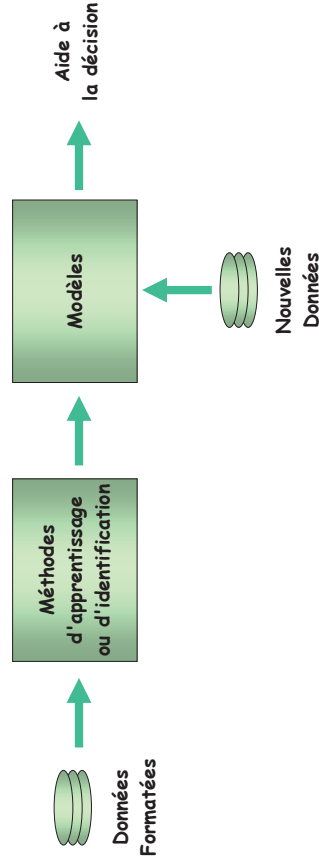


# KDD - Le processus



# Data Mining

- Processus d'induction à partir des données



## Nature des données

- Tableau (Individus x Caractères) de dimension  $(n \times p)$

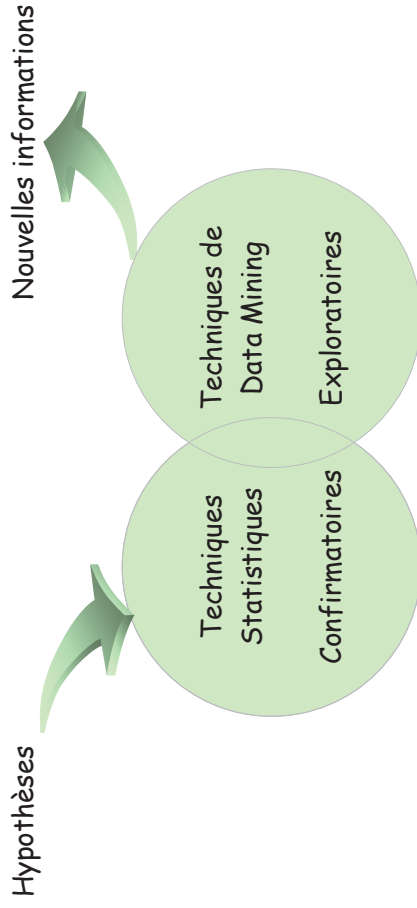
Individus	Caractères								
	Age	Revenu	Sexe		Situation Matrimoniale		Caractère j	...	Caractère p
			M	F	Marié	Célibataire			
$X_1$	$X_1^1$	$X_1^2$	$X_1^3$	$X_1^4$	$X_1^5$	$X_1^6$	$X_1^7$	...	$X_1^p$
$X_2$	$X_2^1$	$X_2^2$	$X_2^3$	$X_2^4$	$X_2^5$	$X_2^6$	$X_2^7$	...	$X_2^p$
...	...	...	...	...	...	...	...	...	...
$X_n$	$X_n^1$	$X_n^2$	$X_n^3$	$X_n^4$	$X_n^5$	$X_n^6$	$X_n^7$	...	$X_n^p$

Vecteur Individus  $X_i = [x_i^1, x_i^2, \dots, x_i^j, \dots, x_i^p]$

Vecteur Caractère  $X^j = [x_1^j, x_2^j, \dots, x_i^j, \dots, x_n^j]^T$

- Les caractères Age et Revenu sont quantitatifs
- Les caractères Sexe et Situation matrimoniale sont qualitatifs
- Modalité du caractère Situation matrimoniale : (Célibataire, Marié, Veuf ou divorcé)
- Les variables :  $X^3, X^4, X^5, X^6$  et  $X^7$  sont booléennes (1 = vrai, 0 = faux)

## Data Mining vs Statistiques




## Classification supervisée Classification non supervisée (clustering)

- Les objets possèdent un ou plusieurs caractères


### • Classification

- Quelques points sont labélisés
- Recherche de règles pour labéliser les autres points
- Apprentissage supervisé



### • Clustering

- Pas de points labélisés
- Groupier les points par similarité
- Apprentissage non supervisé



## KDD et DM - Domaines d'application

- **Science et médecine** : prévision, classification, diagnostic, ...
- **Marketing** : segmentation, ciblage, géomarketing, ...
- **Finance** : gestion des portefeuilles, prévision, ...
- **Banques** : acceptation de crédit, segmentation, ...
- **Sécurité** : détection de fraudes, d'impayés, ...
- **Industrie** : contrôle de qualité, allocation de ressources, ...
- **Ingénierie** : analyse de signaux, reconnaissance de motifs, ...
- **Internet** : moteurs de recherche intelligents, e-marketing, text mining, ...
- **Environnement** : prévision des pics de pollution, analyse des risques, ...

Introduction

Bases du KDD et du DM

Bases de l'analyse des données

Analyse factorielle

Classification

Clustering

Logique floue

Réseaux de neurones artificiels

Conclusion

- Étape 1 : Poser le problème
- Étape 2 : Rechercher les données
- Étape 3 : Sélectionner les données pertinentes
- Étape 4 : Nettoyer les données
- Étape 5 : Transformer les données
- Étape 6 : Rechercher les caractéristiques et les modèles
- Étape 7 : Évaluer et valider les résultats

## Les étapes du processus de KDD

### Étape 1 : Poser le problème

- Quel est la problématique ?
- Quels sont les objectifs ?
- Quels sont les résultats attendus ?
- Comment seront-ils évalués ?

## Les étapes du processus de KDD

### Étape 1: Poser le problème

Un exemple : Classification de fleurs d'iris

- Problème :  
Connaissant :
  - la longueur des sépales d'une fleur d'iris
  - la largeur des sépales d'une fleur d'iris
  - la longueur des pétales d'une fleur d'iris
  - la largeur des pétales d'une fleur d'iris

Est-il possible de classer les fleurs dans les catégories suivantes ?

- Iris Setosa - classe 1
- Iris Versicolour - classe 2
- Iris Virginica - classe 3



- L'objectif est de fournir un modèle de classification qui accepte en entrée les 4 caractéristiques des sépales et des pétales des fleurs d'iris et qui fournit en sortie le numéro de la classe de la fleur (1, 2 ou 3).

- Les résultats de la classification seront évalués sur une base de données de test représentant 25% des données collectées sous la forme d'une matrice de confusion.

## Les étapes du processus de KDD

### Étape 2 : Rechercher les données

- Identifier les informations
- Identifier les sources
- Vérifier leur qualité
- Vérifier leur facilité d'accès
  - Documents papier
  - Supports électroniques
  - Fichiers internes ou externes
  - Sources multiples, Data Warehouse ou Data Mart

## Les étapes du processus de KDD

### Étape 2 : Rechercher les données

Un exemple : Classification de fleurs d'iris




- Title: Iris Plants Database Updated Sept 21 2000 by C.Blake
- File : iris.dat
- Sources:
  - (a) Creator: R.A. Fisher
  - (b) Donor: Michael Marshall
  - (c) Date: July, 1988
- Number of Instances: 150 (50 in each of three classes)
- Number of Attributes: 4 numeric attributes and the class
- Attribute Information:
  1. sepal length in cm
  2. sepal width in cm
  3. petal length in cm
  4. petal width in cm
  5. class:
    - Iris Setosa
    - Iris Versicolour
    - Iris Virginica
- Missing Attribute Values: None

## Les étapes du processus de KDD

### Étape 3 : Sélectionner les données pertinentes

- Réduire les dimensions
  - Expertise humaine
  - Analyses graphiques
  - Analyses de corrélation
  - Analyse en composantes principales
  - ...



## Les étapes du processus de KDD

### Étape 3 : Sélectionner les données pertinentes

Un exemple : Classification de fleurs d'iris

Statistiques sur toutes les classes

Coefficient de corrélation	L sépale	I sépale	L pétale	I pétale	Classe
L sépale	1,00	-0,11	0,87	0,82	0,78
I sépale	-0,11	1,00	-0,42	-0,36	-0,42
L pétale	0,87	-0,42	1,00	0,96	0,95
I pétale	0,82	-0,36	0,96	1,00	0,96
Classe	0,78	-0,42	0,95	0,96	1,00
Minimum	4,30	2,00	1,00	0,10	1,00
Maximum	7,90	4,40	6,90	2,50	3,00
Moyenne	5,84	3,05	3,76	1,20	2,00
Ecart-type	0,83	0,43	1,76	0,76	0,82
Médiane	5,80	3,00	4,35	1,30	2,00
Interquartile	1,30	0,50	3,50	1,50	2,00

## Les étapes du processus de KDD

### Étape 3 : Sélectionner les données pertinentes

Un exemple : Classification de fleurs d'iris

Statistiques sur la classe 1

Coefficient de corrélation				
L sépale	I sépale	L pétale	I pétale	
L sépale	1,00	0,75	0,26	0,28
I sépale	0,75	1,00	0,18	0,28
L pétale	0,26	0,18	1,00	0,31
I pétale	0,28	0,28	0,31	1,00
Minimum	4,30	2,30	1,00	0,10
Maximum	5,80	4,40	1,90	0,60
Moyenne	5,01	3,42	1,46	0,24
Ecart-type	0,35	0,38	0,17	0,11
Médiane	5,00	3,40	1,50	0,20
Interquartile	0,40	0,60	0,20	0,10

## Les étapes du processus de KDD

### Étape 3 : Sélectionner les données pertinentes

Un exemple : Classification de fleurs d'iris

Statistiques sur la classe 3

Coefficient de corrélation				
L sépale	I sépale	L pétale	I pétale	
L sépale	1,00	0,46	0,86	0,28
I sépale	0,46	1,00	0,40	0,54
L pétale	0,86	0,40	1,00	0,32
I pétale	0,28	0,54	0,32	1,00
Minimum	4,90	2,20	4,50	1,40
Maximum	7,90	3,80	6,90	2,50
Moyenne	6,59	2,97	5,55	2,03
Ecart-type	0,64	0,32	0,55	0,27
Médiane	6,50	3,00	5,55	2,00
Interquartile	0,70	0,40	0,80	0,50

## Les étapes du processus de KDD

### Étape 3 : Sélectionner les données pertinentes

Un exemple : Classification de fleurs d'iris

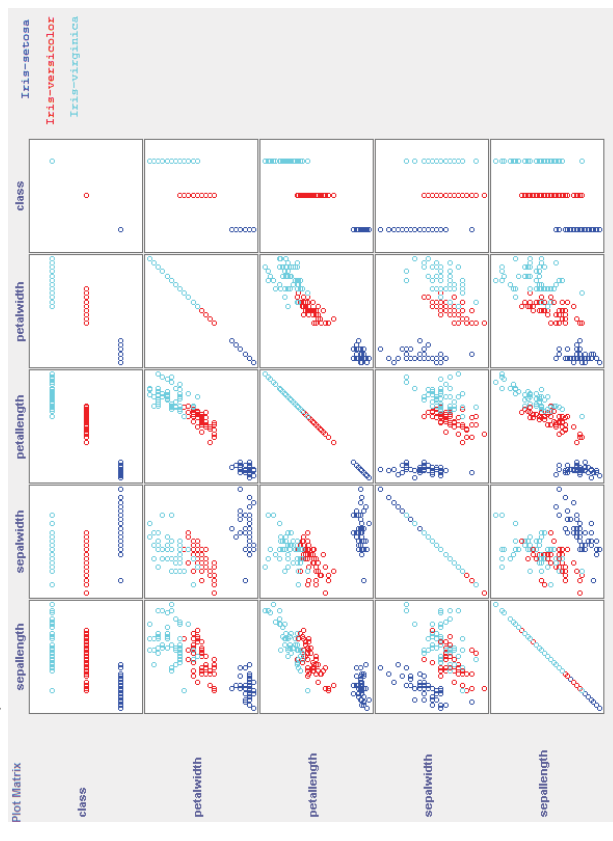
Statistiques sur la classe 2

Coefficient de corrélation				
L sépale	I sépale	L pétale	I pétale	
L sépale	1,00	0,53	0,75	0,55
I sépale	0,53	1,00	0,56	0,66
L pétale	0,75	0,56	1,00	0,79
I pétale	0,55	0,66	0,79	1,00
Minimum	4,90	2,00	3,00	1,00
Maximum	7,00	3,40	5,10	1,80
Moyenne	5,94	2,77	4,26	1,33
Ecart-type	0,52	0,31	0,47	0,20
Médiane	5,90	2,80	4,35	1,30
Interquartile	0,70	0,50	0,60	0,30

## Les étapes du processus de KDD


### Étape 3 : Sélectionner les données pertinentes

Un exemple : Classification de fleurs d'iris



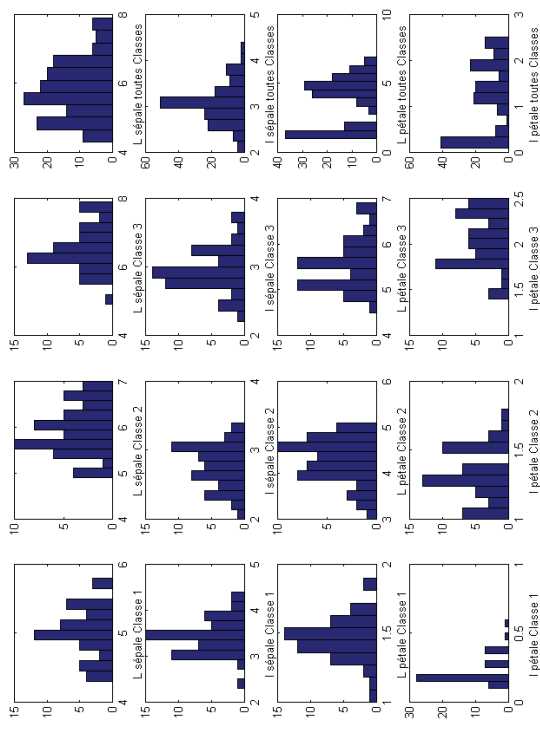
## Les étapes du processus de KDD Étape 3 : Sélectionner les données pertinentes

Un exemple : Classification de fleurs d'iris  
Médiane et quartiles



## Les étapes du processus de KDD Étape 3 : Sélectionner les données pertinentes

Un exemple : Classification de fleurs d'iris  
Histogrammes des caractéristiques



## Les étapes du processus de KDD Étape 3 : Sélectionner les données pertinentes


Un exemple : Classification de fleurs d'iris  
Analyse en composantes principales

### Coefficients

	CP1	CP2	CP3	CP4
L. sépale	0.5224	-0.3723	0.7210	-0.2620
I. sépale	-0.2634	-0.9256	-0.2420	0.1241
L. pétale	0.5813	-0.0211	-0.1409	0.8012
I. pétale	0.5656	-0.0654	-0.6338	-0.5235

### Valeurs propres et % d'inertie

CP1	2.9108	72.77%
CP2	0.9212	23.03%
CP3	0.1474	03.69%
CP4	0.0206	00.51%



## Les étapes du processus de KDD Étape 4 : Nettoyer les données

- Vérifier l'origine des données
- Traiter les valeurs aberrantes
- Traiter les valeurs manquantes
- Traiter les valeurs nulles
- Estimer la qualité des données

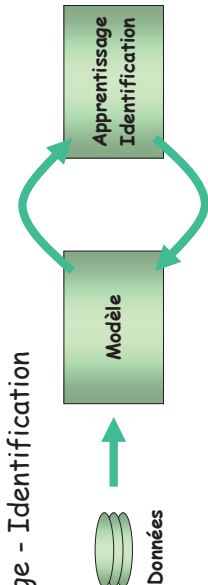
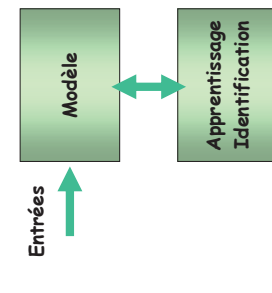
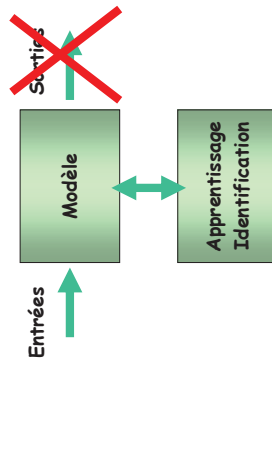
## Les étapes du processus de KDD

### Étape 5 : Transformer les données

- Cette étape peut consister à :
  - Coder les informations qualitatives
  - Coder en ratios (pourcentages)
  - Normaliser les données
  - Transformer les dates en durées
  - Transcoder les données,
    - exemple : code postal en coordonnées géographiques
  - Exprimer des fréquences
  - Exprimer des tendances
  - Réaliser des combinaisons de variables
  - ...

## Les étapes du processus de KDD

### Étape 6 : Rechercher les caractéristiques et les modèles

- Apprentissage - Identification
 
- Apprentissage Supervisé
 
- Apprentissage Non supervisé
 

## Les étapes du processus de KDD


### Étape 6 : Rechercher les caractéristiques et les modèles

- Choix d'une méthode ou d'une technique :
  - Réseaux de neurones
  - Régression
  - Règles
  - Arbres de décision
  - Analyses factorielles
  - Logique Floue
  - Algorithmes génétiques
  - Le raisonnement à base de cas
  - Les « Rough Sets »
  - Les réseaux Bayésiens
  - ...

## Les étapes du processus de KDD

### Étape 6 : Rechercher les caractéristiques et les modèles


Un exemple : Classification de fleurs d'iris  
Analyse en composantes principales



## Les étapes du processus de KDD

### Étape 6 : Rechercher les caractéristiques et les modèles


Un exemple : Classification de fleurs d'iris  
Groupement hiérarchique



## Les étapes du processus de KDD

### Étape 7 : Évaluer et valider les résultats

- Évaluation qualitative - exemple



## Les étapes du processus de KDD

### Étape 7 : Évaluer et valider les résultats


- Évaluation quantitative :

- Erreur quadratique moyenne (MSE : Mean Square Error)
- Erreur absolue moyenne (MAE : Mean Absolute Error)
- Racine carrée de l'erreur quadratique moyenne (RMSE : Root Mean Square error)
- Erreur relative absolue moyenne (MAPE : Mean Absolute Percentage Error)
- Coefficient de corrélation

## Les étapes du processus de KDD

### Étape 7 : Évaluer et valider les résultats


- Évaluation quantitative - exemple



## Les étapes du processus de KDD Étape 7 : Évaluer et valider les résultats

- Évaluation quantitative :
  - matrice de confusion
- exemple : Classification de fleurs d'iris

Classes réelles	Classes estimées		
	C1	C2	C3
C1	50	0	0
C2	0	40	10
C3	0	4	46



## Les étapes du processus de KDD Étape 7 : Évaluer et valider les résultats

- Évaluation quantitative :
  - matrice de confusion
- exemple : Classification de fleurs d'iris

Classes réelles	Classes estimées		
	C1	C2	C3
C1	49	1	0
C2	0	47	3
C3	0	2	48

Arbre de décision

```

petalwidth <= 0.6: Iris-setosa
petalwidth > 0.6
  |
  | petalwidth <= 1.7
  | | petalwidth <= 4.9: Iris-versicolor
  | | petalwidth > 4.9
  | | | petalwidth <= 1.5: Iris-virginica
  | | | petalwidth > 1.5: Iris-versicolor
  | | | petalwidth > 1.7: Iris-virginica
    
```

## Les étapes du processus de KDD Étape 7 : Évaluer et valider les résultats

- Évaluation quantitative :
  - Correctly Classified Instances et Incorrectly Classified Instances
- exemple : Classification de fleurs d'iris

Classes réelles	Classes estimées		
	C1	C2	C3
C1	49	1	0
C2	0	47	3
C3	0	2	48

Arbre de décision

Correctly Classified Instances: 144  
Incorrectly Classified Instances: 6

96%  
4%

## Les étapes du processus de KDD Étape 7 : Évaluer et valider les résultats

- Évaluation quantitative :
  - Kappa Statistic
- exemple : Classification de fleurs d'iris

Classes réelles	Classes estimées		
	C1	C2	C3
C1	49	1	0
C2	0	47	3
C3	0	2	48

Arbre de décision

Kappa statistic: 0.94

Mesure du degré de concordance de 2 juges (Classifieur et Expert)

$$K = \frac{P_0 - P_e}{1 - P_e}$$

$P_0$  : proportion de l'échantillon pour laquelle les juges sont d'accord

$P_i$  : somme des éléments de la ligne  $i$

$P_j$  : somme des éléments de la colonne  $j$

$n$  : taille de l'échantillon

Le coefficient Kappa est un nombre réel, sans dimension, compris entre -1 et 1. L'accord sera d'autant plus élevé que la valeur de Kappa est proche de 1 et l'accord maximal est atteint ( $K = 1$ ) lorsque  $P_0 = 1$  et  $P_e = 0$ .

Lorsqu'il y a **indépendance des jugements**, le coefficient Kappa est égal à **zéro** ( $P_0 = P_e$ ), et dans le cas d'un désaccord total entre les juges, le coefficient Kappa prend la valeur -1 avec  $P_0 = 0$  et  $P_e = 0.5$ .

$$P_0 = \frac{49 + 47 + 48}{150} = 0.96$$

$$P_e = \frac{50 \times 49 + 50 \times 50 + 50 \times 51}{150 \times 150} = \frac{1}{3}$$

$$K = \frac{0.96 - 1/3}{1 - 1/3} = 0.94$$

## Les étapes du processus de KDD Étape 7 : Évaluer et valider les résultats

- Évaluation quantitative :
- Calculs d'erreurs
- exemple : Classification de fleurs d'iris

Classes réelles		Classes estimées		
		C1	C2	C3
C1	49	1	0	0
C2	0	47	3	3
C3	0	2	48	48

Arbre de décision

Mean absolute error 0.035  
 Root mean squared error 0.1586  
 Relative absolute error 7.8705 %  
 Root relative squared error 33.6353 %

Soient  $p_1, p_2, \dots, p_n$  les probabilités calculées par le classifieur pour chaque exemple d'appartenance à sa vraie classe.  
 Soient  $a_1, a_2, \dots, a_n$  les probabilités à priori pour chaque exemple d'appartenance à la classe qui leur a été fixée par définition (en général, les  $a_i$  valent toujours 1, mais on peut imaginer qu'on soit un peu moins catégorique, et que la classe attribuée ne le soit qu'avec une certaine confiance),  
 soit  $\bar{a} = \frac{1}{n} \sum_i a_i$

Mean absolute error

$$\frac{|p_1 - a_1| + |p_2 - a_2| + \dots + |p_n - a_n|}{n}$$

Root mean-squared error

$$\sqrt{\frac{(p_1 - a_1)^2 + \dots + (p_n - a_n)^2}{n}}$$

Relative absolute error

$$\frac{|p_1 - a_1| + \dots + |p_n - a_n|}{|a_1 - \bar{a}| + \dots + |a_n - \bar{a}|}$$

Root relative squared error

$$\sqrt{\frac{(p_1 - a_1)^2 + \dots + (p_n - a_n)^2}{(a_1 - \bar{a})^2 + \dots + (a_n - \bar{a})^2}}$$

## Les étapes du processus de KDD Étape 7 : Évaluer et valider les résultats

- Évaluation quantitative :
- Notions de Vrais/Faux Positifs et Vrais/Faux Négatifs

Classes réelles		Classes estimées	
		C	$\bar{C}$
C	VP	FN	FN
$\bar{C}$	FP	FP	VN

VP : Vrais Positifs, VN : Vrais Négatifs,

FN : Faux Négatifs, FP : Faux Positifs

## Les étapes du processus de KDD Étape 7 : Évaluer et valider les résultats

- Évaluation quantitative :
- Précision, Rappel, F-Mesure
- exemple : Classification de fleurs d'iris

Classes réelles		Classes estimées		
		C	$\bar{C}$	
C	VP	FN	C1	$\bar{C1}$
$\bar{C}$	FP	VN	C2	$\bar{C2}$
			C3	$\bar{C3}$

Arbre de décision

TP Rate 0.98  
 FP Rate 0  
 Iris-setosa 0.94  
 Iris-versicolor 0.96  
 Iris-virginica 0.03

Recall 0.98  
 F-Measure 0.99  
 Iris-setosa 0.94  
 Iris-versicolor 0.96  
 Iris-virginica 0.95

Précision =  $VP / (VP + FP)$  Rappel =  $VP / (VP + FN)$  Taux VP  
 F-Mesure =  $2 \times \text{Précision} \times \text{Rappel} / (\text{Précision} + \text{Rappel})$

Classes réelles		Classes estimées		
		C	$\bar{C}$	
C	VP	FN	C1	$\bar{C1}$
$\bar{C}$	FP	VN	C2	$\bar{C2}$
			C3	$\bar{C3}$

Arbre de décision

TP Rate 0.98  
 FP Rate 0  
 Iris-setosa 0.94  
 Iris-versicolor 0.96  
 Iris-virginica 0.03

Précision =  $VP / (VP + FP)$  Rappel =  $VP / (VP + FN)$  Taux VP  
 F-Mesure =  $2 \times \text{Précision} \times \text{Rappel} / (\text{Précision} + \text{Rappel})$

## Les étapes du processus de KDD Étape 7 : Évaluer et valider les résultats

- Évaluation quantitative :
- Taux de VP et Taux de FP
- exemple : Classification de fleurs d'iris

Classes réelles		Classes estimées		
		C	$\bar{C}$	
C	VP	FN	C1	$\bar{C1}$
$\bar{C}$	FP	VN	C2	$\bar{C2}$
			C3	$\bar{C3}$

Taux de VP =  $VP / (VP + FN)$  Taux de FP =  $FP / (FP + VN)$

## Les étapes du processus de KDD Étape 7 : Évaluer et valider les résultats

- Évaluation quantitative :
- Taux de VP et Taux de FP
- exemple : Classification de fleurs d'iris

Classes réelles		Classes estimées		
		C	$\bar{C}$	
C	VP	FN	C1	$\bar{C1}$
$\bar{C}$	FP	VN	C2	$\bar{C2}$
			C3	$\bar{C3}$

Arbre de décision

TP Rate 0.98  
 FP Rate 0  
 Iris-setosa 0.94  
 Iris-versicolor 0.96  
 Iris-virginica 0.03

Taux de VP =  $VP / (VP + FN)$  Taux de FP =  $FP / (FP + VN)$

## Les étapes du processus de KDD Étape 7 : Évaluer et valider les résultats


Test outcome		Condition (as determined by "Gold standard")	
		Condition positive	Condition negative
Test outcome positive	True positive	True positive	Precision = $\frac{\Sigma \text{ True positive}}{\Sigma \text{ Test outcome positive}}$
Test outcome positive	False negative (Type II error)	False positive (Type I error)	Negative predictive value = $\frac{\Sigma \text{ True negative}}{\Sigma \text{ Test outcome negative}}$
Test outcome negative	False negative (Type II error)	True negative	Accuracy = $\frac{\Sigma \text{ True positive} + \Sigma \text{ True negative}}{\Sigma \text{ Total population}}$
Test outcome negative	Sensitivity = $\frac{\Sigma \text{ True positive}}{\Sigma \text{ Condition positive}}$	Specificity = $\frac{\Sigma \text{ True negative}}{\Sigma \text{ Condition negative}}$	

sensitivity =  $\frac{\text{number of true positives}}{\text{number of true positives} + \text{number of false negatives}}$

specificity =  $\frac{\text{number of true negatives}}{\text{number of true negatives} + \text{number of false positives}}$

## Les étapes du processus de KDD Étape 7 : Évaluer et valider les résultats

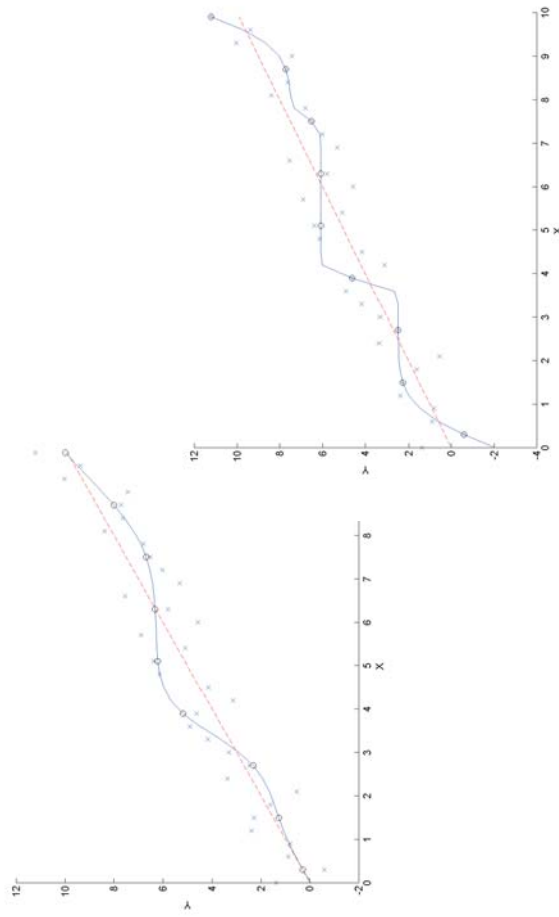
### Évaluation quantitative



ROC : Receiver Operating Characteristic

## Les étapes du processus de KDD Étape 7 : Évaluer et valider les résultats

### Sur apprentissage - Overfitting



ROC : Receiver Operating Characteristic

Model	Positive		Negative		Real
	TP	FN	FP	TN	

True Positive Rate =  $\frac{TP}{TP + FN}$

False Positive Rate =  $\frac{FP}{FP + TN}$

Area under ROC curve

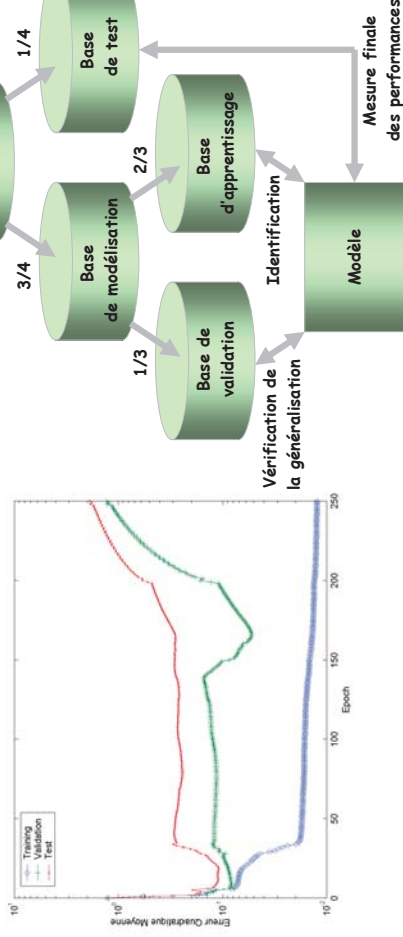
False Positive Rate

## Les étapes du processus de KDD

### Étape 7 : Évaluer et valider les résultats

73

- Évaluation par le test
  - Base de test 25% de la base totale
  - Base de validation 25% de la base totale
  - Base d'apprentissage 50% de la base totale



## Les étapes du processus de KDD


### Étape 7 : Évaluer et valider les résultats

Bases du KDD et du DM

74

- Validation croisée

Attention cette technique ne fournit pas de modèles mais permet d'évaluer les performances de la modélisation dans les cas où la base totale est petite



Pour tout  $i$  de 1 à  $k$

- Appliquer une méthode d'identification sur (Base totale - Si)
- Calculer la performance du modèle sur Si

Fin

Agréger les performances individuelles pour établir une mesure globale

*Si la taille des Si est de 1 individu on parle alors de « Leave one out »*

75

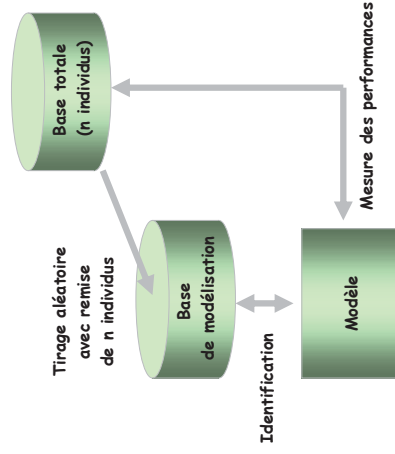
## Les étapes du processus de KDD

### Étape 7 : Évaluer et valider les résultats

76

- Bootstrap

Attention cette technique ne fournit pas de modèles mais permet d'évaluer les performances de la modélisation dans les cas où la base totale est petite



L'expérience est réalisée un grand nombre de fois et les performances sont agrégées pour fournir une évaluation globale

## Organisation du cours

Introduction  
Bases du KDD et du DM

Bases de l'analyse des données

Analyse factorielle  
Classification  
Clustering  
Logique floue  
Réseaux de neurones artificiels  
Conclusion

## Au programme

- Introduction
- Pré traitement des données
- Quelques mesures et graphiques de statistiques descriptives
- Éléments du traitement du signal : transformée et série de Fourier
- Modèle linéaire : régression linéaire

## L'espace des données

- Considérons l'espace de n points de dimension p suivant :

$X$	:	$X_1$	...	$X_j$	...	$X^p$
		$X_1^1$	...	$X_1^j$	...	$X_1^p$
		...	...	...	...	...
		$X_1^j$	...	$X_1^j$	...	$X_1^p$
		...	...	...	...	...
		$X_n^1$	...	$X_n^j$	...	$X_n^p$
		...	...	...	...	...
		$X_n^j$	...	$X_n^j$	...	$X_n^p$
		...	...	...	...	...


$$X_j = [x_1^j, x_2^j, \dots, x_i^j, \dots, x_n^j]^T$$

$$X^j = [x_1^j, x_2^j, \dots, x_i^j, \dots, x_n^j]^T$$


## Introduction

L'analyse des données contient deux grands groupes de méthodes

Analyse Factorielle



Classification/Régression



## Pré Traitement des données

- Données Centrées - Réduites

$$X^j = [x_1^j, x_2^j, \dots, x_i^j, \dots, x_n^j]^T$$

$$x_i^{j*} = \frac{x_i^j - \bar{X}^j}{s_{X^j}}$$

Fonctions Matlab : `prestd`, `poststd`

- Données Bornées [0,1]

$$x_i^{j*} = \frac{x_i^j - X_{\min}^j}{X_{\max}^j - X_{\min}^j}$$

- Données Bornées [a,b]

$$x_i^{j*} = \frac{x_i^j - \text{offset}}{\text{quotient}}$$

$$\text{quotient} = (X_{\max}^j - X_{\min}^j) / (b - a)$$

$$\text{offset} = X_{\max}^j - \text{quotient} \times b$$

Fonctions Matlab : `premmx`, `postmmx`

## Quelques mesures de statistiques descriptives

$$X^j = [x_1^j, x_2^j, \dots, x_i^j, \dots, x_n^j]^T$$

Mesures de bornage	Fonctions MATLAB
Maximum de $X^j = X_{\max}^j = \max\{x_1^j, x_2^j, \dots, x_i^j, \dots, x_n^j\}$	max
Minimum de $X^j = X_{\min}^j = \min\{x_1^j, x_2^j, \dots, x_i^j, \dots, x_n^j\}$	min

## Quelques mesures de statistiques descriptives

$$X^j = [x_1^j, x_2^j, \dots, x_i^j, \dots, x_n^j]^T$$

Mesures de tendance centrale	Fonctions MATLAB
Moyenne arithmétique = $\bar{X}^j = \frac{1}{n} \sum_{i=1}^n x_i^j$	mean
Moyenne géométrique = $\left[ \prod_{i=1}^n x_i^j \right]^{\frac{1}{n}}$	geomean
Moyenne harmonique = $\frac{n}{\sum_{i=1}^n \frac{1}{x_i^j}}$	harmmean
Médiane M : $F(M) = 0.5$	median

## Quelques mesures de statistiques descriptives


$$X^j = [x_1^j, x_2^j, \dots, x_i^j, \dots, x_n^j]^T$$

Mesures de dispersion	Fonctions MATLAB
Intervalle interquartile = $ Q_3 - Q_1 $ $F(Q_1) = 0.25, F(Q_2) = 0.50, F(Q_3) = 0.75$	iqr
Étendue ou intervalle de variation $w = X_{\max}^j - X_{\min}^j$	range
Variance : $s_j^2 = \frac{1}{n} \sum_{i=1}^n (x_i^j - \bar{X}^j)^2$	var
Écart-type : $s_j = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i^j - \bar{X}^j)^2}$	std

## Quelques mesures de statistiques descriptives

$$X^j = [x_1^j, x_2^j, \dots, x_i^j, \dots, x_n^j]^T \quad X^k = [x_1^k, x_2^k, \dots, x_i^k, \dots, x_n^k]^T$$

Mesures de liaison entre deux caractères quantitatifs	Fonctions MATLAB
Co variance : $s_{jk} = \frac{1}{n} \sum_{i=1}^n (x_i^j - \bar{X}^j)(x_i^k - \bar{X}^k)$	cov
Coefficient de corrélation : $r_{jk} = \frac{s_{jk}}{s_j s_k}$	corrcoef



## Quelques mesures de statistiques descriptives

### Mesures de liaison entre caractères quantitatifs

Matrice de variance

$$V = \begin{pmatrix} s_1^2 & s_{12} & \dots & s_{1p} \\ & s_2^2 & & \vdots \\ & & \ddots & \vdots \\ & & & s_p^2 \end{pmatrix}$$

Matrice de corrélation

$$R = \begin{pmatrix} 1 & r_{12} & \dots & r_{1p} \\ & 1 & & \vdots \\ & & \ddots & \vdots \\ & & & 1 \end{pmatrix} \quad D_{i/j} = \begin{pmatrix} 1/s_1 & 0 & \dots & 0 \\ 0 & 1/s_2 & 0 & 0 \\ \vdots & \vdots & \dots & \vdots \\ 0 & \dots & \dots & 1/s_p \end{pmatrix}$$

$$R = D_{i/j} V D_{i/j}$$

## Quelques mesures de statistiques descriptives

### Tableau de contingence entre caractères qualitatifs

Exemple :

Individus x Caractères

Individus	Caractères				
	Niveau hiérarchique X1		Sexe X2		
	Cadre Supérieur	Cadre Employé	M	F	
1	1	0	0	1	0
2	0	1	0	1	0
3	1	0	0	0	1
4	1	0	0	1	0
5	0	0	1	0	1
6	0	0	1	0	1
7	0	1	0	1	0
8	0	0	1	1	0

Tableau de contingence  $X1 \times X2$

Niveau hiérarchique X1	Sexe X2	
	M	F
Cadre Supérieur	2	1
Cadre	2	0
Employé	1	2

Commandes MATLAB

→ X1=[1,0,0,0,1,0,1,0,0,0,1,0,0,1,0,0,0,1];  
 → X2=[1,0,1,0,0,1,1,0,0,1,0,0,1,1,0,1,0,1];  
 → X1\*X2

ans =  
 2 1  
 2 0  
 1 2

## Quelques mesures de statistiques descriptives

### Mesures de liaison entre deux caractères qualitatifs

Matrice de contingence :

$$\begin{bmatrix} n_{11} & n_{12} & \dots & n_{1j} & \dots & n_{1s} \\ n_{21} & n_{22} & \dots & \dots & \dots & \dots \\ \vdots & \vdots & \dots & \vdots & \dots & \vdots \\ n_{r1} & n_{r2} & \dots & n_{rj} & \dots & n_{rs} \end{bmatrix}$$

$$n_i = \sum_{j=1}^s n_{ij} \quad n_j = \sum_{i=1}^r n_{ij} = \sum_{j=1}^s n_{ij} \times n_j$$

$$\text{Écart à l'indépendance : } D^2 = \sum_{i=1}^r \sum_{j=1}^s \frac{\left( n_{ij} - \frac{n_i \times n_j}{n} \right)^2}{\frac{n_i \times n_j}{n}} = n \left[ \sum_{i=1}^r \sum_{j=1}^s \frac{n_{ij}^2}{n_i \times n_j} - 1 \right]$$

$$0 \leq D^2 \leq n \times \inf(s-1, r-1)$$

Indépendance

Dépendance

## Quelques mesures de statistiques descriptives

### Mesure de liaison entre un caractère quantitatif Y et un caractère qualitatif X

Si X possède k catégories, on note :

$n_1, n_2, \dots, n_k$  les effectifs observés

$\bar{Y}_1, \bar{Y}_2, \dots, \bar{Y}_k$  les moyennes de Y pour chaque catégorie

$$\text{Rapport de corrélation : } e^2 = \frac{1}{n} \sum_{i=1}^k n_i (\bar{Y}_i - \bar{Y})^2}{s_y^2}$$

$$n_1 = 3, n_2 = 3$$

$$\bar{Y}_1 = 200, \bar{Y}_2 = 120$$

$$\bar{Y} = 160, s_y^2 = 2960$$

$$e^2 = 0.54$$

Individus	Sexe X		Revenu Y
	H	F	
1	1	0	150
2	1	0	200
3	0	1	120
4	0	1	110
5	1	0	250
6	0	1	130

Caractères

Indépendance

Dépendance

## Quelques mesures de statistiques descriptives

$$X_k = [x_k^1, x_k^2, \dots, x_k^1, \dots, x_k^p]^T \quad X_k = [x_k^1, x_k^2, \dots, x_k^1, \dots, x_k^p]^T$$

### Mesures de distance

Formule Générale :  $d_k^2 = d^2(X_i, X_k) = (X_i - X_k)^T M (X_i - X_k)$

Distance Euclidienne :  $M = I = \begin{bmatrix} 1 & & 0 \\ & \ddots & \\ 0 & & 1 \end{bmatrix}$

Distance standardisée :  $M = D_{1/s^2} = \begin{bmatrix} 1/s_1^2 & & 0 \\ & \ddots & \\ 0 & & 1/s_p^2 \end{bmatrix}$

Distance de Mahalanobis :  $M = V^{-1}$   $V =$  matrice de covariance

Distance "City Block" :  $d_{jk}^2 = \sum_{i=1}^n |x_i^j - x_i^k|$

## Quelques mesures de statistiques descriptives

$$X^{cible} = [x_1^{cible}, x_2^{cible}, \dots, x_n^{cible}]^T \quad X^{estimé} = [x_1^{estimé}, x_2^{estimé}, \dots, x_n^{estimé}]^T$$

### Mesures d'erreur

Erreur quadratique moyenne :  $MSE = \frac{1}{n} \sum_{i=1}^n (x_i^{cible} - x_i^{estimé})^2$

Racine de l'erreur quadratique moyenne :  $RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i^{cible} - x_i^{estimé})^2}$


Erreur absolue moyenne :  $MAE = \frac{1}{n} \sum_{i=1}^n |x_i^{cible} - x_i^{estimé}|$

Erreur relative absolue moyenne :  $MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{x_i^{cible} - x_i^{estimé}}{x_i^{cible}} \right|$

## Quelques graphiques de statistiques descriptives

- **Tracé de courbes**

Fonction MATLAB : plot



- **Histogramme**


Fonction MATLAB : hist

- **Boxplot**

Fonction MATLAB : boxplot

## Éléments du traitement du signal

- Transformée de Fourier discrète : permet de convertir un signal du domaine temporel dans le domaine fréquentiel



### Transformée

$$X_k = \sum_{n=1}^N x_n e^{-i2\pi(n-1)(k-1)/N}$$

pour  $k = 1, 2, \dots, N$

### Transformée inverse

$$x_n = \frac{1}{N} \sum_{k=1}^N X_k e^{-i2\pi(n-1)(k-1)/N}$$

pour  $n = 1, 2, \dots, N$

Fonction Matlab : fft

Fonction Matlab : ifft

## Éléments du traitement du signal

- Série de Fourier


$$X_n = a_0 + \sum_{k=1}^{N/2} a_k \cos(2\pi k t_n / (N \cdot dt)) + b_k \sin(2\pi k t_n / (N \cdot dt))$$

$$a_0 = X_1 / N$$

$$a_k = 2 \times \Re(X_{k+1}) / N$$

$$b_k = -2 \times \Im(X_{k+1}) / N$$

- exemple :  
reconstruction  
d'un signal carré  
(N=100)



## Régression linéaire

$$X^j = [x_1^j, x_2^j, \dots, x_1^j, \dots, x_n^j]^T$$


$$X^k = [x_1^k, x_2^k, \dots, x_1^k, \dots, x_n^k]^T$$

$$X^k = \hat{a} X^j + \hat{b}$$

$$\hat{b} = \frac{\sum_{i=1}^N (x_i^j - \bar{X}^j)(x_i^k - \bar{X}^k)}{\sum_{i=1}^N (x_i^j - \bar{X}^j)^2}$$

$$\hat{a} = \bar{X}^k - \hat{b} \times \bar{X}^j$$

Fonction Matlab : regress




## Organisation du cours

- Introduction
- Bases du KDD et du DM
- Bases de l'analyse des données
- Analyse factorielle**
- Classification
- Clustering
- Logique floue
- Réseaux de neurones artificiels
- Conclusion

## Analyse Factorielle

- Terme générique pour parler :
  - de l'analyse en composantes principales
  - et de l'analyse factorielle proprement dite
- Objectif :
  - Réduire les dimensions de l'espace des données
  - Création de variables « latentes » : combinaisons linéaires des variables réelles



## Analyse en Composantes Principales

- X étant un tableau de p variables numériques décrivant n individus  $e_1, e_2, \dots, e_n$
- L'ACP permet de rechercher une représentation des n individus dans un sous espace de l'espace initial.
- Autrement dit, l'objectif est de définir k nouvelles variables, combinaisons des p variables de l'espace initial, qui feraient perdre le « moins d'information possible ».
- Ces k variables sont appelées « composantes principales », et les axes qu'elles déterminent « axes principaux ».

## Analyse en Composantes Principales

- Notations
  - Vecteurs individus dans l'espace initial :  $e_1, e_2, \dots, e_n$
  - Vecteurs individus dans l'espace de projection :  $f_1, f_2, \dots, f_n$
  - Vecteurs variables :  $x_1, x_2, \dots, x_n$
  - Poids associés à chaque individus :  $p_1, p_2, \dots, p_n$
  - Centre de gravité du nuage de points initial : g
  - Inertie totale du nuage de points :  $I_g$

Remarque : on supposera les variables centrées


## Analyse en Composantes Principales

- On cherche un sous-espace de l'espace initial tel que :

$$\sum_{i=1}^n p_i \|e_i - f\|^2 \text{ soit minimale}$$

$$\text{Or } \|e_i - g\|^2 = \|e_i - f\|^2 + \|f - g\|^2$$

$$\text{L'objectif est donc de maximiser : } \sum_{i=1}^n p_i \|f - g\|^2$$



En d'autres termes,

l'objectif est de maximiser la dispersion (ou inertie totale) des  $f_i$

$$\text{Soit l'inertie du nuage initial : } I_g^{\text{init}} = \sum_{i=1}^n p_i e_i^t M e_i = \text{Trace}(MV)$$

avec V matrice de variance et M une métrique

Il faut donc maximiser l'inertie du nuage projeté :  $I_g^{\text{pro}} = \text{Trace}(MVP)$

avec P : matrice de projection

## Analyse en Composantes Principales

- Axes principaux
  - On cherche une droite maximisant l'inertie du nuage projeté sur cette droite. Soit a un vecteur de cette droite
  - On a :  $P = a(a^t M a)^{-1} a^t M$
  - Le but est de trouver a maximisant  $\text{Trace}(VMP)$
  - On montre que a est le vecteur propre de la matrice VM associé à la plus grande valeur propre.
  - Le sous-espace des projetés de dimension k est engendré par les k vecteurs propres de VM associés aux k plus grandes valeurs propres

## Analyse en Composantes Principales

- Facteurs principaux

A l'axe principal  $a_i$  est associé le facteur principal  $u_i$

$$u_i = M a_i$$

- Composantes principales

Ce sont les variables  $c_i$  définies par les facteurs principaux, combinaisons linéaires des  $x_1, \dots, x_p$

$$c_i = X u_i$$

La variance de  $c_i$  est égale à la valeur propre  $\lambda_i$  correspondante.

Ces composantes sont orthogonales et donc non corrélées entre elles.

## Analyse en Composantes Principales

- Interprétation : exemple sur la base des iris


Vecteurs propres				
	CP1	CP2	CP3	CP4
L sépale	0.5224	-0.3723	0.7210	-0.2620
L sépale	-0.2634	-0.9256	-0.2420	0.1241
L pétale	0.5813	-0.0211	-0.1409	0.8012
L pétale	0.5656	-0.0654	-0.6338	-0.5235

	valeurs propres	%	d'inertie cumulé
CP1	2.9108	72.77%	72.77%
CP2	0.9212	23.03%	95.80%
CP3	0.1474	03.69%	99.49%
CP4	0.0206	00.51%	100.00%

## Analyse en Composantes Principales

- Interprétation : exemple sur la base des iris



## Organisation du cours

Introduction
Bases du KDD et du DM
Bases de l'analyse des données
Analyse factorielle
<b>Classification</b>
Clustering
Logique floue
Réseaux de neurones artificiels
Conclusion

## Classification

- Objectif : identifier les classes auxquelles appartiennent des objets à partir de traits descriptifs

$\Pi$  est la population,

$D$  est l'ensemble des descriptions,

$C$  est l'ensemble des classes

$X : \Pi \rightarrow D$

fonction qui associe une description à tout élément de la population

$Y : \Pi \rightarrow C$

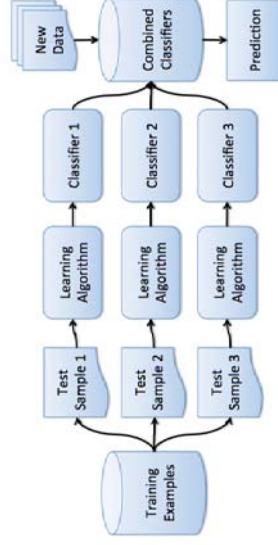
fonction qui associe une classe à tout élément de la population

$F : D \rightarrow C$

fonction de classement recherchée


## Méthodes de classification

- 4 grandes catégories de méthodes de classification
  - Distance : exemple k plus proches voisins
  - Probabiliste : exemple Naïves Bayes
  - Arbres de décision: exemple ID3
  - Distance et optimisation : exemple Machines à vecteurs de support
- Il existe un nombre important de méthodes de classification basées sur ces 4 catégories
- Ensemble Learning



## Classification

- Le but est de rechercher une fonction de classement  $F$  telle que  $F \circ X$  soit une bonne approximation de  $Y$ .



## Algorithme des k plus proches voisins


- On considère l'espace de  $n$  points de dimension  $p$  suivant :

$$X : \begin{matrix} X_1 & \dots & X_j & \dots & X^n \\ \begin{bmatrix} x_1^1 & \dots & x_1^j & \dots & x_1^p \\ \dots & \dots & \dots & \dots & \dots \\ x_i^1 & \dots & x_i^j & \dots & x_i^p \\ \dots & \dots & \dots & \dots & \dots \\ x_n^1 & \dots & x_n^j & \dots & x_n^p \end{bmatrix} & \dots & \dots & \dots & \dots \end{matrix}$$

- A chaque point est associée une classe connue à l'avance
- Soit  $X_T = [x_T^1, x_T^2, \dots, x_T^j, \dots, x_T^p]$  un point que l'on souhaite classifier
- On calcule toutes les distances entre le point  $X_T$  et les  $n$  points de l'espace
- On conserve les  $k$  points les plus proches de  $X_T$
- La classe majoritaire dans l'ensemble de ces  $k$  points est attribuée à  $X_T$

## Algorithme des k plus proches voisins

- Exemple :



Si  $k=3$  le nouveau point sera associé à la classe des cercles

Si  $k=5$  le nouveau point sera associé à la classe des carrés

## Classifieur naïf de Bayes

- On estime  $p(c_k)$  par  $\hat{p}(c_k) = \frac{n_k}{n}$
- et  $p(x/c_k)$  par :  $\hat{p}(x/c_k) = \prod_{i=1}^p p(x^i/c_k)$

Ce qui revient à considérer les attributs comme indépendants les uns des autres

- La règle de classification de Bayes devient alors : classer le vecteur  $x$  dans la classe  $c_k$  qui maximise :

$$\prod_{i=1}^p p(x^i/c_k) p(c_k)$$

- Lorsque les attributs prennent leurs valeurs dans un même ensemble, on peut faire l'hypothèse que dans chaque classe, la probabilité d'observer une valeur quelconque d'un attribut est en fait indépendante de l'attribut.

Pour toute classe  $c$ , pour toute valeur  $v$  et tous les indices  $i$  et  $j$  :

$$p(x^i = v/c) = p(x^j = v/c)$$

## Classifieur naïf de Bayes

- On note :

$x = [x^1, x^2, \dots, x^i, \dots, x^p]$  un vecteur de descripteurs

$C = \{c_1, \dots, c_q\}$  l'ensemble des classes possibles

$S$  : ensemble fini de couples de la forme  $(x, c_k)$

$n$  : nombre d'observations de  $S$

$n_k$  : nombre d'éléments de  $S$  appartenant à la classe  $c_k$

- La règle de classification de Bayes recommande de classer le vecteur  $x$  dans la classe  $c_k$  pour laquelle  $P(c_k/x)$  est maximal.

$$\text{Ce qui revient à maximiser : } \frac{p(x/c_k)p(c_k)}{p(x)}$$

soit encore  $p(x/c_k)p(c_k)$ ,  $p(x)$  ne dépendant pas de  $c_k$

Pour pouvoir appliquer la règle de Bayes il faut donc pouvoir estimer :  $p(x/c_k)$  et  $p(c_k)$

## Classifieur naïf de Bayes

- Exemple

$$S = S_1 \cup S_2$$

$$S_1 = \{01100, 11001, 10110, 10101, 10010\}$$

$$S_2 = \{01010, 11111, 11010, 11101, 10101\}$$

$$C = \{c_1, c_2\}$$

- On demande de classer  $x=00111$

$$\hat{p}(c_1) = \frac{n_1}{n} = \frac{5}{10} = \frac{1}{2}$$

$$\hat{p}(c_2) = \frac{n_2}{n} = \frac{5}{10} = \frac{1}{2}$$

## Classifieur naïf de Bayes

- On suppose les attributs indépendants

	$c_1$	$c_2$	$c_1$	$c_2$
$\hat{p}(x_1 = 0/c_j)$	1/5	1/5	$\hat{p}(x_1 = 1/c_j)$	4/5
$\hat{p}(x_2 = 0/c_j)$	3/5	1/5	$\hat{p}(x_2 = 1/c_j)$	4/5
$\hat{p}(x_3 = 0/c_j)$	2/5	2/5	$\hat{p}(x_3 = 1/c_j)$	3/5
$\hat{p}(x_4 = 0/c_j)$	3/5	2/5	$\hat{p}(x_4 = 1/c_j)$	3/5
$\hat{p}(x_5 = 0/c_j)$	3/5	2/5	$\hat{p}(x_5 = 1/c_j)$	3/5

$$\hat{p}(00111/c_1) = \frac{1}{5} \times \frac{3}{5} \times \frac{2}{5} \times \frac{2}{5} \times \frac{36}{5} = 11.5 \cdot 10^{-3}$$

$$\hat{p}(00111/c_2) = \frac{1}{5} \times \frac{1}{5} \times \frac{3}{5} \times \frac{3}{5} \times \frac{27}{5} = 8.6 \cdot 10^{-3}$$

- On classera donc  $x=00111$  en classe  $c_1$

## Classifieur naïf de Bayes

- Si on fait en plus l'hypothèse que les attributs prennent dans chaque classe les mêmes valeurs avec les mêmes probabilités

$$\hat{p}(x_i = 0/c_1) = \frac{12}{25}; \hat{p}(x_i = 1/c_1) = \frac{13}{25}$$

$$\hat{p}(x_i = 0/c_2) = \frac{8}{25}; \hat{p}(x_i = 1/c_2) = \frac{17}{25}$$

$$\hat{p}(00111/c_1) = \frac{12^2 \times 13^3}{25^5} = 32.4 \cdot 10^{-3}$$

$$\hat{p}(00111/c_2) = \frac{8^2 \times 17^3}{25^5} = 32.2 \cdot 10^{-3}$$

- On classera donc  $x=00111$  en classe  $c_1$

## Exercice 1 classifieur naïf de Bayes

- Objectif : Classifier des phrases selon leur thème : la radio ou la télévision
- Échantillon :

- Classe télévision :
  - Le programme TV n'est pas intéressant.
  - La TV m'ennuie.
  - Les enfants aiment la TV.
  - On reçoit la TV par onde radio.
- Classe radio :
  - Il est intéressant d'écouter la radio.
  - Sur les ondes, les programmes pour enfants sont rares.
  - Les enfants vont écouter la radio; c'est rare.
- Vocabulaire :  $V = \{\text{TV, programme, intéressant, enfants, radio, onde, écouter, rare}\}$

- En utilisant un classifieur de Bayes, à quel thème serait associée la phrase : « J'ai vu la radio de mes poumons à la TV »

## Exercice 1 classifieur naïf de Bayes

- Codage des informations
- Échantillon :

TV	programme	intéressant	enfants	radio	onde	écouter	rare
x1	x2	x3	x4	x5	x6	x7	x8
1							
2							
3							
4							
5							
6							
7							

- Phrase à classer :  
 $x = x_1 x_2 x_3 x_4 x_5 x_6 x_7 x_8$

## Exercice 1 classifieur naïf de Bayes

$$\hat{p}(c_1) = -$$

$$\hat{p}(c_2) = -$$

$$\hat{p}(x_1 = 1/c_1) = -$$

$$\hat{p}(x_1 = 1/c_2) = -$$

$$\hat{p}(x_2 = 0/c_1) = -$$

$$\hat{p}(x_2 = 0/c_2) = -$$

$$\hat{p}(c_1) \times \hat{p}(10001000/c_1) =$$

$$\hat{p}(c_2) \times \hat{p}(10001000/c_2) =$$

## Exercice 1 classifieur naïf de Bayes

$$\hat{p}(c_1) = \frac{4}{7} \quad \hat{p}(c_2) = \frac{3}{7}$$

$$\hat{p}(x_1 = 0/c_1) = \frac{0}{4} \quad \hat{p}(x_1 = 0/c_2) = \frac{3}{3} \quad \hat{p}(x_1 = 1/c_1) = \frac{4}{4} \quad \hat{p}(x_1 = 1/c_2) = \frac{0}{3}$$

$$\hat{p}(x_2 = 0/c_1) = \frac{3}{4} \quad \hat{p}(x_2 = 0/c_2) = \frac{2}{3} \quad \hat{p}(x_2 = 1/c_1) = \frac{1}{4} \quad \hat{p}(x_2 = 1/c_2) = \frac{1}{3}$$

$$\hat{p}(x_3 = 0/c_1) = \frac{3}{4} \quad \hat{p}(x_3 = 0/c_2) = \frac{2}{3} \quad \hat{p}(x_3 = 1/c_1) = \frac{1}{4} \quad \hat{p}(x_3 = 1/c_2) = \frac{1}{3}$$

$$\hat{p}(x_4 = 0/c_1) = \frac{3}{4} \quad \hat{p}(x_4 = 0/c_2) = \frac{1}{3} \quad \hat{p}(x_4 = 1/c_1) = \frac{1}{4} \quad \hat{p}(x_4 = 1/c_2) = \frac{2}{3}$$

$$\hat{p}(x_5 = 0/c_1) = \frac{3}{4} \quad \hat{p}(x_5 = 0/c_2) = \frac{3}{3} \quad \hat{p}(x_5 = 1/c_1) = \frac{1}{4} \quad \hat{p}(x_5 = 1/c_2) = \frac{2}{3}$$

$$\hat{p}(x_6 = 0/c_1) = \frac{3}{4} \quad \hat{p}(x_6 = 0/c_2) = \frac{2}{3} \quad \hat{p}(x_6 = 1/c_1) = \frac{1}{4} \quad \hat{p}(x_6 = 1/c_2) = \frac{1}{3}$$

$$\hat{p}(x_7 = 0/c_1) = \frac{4}{4} \quad \hat{p}(x_7 = 0/c_2) = \frac{3}{3} \quad \hat{p}(x_7 = 1/c_1) = \frac{0}{4} \quad \hat{p}(x_7 = 1/c_2) = \frac{2}{3}$$

$$\hat{p}(x_8 = 0/c_1) = \frac{4}{4} \quad \hat{p}(x_8 = 0/c_2) = \frac{1}{3} \quad \hat{p}(x_8 = 1/c_1) = \frac{0}{4} \quad \hat{p}(x_8 = 1/c_2) = \frac{2}{3}$$

$$\hat{p}(c_1) \times \hat{p}(10001000/c_1) = \frac{4}{7} \times \frac{1}{4} \times \frac{3}{4} \times \frac{3}{4} \times \frac{3}{4} \times \frac{1}{4} \times \frac{3}{4} \times \frac{2}{4} \times \frac{4}{4} \times \frac{4}{4} = \frac{20736}{458752} = 0,0452$$

$$\hat{p}(c_2) \times \hat{p}(10001000/c_2) = \frac{3}{7} \times \frac{0}{3} \times \frac{2}{3} \times \frac{2}{3} \times \frac{2}{3} \times \frac{1}{3} \times \frac{2}{3} \times \frac{1}{3} \times \frac{1}{3} \times \frac{0}{3} = 0$$

## Exercice 1 classifieur naïf de Bayes

$$\hat{p}(x_i, c_k) = \frac{1 + \text{Nombre d'occurrences de } x_i \text{ de } V \text{ dans l'ensemble des textes de classe } k}{\text{Card}(V) + \text{Nombre total d'occurrences de mots dans l'ensemble des textes de classe } k}$$

$$\hat{p}(c_1) = \frac{4}{7} \quad \hat{p}(c_2) = \frac{3}{7}$$

$$\hat{p}(x_1 = 1/c_1) = \frac{1+4}{8+9} \quad \hat{p}(x_1 = 1/c_2) = \frac{1+0}{8+11}$$

$$\hat{p}(x_2 = 1/c_1) = \frac{1+1}{8+9} \quad \hat{p}(x_2 = 1/c_2) = \frac{1+1}{8+11}$$

$$\hat{p}(x_3 = 1/c_1) = \frac{1+1}{8+9} \quad \hat{p}(x_3 = 1/c_2) = \frac{1+1}{8+11}$$

$$\hat{p}(x_4 = 1/c_1) = \frac{1+1}{8+9} \quad \hat{p}(x_4 = 1/c_2) = \frac{1+2}{8+11}$$

$$\hat{p}(x_5 = 1/c_1) = \frac{1+1}{8+9} \quad \hat{p}(x_5 = 1/c_2) = \frac{1+2}{8+11}$$

$$\hat{p}(x_6 = 1/c_1) = \frac{1+1}{8+9} \quad \hat{p}(x_6 = 1/c_2) = \frac{1+1}{8+11}$$

$$\hat{p}(x_7 = 1/c_1) = \frac{1+0}{8+9} \quad \hat{p}(x_7 = 1/c_2) = \frac{1+2}{8+11}$$

$$\hat{p}(x_8 = 1/c_1) = \frac{1+0}{8+9} \quad \hat{p}(x_8 = 1/c_2) = \frac{1+2}{8+11}$$

$$\hat{p}(c_1) \times \hat{p}(10001000/c_1) = \frac{4}{7} \times \frac{5}{17} \times \frac{2}{17} = \frac{40}{2023} = 0,020$$

$$\hat{p}(c_2) \times \hat{p}(10001000/c_2) = \frac{3}{7} \times \frac{1}{19} \times \frac{3}{19} = \frac{9}{2527} = 0,0035$$

## Exercice 2 classifieur naïf de Bayes

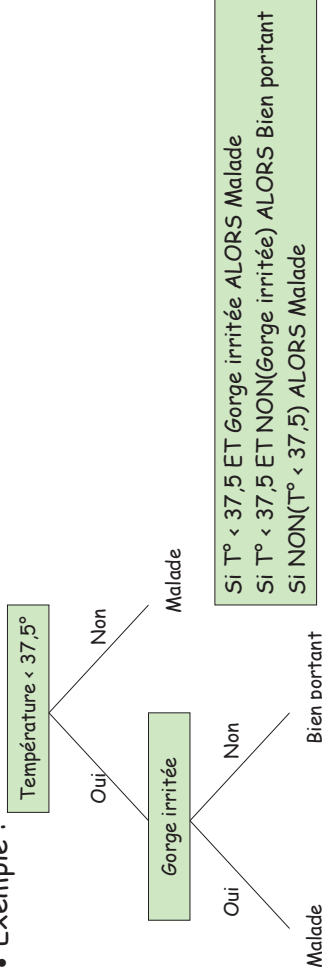
### Diagnostic de la grippe

#	Frissons	Nez qui coule	Maux de tête	Fièvre	Grippe
1	Oui	Non	Moyen	Oui	Non
2	Oui	Oui	Non	Non	Oui
3	Oui	Non	Fort	Oui	Oui
4	Non	Oui	Moyen	Oui	Oui
5	Non	Non	Non	Non	Non
6	Non	Oui	Fort	Oui	Oui
7	Non	Oui	Fort	Non	Non
8	Oui	Oui	Moyen	Oui	Oui
9	Oui	Non	Non	Oui	?

## Arbres de Décision

- Un arbre de décision est une représentation graphique d'une procédure de classification
- Un arbre de décision peut être traduit sous forme de règles de décision

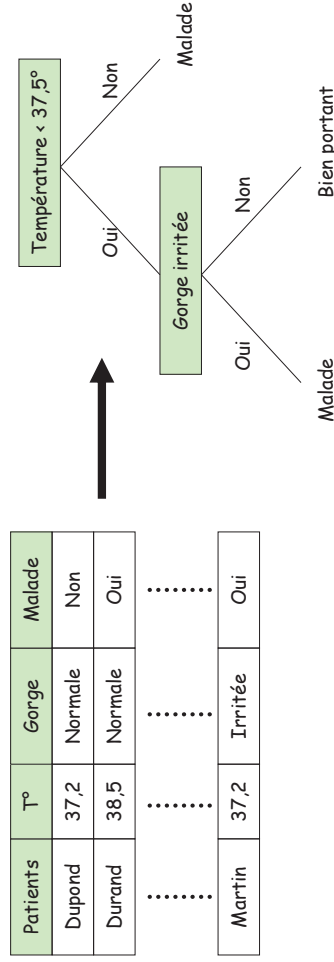
• Exemple :



## Arbres de Décision

- Comment généré automatiquement un arbre à partir de données ?

• Exemple :




## Arbres de Décision

- Un arbre de décision est un arbre au sens informatique du terme.
  - Chaque nœud interne test un attribut
  - Chaque branche correspond à une valeur d'un attribut
  - Chaque nœud feuille est une classe

Les nœuds de l'arbre sont repérés par des positions qui sont des mots de  $\{1, \dots, p\}^*$ , où  $p$  est l'arité maximale des nœuds.

On note  $\epsilon$  le mot vide.



## Arbres de Décision

- Notation

S : échantillon

$\{1, \dots, c\}$  : ensemble de classes

t : arbre de décision

p : position dans l'arbre

$N(p)$  : cardinal de l'ensemble des exemples associé à p

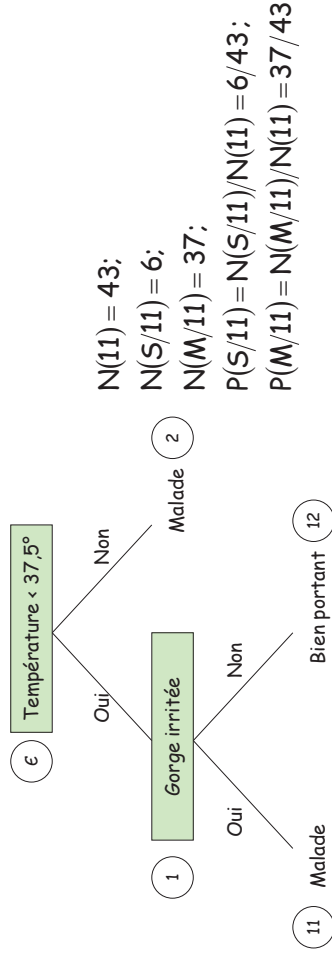
$N(k/p)$  : cardinal de l'ensemble des exemples associé à p et de classe k

$P(k/p) = N(k/p)/N(p)$  : proportion d'éléments de classe k à la position p

## Arbres de Décision

### Exemple

	Gorge irritée	Gorge non irritée	
$T^{\circ} < 37,5$	(6 S, 37 M)	(91 S, 1 M)	M : Malade S : Bien portant
$T^{\circ} \geq 37,5$	(2 S, 21 M)	(1 S, 41 M)	




## Arbres de Décision

### Racine de l'arbre (pas de test)

Etiquette (3,5) correspondant à :  $(N(\epsilon, \text{oui}), N(\epsilon, \text{non}))$

### Quel est premier test à réaliser ?



### Intuitivement :

- Le test sur R n'est pas discriminatoire
- Le test sur A est intéressant sur les branches jeune et âgé

## Arbres de Décision

- Exemple introductif à l'apprentissage automatique d'arbre de décision
- Données banque

	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

- Moyenne du solde du compte :
- $M = \{\text{élevé, moyen, faible}\}$
- Tranche d'âge du client :
- $A = \{\text{jeune, moyen, âgé}\}$
- Type de localité de résidence du client :
- $R = \{\text{village, bourg, ville}\}$
- Niveau d'études supérieures du client :
- $E = \{\text{oui, non}\}$
- Consultation du compte par Internet :
- $I = \{\text{oui, non}\}$

- On souhaite construire un arbre de décision qui soit capable de déterminer si un client consultera son compte par Internet en fonction des attributs : M, A, R et E

## Arbres de Décision

- Quelles fonctions permettraient de représenter ces intuitions ?

### Fonctions qui seraient :

- Minimum lorsque le nœud est pur (tous les exemples sont dans une même classe)
- et Maximum lorsque les exemples sont équirépartis.

- Exemples de fonctions possédant ces propriétés :

- Entropie :  $\text{Entropie}(p) = -\sum_{k=1}^c P(k/p) \times \log(P(k/p))$
- Fonction de Gini :  $\text{Gini}(p) = 1 - \sum_{k=1}^c P(k/p)^2 = 2 \times \sum_{k < k'} P(k/p) \times P(k'/p)$

## Arbres de Décision

- Quelles fonction permettrait choisir un test ?

- Fonction gain :  $\text{Gain}(p, \text{test}) = i(p) - \sum_{j=1}^n P_j \times i(p_j)$

$p$  : position

test : test d'arité  $n$

$P_j$  : proportion d'éléments de  $S$  à la position  $p$  qui vont en position  $p_j$


$i(p)$  : Entropie( $p$ ) ou Gini( $p$ )

- Le test choisi est celui qui possède le gain le plus grand

## Arbres de Décision

- Exemple traité avec l'entropie :

(3,5) Entropie( $\epsilon$ ) =  $-\frac{3}{8} \log\left(\frac{3}{8}\right) - \frac{5}{8} \log\left(\frac{5}{8}\right) \approx 0,954$



$$\text{Entropie}(1) = -\frac{1}{3} \log\left(\frac{1}{3}\right) - \frac{2}{3} \log\left(\frac{2}{3}\right) \approx 0,918$$

$$\text{Entropie}(2) = -\frac{2}{3} \log\left(\frac{2}{3}\right) - \frac{1}{3} \log\left(\frac{1}{3}\right) \approx 0,918$$


$$\text{Entropie}(3) = -\frac{0}{2} \log\left(\frac{0}{2}\right) - \frac{2}{2} \log\left(\frac{2}{2}\right) = 0$$

$$\begin{aligned} \text{Gain}(\epsilon, M) &= \text{Entropie}(\epsilon) - \left( \frac{3}{8} \text{Entropie}(1) + \frac{3}{8} \text{Entropie}(2) + \frac{2}{8} \text{Entropie}(3) \right) \\ &= \text{Entropie}(\epsilon) - 0,688 \end{aligned}$$

## Arbres de Décision

- Exemple traité avec l'entropie :

(3,5) Entropie( $\epsilon$ ) =  $-\frac{3}{8} \log\left(\frac{3}{8}\right) - \frac{5}{8} \log\left(\frac{5}{8}\right) \approx 0,954$



$$\text{Entropie}(1) = -\frac{1}{1} \log\left(\frac{1}{1}\right) - \frac{0}{1} \log\left(\frac{0}{1}\right) = 0$$

$$\text{Entropie}(2) = -\frac{2}{4} \log\left(\frac{2}{4}\right) - \frac{2}{4} \log\left(\frac{2}{4}\right) = 1$$


$$\text{Entropie}(3) = -\frac{0}{3} \log\left(\frac{0}{3}\right) - \frac{3}{3} \log\left(\frac{3}{3}\right) = 0$$

$$\begin{aligned} \text{Gain}(\epsilon, A) &= \text{Entropie}(\epsilon) - \left( \frac{1}{8} \text{Entropie}(1) + \frac{4}{8} \text{Entropie}(2) + \frac{3}{8} \text{Entropie}(3) \right) \\ &= \text{Entropie}(\epsilon) - 0,5 \end{aligned}$$

## Arbres de Décision

- Exemple traité avec l'entropie :

(3,5) Entropie( $\epsilon$ ) =  $-\frac{3}{8} \log\left(\frac{3}{8}\right) - \frac{5}{8} \log\left(\frac{5}{8}\right) \approx 0,954$



$$\text{Entropie}(1) = -\frac{1}{2} \log\left(\frac{1}{2}\right) - \frac{1}{2} \log\left(\frac{1}{2}\right) = 1$$

$$\text{Entropie}(2) = -\frac{1}{3} \log\left(\frac{1}{3}\right) - \frac{2}{3} \log\left(\frac{2}{3}\right) \approx 0,918$$


$$\text{Entropie}(3) = -\frac{1}{3} \log\left(\frac{1}{3}\right) - \frac{2}{3} \log\left(\frac{2}{3}\right) \approx 0,918$$

$$\begin{aligned} \text{Gain}(\epsilon, R) &= \text{Entropie}(\epsilon) - \left( \frac{2}{8} \text{Entropie}(1) + \frac{3}{8} \text{Entropie}(2) + \frac{3}{8} \text{Entropie}(3) \right) \\ &= \text{Entropie}(\epsilon) - 0,938 \end{aligned}$$

## Arbres de Décision

- Exemple traité avec l'entropie :

$$(3,5) \quad \text{Entropie}(\epsilon) = -\frac{3}{8} \log\left(\frac{3}{8}\right) - \frac{5}{8} \log\left(\frac{5}{8}\right) \approx 0,954$$



$$\text{Entropie}(1) = -\frac{3}{5} \log\left(\frac{3}{5}\right) - \frac{2}{5} \log\left(\frac{2}{5}\right) \approx 0,97$$

$$\text{Entropie}(2) = -\frac{0}{3} \log\left(\frac{0}{3}\right) - \frac{3}{3} \log\left(\frac{3}{3}\right) = 0$$

$$\text{Gain}(\epsilon, E) = \text{Entropie}(\epsilon) - \left(\frac{5}{8} \text{Entropie}(1) + \frac{3}{8} \text{Entropie}(2)\right) = \text{Entropie}(\epsilon) - 0,607$$

## Arbres de Décision

- Algorithme générique de construction d'un arbre

**entrée** : langage de description; échantillon S

**début**

Initialiser à l'arbre vide; la racine est le nœud courant

**répéter**

Décider si le nœud courant est terminal

si le nœud est terminal **alors**

Affecter une classe

**sinon**

Sélectionner un test et créer le sous-arbre

**fin**

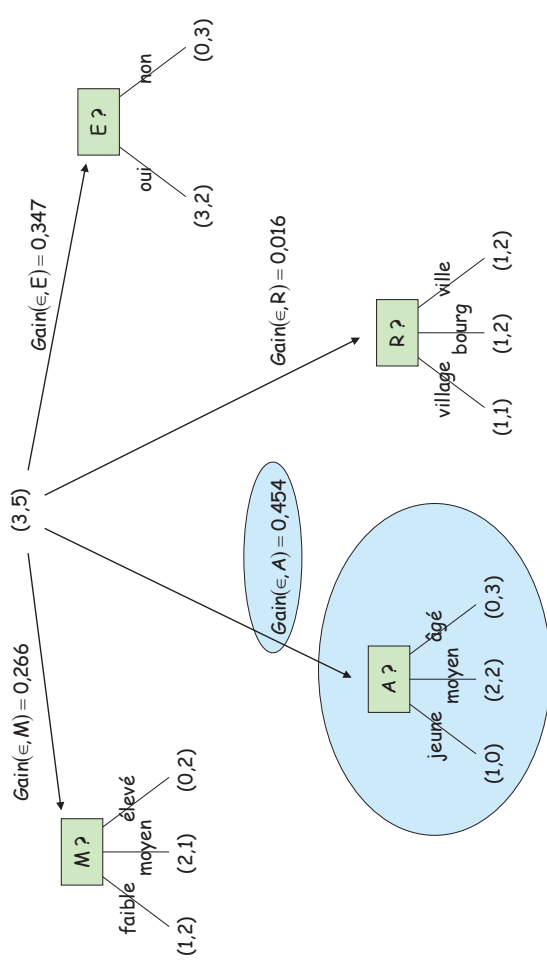
Passer au nœud suivant non exploré si il en existe

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

**fin**

## Arbres de Décision

- Exemple traité avec l'entropie :



## Arbres de Décision

- Algorithme CART (Breiman 1984) - Arbres de décision binaires

Un nœud p est terminal si :

$$\text{Gini}(p) \leq i_0 \text{ ou } N(p) \leq n_0, i_0 \text{ et } n_0 \text{ sont des paramètres à fixer}$$

On choisit le test qui maximise :

$$\text{Gain}(p, \text{test}) = \text{Gini}(p) - (P_{\text{gauche}} \times \text{Gini}(p_1) + P_{\text{droite}} \times \text{Gini}(p_2))$$

On attribut la classe majoritaire à une feuille

Cet algorithme de construction est suivi d'une phase d'élagage de l'arbre qui ne sera pas traitée dans le cadre de ce cours

## Arbres de Décision

- Algorithme ID3

Un nœud  $p$  est terminal si : tous les éléments associés à ce nœud sont dans une même classe ou si aucun test n'a pu être sélectionné

On choisit le test qui maximise :

$$\text{Gain}(p, \text{test}) = \text{Entropie}(p) - \sum_{j=1}^n P_j \times \text{Entropie}(p_j)$$

On attribut la classe majoritaire à une feuille

Cet algorithme de construction est suivi d'une phase d'élagage de l'arbre qui ne sera pas traitée dans le cadre de ce cours

## Arbres de Décision : Exercice

- Exemple introductif à l'apprentissage automatique d'arbre de décision
- Données banque

	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

- On souhaite construire un arbre de décision qui soit capable de déterminer si un client consultera son compte par Internet en fonction des attributs : M, A, R et E

## Arbres de Décision

- Algorithme C4.5 (Quilan 1993) (initialement ID3)

Un nœud  $p$  est terminal si : tous les éléments associés à ce nœud sont dans une même classe ou si aucun test n'a pu être sélectionné

On choisit le test qui maximise :

$$\text{GainRatio}(p, \text{test}) = \text{Gain}(p, \text{test}) / \text{SplitInfo}(p, \text{test})$$

$$\text{Gain}(p, \text{test}) = \text{Entropie}(p) - \sum_{j=1}^n P_j \times \text{Entropie}(p_j)$$

$$\text{SplitInfo}(p, \text{test}) = - \sum_{j=1}^n P'(j/p) \times \log(P'(j/p))$$

$P'(j/p)$  : proportion des éléments de  $p$  prenant la jème valeur de test

On attribut la classe majoritaire à une feuille

Cet algorithme de construction est suivi d'une phase d'élagage de l'arbre qui ne sera pas traitée dans le cadre de ce cours

## Arbres de Décision : Exercice

Fonction ID3 (I,O,T)

I ensemble des attributs d'entrée

O attribut de sortie

T ensemble des individus d'apprentissage

Si (T est vide)

Renvoyer Erreur

Si (tous les individus de T appartiennent à la même classe)

Renvoyer un nœud avec le label de la classe

Si (I est vide)

Renvoyer un nœud avec le label le plus fréquent sur l'attribut de sortie de T

Calculer le gain d'information pour tous les attributs de I relativement à T

X est l'attribut avec le plus grand gain

{x<sub>j</sub> / j=1,2,...,m} sont les valeurs de X

{T<sub>j</sub> / j=1,2,...,m} sont les sous ensembles de T décomposé par rapport aux x<sub>j</sub>


Renvoyer un arbre avec X comme label du nœud racine

et x<sub>1</sub>, x<sub>2</sub>, ..., x<sub>m</sub> comme labels des arcs allant aux arbres

ID3(I-{X},O,T\_1), ID3(I-{X},O,T\_2), ..., ID3(I-{X},O,T\_m)

## Arbres de Décision : Exercice

ID3 ( $\{M, A, R, E\}, \{I\}, \{1, 2, 3, 4, 5, 6, 7, 8\}$ )



$$\text{Entropie}(1) = -\frac{1}{3}\log\left(\frac{1}{3}\right) - \frac{2}{3}\log\left(\frac{2}{3}\right) \approx 0,918$$

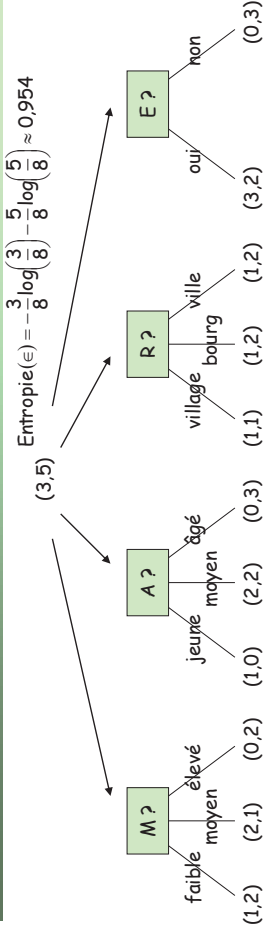
$$\text{Entropie}(2) = -\frac{2}{3}\log\left(\frac{2}{3}\right) - \frac{1}{3}\log\left(\frac{1}{3}\right) \approx 0,918$$

$$\text{Entropie}(3) = -\frac{0}{2}\log\left(\frac{0}{2}\right) - \frac{2}{2}\log\left(\frac{2}{2}\right) = 0$$

$$\begin{aligned} \text{Gain}(\epsilon, M) &= \text{Entropie}(\epsilon) - \left(\frac{3}{8}\text{Entropie}(1) + \frac{3}{8}\text{Entropie}(2) + \frac{2}{8}\text{Entropie}(3)\right) \\ &= \text{Entropie}(\epsilon) - 0,688 \end{aligned}$$

## Arbres de Décision : Exercice

## Arbres de Décision : Exercice



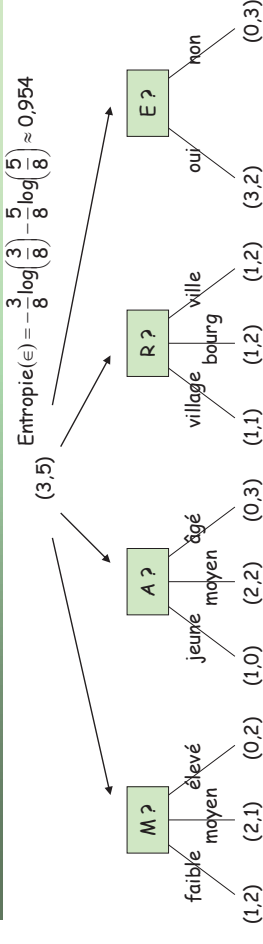
$$\text{Entropie}(1) = -\frac{1}{1}\log\left(\frac{1}{1}\right) - \frac{0}{1}\log\left(\frac{0}{1}\right) = 0$$

$$\text{Entropie}(2) = -\frac{2}{4}\log\left(\frac{2}{4}\right) - \frac{2}{4}\log\left(\frac{2}{4}\right) = 1$$

$$\text{Entropie}(3) = -\frac{0}{3}\log\left(\frac{0}{3}\right) - \frac{3}{3}\log\left(\frac{3}{3}\right) = 0$$

$$\begin{aligned} \text{Gain}(\epsilon, A) &= \text{Entropie}(\epsilon) - \left(\frac{1}{8}\text{Entropie}(1) + \frac{4}{8}\text{Entropie}(2) + \frac{3}{8}\text{Entropie}(3)\right) \\ &= \text{Entropie}(\epsilon) - 0,5 \end{aligned}$$

## Arbres de Décision : Exercice



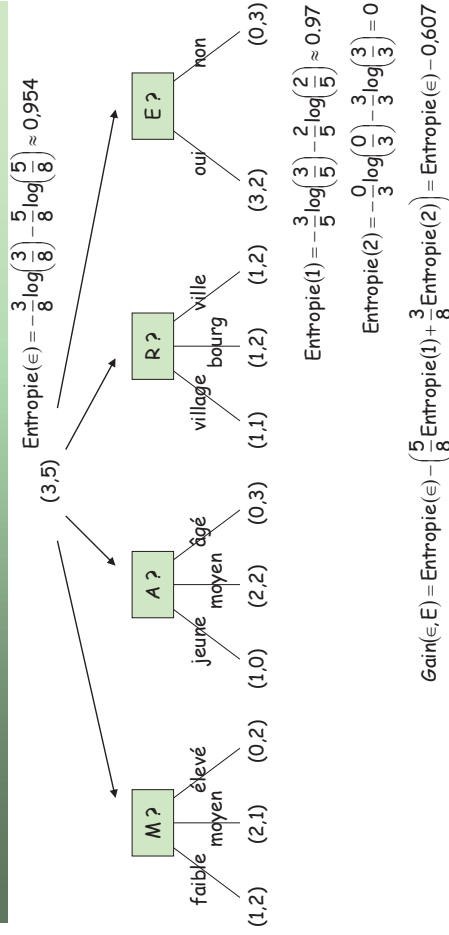
$$\text{Entropie}(1) = -\frac{1}{2}\log\left(\frac{1}{2}\right) - \frac{1}{2}\log\left(\frac{1}{2}\right) = 1$$

$$\text{Entropie}(2) = -\frac{1}{3}\log\left(\frac{1}{3}\right) - \frac{2}{3}\log\left(\frac{2}{3}\right) \approx 0,918$$


$$\text{Entropie}(3) = -\frac{1}{3}\log\left(\frac{1}{3}\right) - \frac{2}{3}\log\left(\frac{2}{3}\right) \approx 0,918$$

$$\begin{aligned} \text{Gain}(\epsilon, R) &= \text{Entropie}(\epsilon) - \left(\frac{2}{8}\text{Entropie}(1) + \frac{3}{8}\text{Entropie}(2) + \frac{3}{8}\text{Entropie}(3)\right) \\ &= \text{Entropie}(\epsilon) - 0,938 \end{aligned}$$


### Arbres de Décision : Exercice




### Arbres de Décision : Exercice



### Arbres de Décision : Exercice

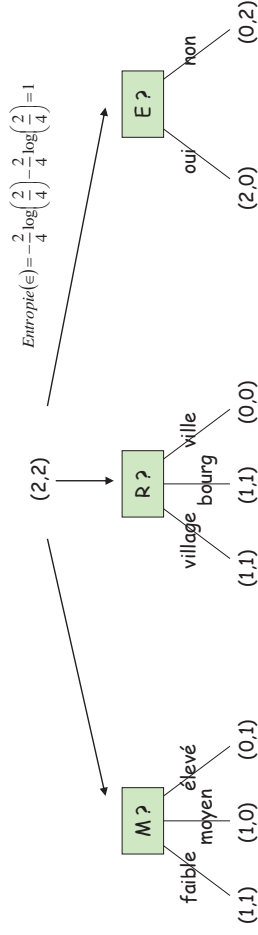


### Arbres de Décision : Exercice



	M	R	E	I
1	moyen	village	oui	oui
2	élevé	bourg	non	non
4	faible	bourg	oui	oui
8	faible	village	non	non

### Arbres de Décision : Exercice



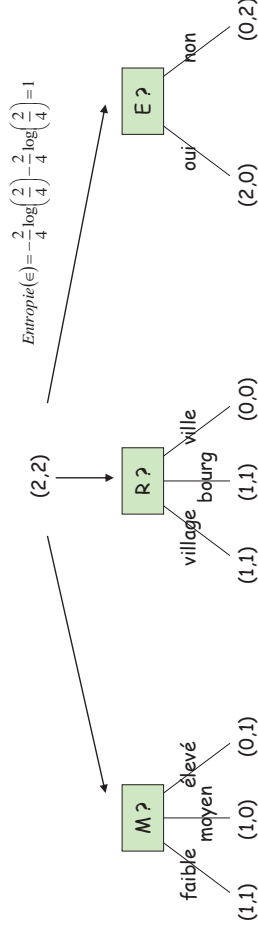
$Entropie(1) = -\frac{1}{2} \log\left(\frac{1}{2}\right) - \frac{1}{2} \log\left(\frac{1}{2}\right) = 1$

$Entropie(2) = -\frac{1}{1} \log\left(\frac{1}{1}\right) - \frac{0}{1} \log\left(\frac{0}{1}\right) = 0$

$Entropie(3) = -\frac{0}{1} \log\left(\frac{0}{1}\right) - \frac{1}{1} \log\left(\frac{1}{1}\right) = 0$

$Gain(\epsilon, M) = Entropie(\epsilon) - \left(\frac{2}{4} Entropie(1) + \frac{1}{4} Entropie(2) + \frac{1}{4} Entropie(3)\right) = Entropie(\epsilon) - 0.5$

### Arbres de Décision : Exercice



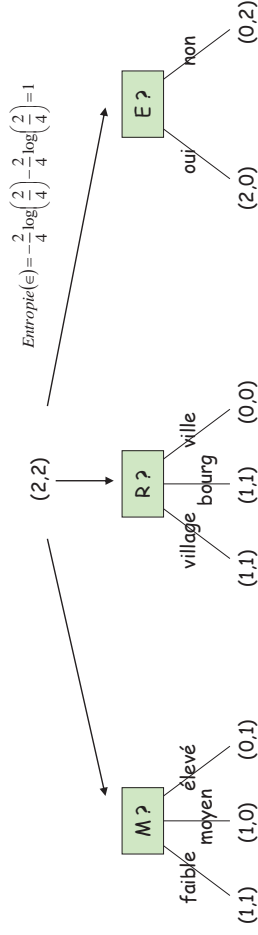
$Entropie(1) = -\frac{1}{2} \log\left(\frac{1}{2}\right) - \frac{1}{2} \log\left(\frac{1}{2}\right) = 1$

$Entropie(2) = -\frac{1}{2} \log\left(\frac{1}{2}\right) - \frac{1}{2} \log\left(\frac{1}{2}\right) = 1$

$Entropie(3) = -\frac{0}{0} \log\left(\frac{0}{0}\right) - \frac{0}{0} \log\left(\frac{0}{0}\right) = 0$

$Gain(\epsilon, R) = Entropie(\epsilon) - \left(\frac{2}{4} Entropie(1) + \frac{2}{4} Entropie(2) + \frac{0}{4} Entropie(3)\right) = Entropie(\epsilon) - 1$

### Arbres de Décision : Exercice




$Entropie(1) = -\frac{2}{2} \log\left(\frac{2}{2}\right) - \frac{0}{2} \log\left(\frac{0}{2}\right) = 0$

$Entropie(2) = -\frac{0}{2} \log\left(\frac{0}{2}\right) - \frac{2}{2} \log\left(\frac{2}{2}\right) = 0$

$Gain(\epsilon, E) = Entropie(\epsilon) - \left(\frac{2}{4} Entropie(1) + \frac{2}{4} Entropie(2)\right) = Entropie(\epsilon) - 0$


### Arbres de Décision : Exercice



$ID3(\{M, R\}, \{I\}, \{1, 4\})$


$ID3(\{M, R\}, \{I\}, \{2, 8\})$

## Arbres de Décision : Exercice



- Arbre final

## Arbres de Décision : Exercice



## Arbres de Décision : Exercice

- Evaluer les performances

	M	A	R	E	Ir	Ie
1	moyen	moyen	village	oui	oui	oui
2	élevé	moyen	bourg	non	non	non
3	faible	âgé	bourg	non	non	non
4	faible	moyen	bourg	oui	oui	oui
5	moyen	jeune	ville	oui	oui	oui
6	élevé	âgé	ville	oui	non	non
7	moyen	âgé	ville	oui	non	non
8	faible	moyen	village	non	non	non
9	moyen	âgé	village	oui	oui	non
10	élevé	jeune	ville	non	oui	oui
11	faible	âgé	village	non	non	non
12	moyen	moyen	bourg	oui	non	oui

## Arbres de Décision : Exercice

- Peut-on jouer au tennis ?


	Outlook	Temperature	Humidity	Windy	Play
1	sunny	hot	high	false	no
2	sunny	hot	high	true	no
3	overcast	hot	high	false	yes
4	rainy	mild	high	false	yes
5	rainy	cool	normal	false	yes
6	rainy	cool	normal	true	no
7	overcast	cool	normal	true	yes
8	sunny	mild	high	false	no
9	sunny	cool	normal	false	yes
10	rainy	mild	normal	false	yes
11	sunny	mild	normal	true	yes
12	overcast	mild	high	true	yes
13	overcast	hot	normal	false	yes
14	rainy	mild	high	true	no

## Organisation du cours

- Introduction
- Bases du KDD et du DM
- Bases de l'analyse des données
- Analyse factorielle
- Classification
- Clustering**
- Logique floue
- Réseaux de neurones artificiels
- Conclusion

## Clustering


- Principe: action de découper un ensemble d'objets en groupes (clusters) de telle sorte que les caractéristiques des objets dans un même cluster soient similaires et que les caractéristiques des objets dans des clusters différents soient distinctes



- Méthodes :
  - Clustering hiérarchique
  - K-means
  - Fuzzy C-means
  - Subtractive clustering
  - ...


## Le clustering hiérarchique

- Étape 1 : trouver les similarités entre paires d'objets
- Étape 2 : Grouper les objets sous la forme d'un arbre
- Étape 3 : Déterminer la coupe de l'arbre



## Le clustering hiérarchique

- Étape 1 : trouver les similarités entre toutes les paires d'objets



#Point	X1	X2
1	1.0000	2.0000
2	2.5000	4.5000
3	2.0000	2.0000
4	4.0000	1.5000
5	4.0000	2.5000

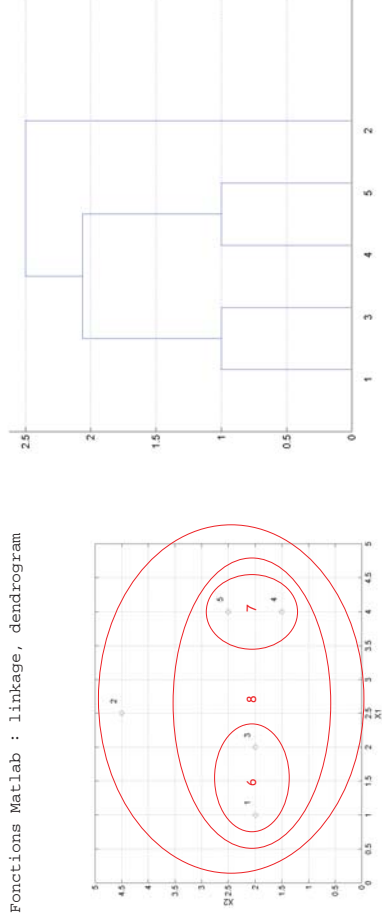
Distance entre les points					
	1	2	3	4	5
1					
2	1.0000				
3	2.9155	0			
4	1.0000	2.5495	0		
5	3.0414	3.3541	2.0616	0	

## Le clustering hiérarchique

- Étape 2 : Grouper les objets sous la forme d'un arbre

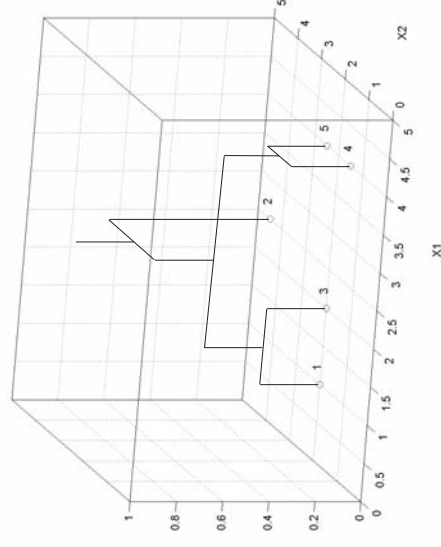
	point 1	point 2	distance
G1	1.0000	3.0000	1.0000
G2	4.0000	5.0000	1.0000
G3	6.0000	7.0000	2.0616
G4	8.0000	2.0000	2.5000

Fonctions Matlab : linkage, dendrogram



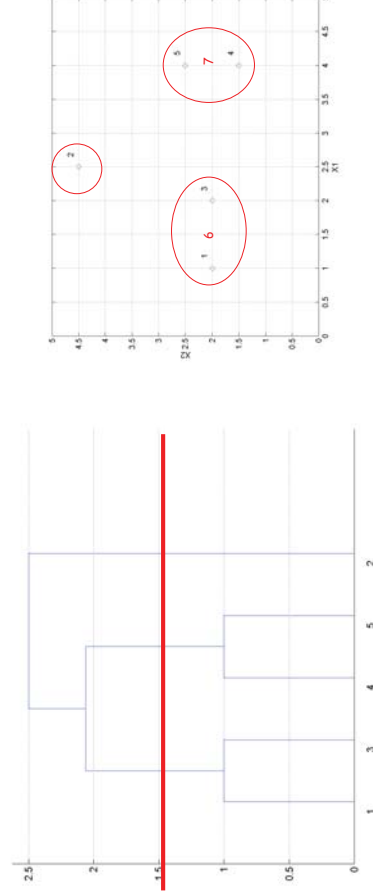
## Le clustering hiérarchique

- Étape 2 : Grouper les objets sous la forme d'un arbre



## Le clustering hiérarchique

- Étape 3 : Déterminer la coupe de l'arbre



## L'algorithme du K-means

- On considère l'espace de  $n$  points de dimension  $p$  suivant :

$$X = \begin{matrix} X^1 & \dots & X^j & \dots & X^p \\ X_1^1 & \dots & X_1^j & \dots & X_1^p \\ \dots & \dots & \dots & \dots & \dots \\ X_i^1 & \dots & X_i^j & \dots & X_i^p \\ \dots & \dots & \dots & \dots & \dots \\ X_n^1 & \dots & X_n^j & \dots & X_n^p \end{matrix}$$

- On suppose que les  $n$  points peuvent être groupés en  $c$  clusters  $c < n$
- Les clusters sont décrits par leurs centres

$$V_k = [v_k^1, v_k^2, \dots, v_k^j, \dots, v_k^p], 1 \leq k \leq c$$

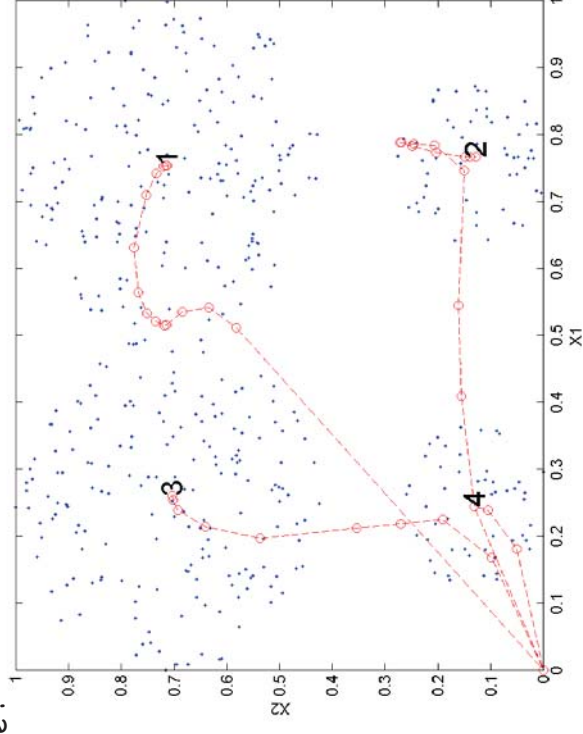
- On note  $d(i,k)$  la distance entre le point  $X_i$  et le centre  $V_k$
- Le point  $X_i$  appartient au cluster dont le centre est le plus proche
- On note  $m_k$  la moyenne des vecteurs dans le cluster  $k$

## L'algorithme du K-means

- Algorithme :
  - Initialiser la position des centres :  $V_k = [v_k^1, v_k^2, \dots, v_k^d], 1 \leq k \leq c$
  - Calculer les  $m_k$
  - Jusqu'à ce qu'il n'y ait plus de changement sur les  $m_k$
- Faire
  - Chaque point  $X_i$  est affecté au cluster le plus proche
  - Calculer les nouveaux  $m_k$
- Fin Jusqu'à

## L'algorithme du K-means

- Exemple :




## L'algorithme du K-means

- Algorithme très simple mais :
  - L'initialisation des positions des centres conditionne le résultat final (cf. transparent suivant)
  - Il peut arriver qu'un cluster soit vide
  - Le résultat dépend de la métrique utilisée pour calculer les distances
  - Le nombre de clusters  $k$  doit être fixé a priori

## L'algorithme du K-means

- Exemple :



## Organisation du cours

- Introduction
- Bases du KDD et du DM
- Bases de l'analyse des données
- Analyse factorielle
- Classification
- Clustering
- Logique floue**
- Réseaux de neurones artificiels
- Conclusion

## Introduction

Traiter plus efficacement, et/ou plus simplement des problèmes que l'informatique classique peinait à résoudre :  
Classification, Contrôle de processus ...

### Années 60 - Lofti Zadeh : Sous-ensembles Flous

Base formelle pour le traitement des

- Incertitudes
- Imprécisions
- Incomplétudes

Interface entre :

- l'information numérique (quantitatif)
- et l'information symbolique (qualitatif)

### Années 70/80 - Raisonnement Flou - Logique Floue


Premières applications industrielles

## Introduction

- **Imprécisions** (vague, flou, général, ambigu)  
Difficultés dans l'énoncé de la connaissance  
"2000 à 3000 manifestants"  
"à peu près 1kg"  
"environ 1m80"
- **Incertitudes**  
Doutes sur la validité d'une connaissance  
"je crois que la voiture était blanche"
- **Incomplétudes**  
Absences de connaissances ou connaissances partielles


## Objectif

Interface entre :  
l'information numérique (quantitatif)  
et l'information symbolique (qualitatif)




## Concepts de base : Définitions

Un sous ensemble classique A de X est défini par une fonction caractéristique  $X_A$



Un sous ensemble flou A de X est défini par une fonction d'appartenance  $F_A$



Notation :

$$A = \sum_{x \in X} F_A(x) / x \quad \text{si } X \text{ est dénombrable}$$


$$A = \int F_A(x) / x \quad \text{si } X \text{ est indénombrable}$$

## Concepts de base : Fonction d'appartenance

- Triangle

$$F_A(x; a, b, c, d) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{c-a}, & a \leq x \leq b \\ \frac{c-x}{c-b}, & b \leq x \leq c \\ 0, & c \leq x \end{cases}$$

$$F_A(x; a, b, c, d) = \max \left( \min \left( \frac{x-a}{b-a}, \frac{c-x}{c-b} \right), 0 \right)$$



## Concepts de base : Fonction d'appartenance



Support de A :  $\text{supp}(A) = \{x \in X / F_A(x) \neq 0\}$

Noyau de A :  $\text{noy}(A) = \{x \in X / F_A(x) = 1\}$

Hauteur de A :  $h(A) = \sup_{x \in X} (F_A(x))$

Cardinalité de A :  $|A| = \sum_{x \in X} F_A(x)$


$\alpha$  - coupe de A :  $A_\alpha = \{x \in X / F_A(x) \geq \alpha\}$

## Concepts de base : Fonction d'appartenance

- Trapèze

$$F_A(x; a, b, c, d) = \begin{cases} 0, & x \leq a \\ \frac{x-a}{b-a}, & a \leq x \leq b \\ 1, & b \leq x \leq c \\ \frac{d-x}{d-c}, & c \leq x \leq d \\ 0, & d \leq x \end{cases}$$

$$F_A(x; a, b, c, d) = \max \left( \min \left( \frac{x-a}{b-a}, 1, \frac{d-x}{d-c} \right), 0 \right)$$





## Concepts de base : Fonction d'appartenance

- Gaussienne

$$F_A(x; \sigma, m) = e^{-\frac{(x-m)^2}{2\sigma^2}}$$

- Cloche

$$F_A(x; a, b, c) = \frac{1}{1 + \left| \frac{x-c}{a} \right|^{2b}}$$




## Concepts de base : Nombre flou

**Définition** : un nombre flou est un sous-ensemble flou dont la fonction d'appartenance est normale et convexe.

- $F_A$  est une fonction d'appartenance convexe ssi :

$$\forall (x, y) \in \mathbb{R} \times \mathbb{R}, \forall z \in [x, y] \quad F_A(z) \geq \min(F_A(x), F_A(y))$$

- $F_A$  est une fonction d'appartenance normale ssi :  $h(A)=1$



## Concepts de base : Norme Triangulaire

Une **norme triangulaire** (t-norme) est une fonction

$T : [0, 1] \times [0, 1] \rightarrow [0, 1]$  qui vérifie pour tous a, b, c et d de  $[0, 1]$

- $T(0,0)=0$  et  $T(1,1)=1$
- $T(a,1)=T(1,a)=a$
- $T(a,b)=T(b,a)$
- $T(a,b) \leq T(c,d)$  si  $a \leq c$  et  $b \leq d$
- $T(a, T(b,c))=T(T(a,b),c)$

conditions aux limites  
élément neutre  
commutativité  
monotonie  
associativité

Exemple :  $T(a,b)=\min(a,b)$

## Concepts de base : Conorme Triangulaire

Une **conorme triangulaire** (t-conorme) est une fonction

$S : [0, 1] \times [0, 1] \rightarrow [0, 1]$  qui vérifie pour tous a, b, c et d de  $[0, 1]$

- $S(1,1)=1$  et  $S(0,0)=0$
- $S(a,0)=S(0,a)=a$
- $S(a,b)=S(b,a)$
- $S(a,b) \leq S(c,d)$  si  $a \leq c$  et  $b \leq d$
- $S(a, S(b,c))=S(S(a,b),c)$

conditions aux limites  
élément neutre  
commutativité  
monotonie  
associativité

Exemple :  $S(a,b)=\max(a,b)$

## Concepts de base : Norme et Conorme Triangulaire

- **Dualité**  
 $S(a,b) = 1 - T(1-a, 1-b)$   
 $T(a,b) = 1 - S(1-a, 1-b)$
- **Exemples**  
 $S(a,b) = \max(a,b)$   
 $S(a,b) = a+b-ab$   
 $T(a,b) = \min(a,b)$   
 $T(a,b) = ab$
- **Utilisation**  
 Opérateur de conjonction  $\cap$  : T-norme  
 Opérateur de disjonction  $\cup$  : T-conorme

## Concepts de base : Norme et Conorme Triangulaire

- Principales t-normes et t-conormes duales

Nom	T-norme	T-conorme	Négation
Zadeh	$\min(x,y)$	$\max(x,y)$	$1-x$
Probabiliste	$xy$	$x+y-xy$	$1-x$
Lukasiewicz	$\max(x+y-1,0)$	$\min(x+y,1)$	$1-x$
Hamacher $\gamma > 0$	$\frac{xy}{\gamma + (1-\gamma)(x+y-xy)}$	$\frac{x+y-xy-(1-\gamma)xy}{1-(1-\gamma)xy}$	$1-x$
Weber	$\begin{cases} x \text{ si } y = 1 \\ y \text{ si } x = 1 \\ 0 \text{ sinon} \end{cases}$	$\begin{cases} x \text{ si } y = 0 \\ y \text{ si } x = 0 \\ 1 \text{ sinon} \end{cases}$	$1-x$



## Concepts de base : Opérations

- Soit A et B deux sous ensembles flous de X et x un élément de X

- **Égalité**  
 $A = B \text{ ssi } \forall x \in X : F_A(x) = F_B(x)$

- **Inclusion**  
 $B \subset A \text{ ssi } \forall x \in X : F_A(x) \geq F_B(x)$


- **Complément**  
 $\bar{A}$  est défini  $\forall x \in X$  par :  
 $F_{\bar{A}}(x) = 1 - F_A(x)$




## Concepts de base : Opérations

- Soit A et B deux sous ensembles flous de X et x un élément de X

- **Intersection**  $C = A \cap B \text{ ssi } \forall x \in X : F_C(x) = \min(F_A(x), F_B(x))$



- **Union**  $C = A \cup B \text{ ssi } \forall x \in X : F_C(x) = \max(F_A(x), F_B(x))$



## Concepts de base : Relation Floue

### • Produit Cartésien :

Soient  $r$  sous-ensembles flous  $A_1, A_2, \dots, A_r$ , respectivement définis sur  $X_1, X_2, \dots, X_r$ , on définit leur produit cartésien  $A = A_1 \times A_2 \times \dots \times A_r$ , comme un sous-ensemble flou de  $X$  de fonction d'appartenance :

$$\forall x = (x_1, x_2, \dots, x_r) \in X, F_A(x) = \min(F_{A_1}(x_1), F_{A_2}(x_2), \dots, F_{A_r}(x_r))$$


### • Relation floue :

Une relation floue entre  $r$  ensembles de référence  $X_1, X_2, \dots, X_r$ , est un sous-ensemble flou de  $X_1 \times X_2 \times \dots \times X_r$ , de fonction d'appartenance  $F_R$ .

## Concepts de base : Relation Floue

**Exemple :** Relation floue traduisant "x est proche de y".

$$F_R(x, y) = e^{-k(x-y)^2}, \forall (x, y) \in \mathbb{R} \times \mathbb{R}, k > 0$$




## Concepts de base : Fuzzification - Variable Linguistique

### Définition

- Soit une variable  $E$  définie sur un univers de discours  $X$ , et  $T_E$  un ensemble de qualificatifs linguistiques ou ensemble des termes, caractérisant la variable  $E$
- Une variable linguistique est formée du triplet  $(E, X, T_E)$

**Exemple :** (Température, [0,40], {Froide, Moyenne, Chaude})



## Concepts de base : Fuzzification en tableau

**Exemple :** (Température, [0,40], {Froide, Moyenne, Chaude})

Température	Froide	Moyenne	Chaude
0,00	1,00	0,00	0,00
2,00	1,00	0,00	0,00
4,00	1,00	0,00	0,00
6,00	0,93	0,00	0,00
8,00	0,80	0,00	0,00
10,00	0,67	0,00	0,00
12,00	0,53	0,20	0,00
14,00	0,40	0,40	0,00
16,00	0,27	0,60	0,00
18,00	0,13	0,80	0,00
20,00	0,00	1,00	0,00
22,00	0,00	0,80	0,13
24,00	0,00	0,60	0,27
26,00	0,00	0,40	0,40
28,00	0,00	0,20	0,53
30,00	0,00	0,00	0,67
32,00	0,00	0,00	0,80
34,00	0,00	0,00	0,93
36,00	0,00	0,00	1,00
38,00	0,00	0,00	1,00
40,00	0,00	0,00	1,00

## Système d'inférence floue (SIF)

- Petits rappels de logique classique

p	$\bar{p}$
0	1
1	0

NON

p	q
0	0
1	0
0	1
1	1

ET

p	q
0	0
1	1
0	1
1	1

OU

p	q
0	0
1	1
0	1
1	0

Implication

$p \rightarrow q$

Modus ponens

SI	p	$\rightarrow$	q	vrai
et	p		q	vrai
alors	q		q	vrai

Modus tollens

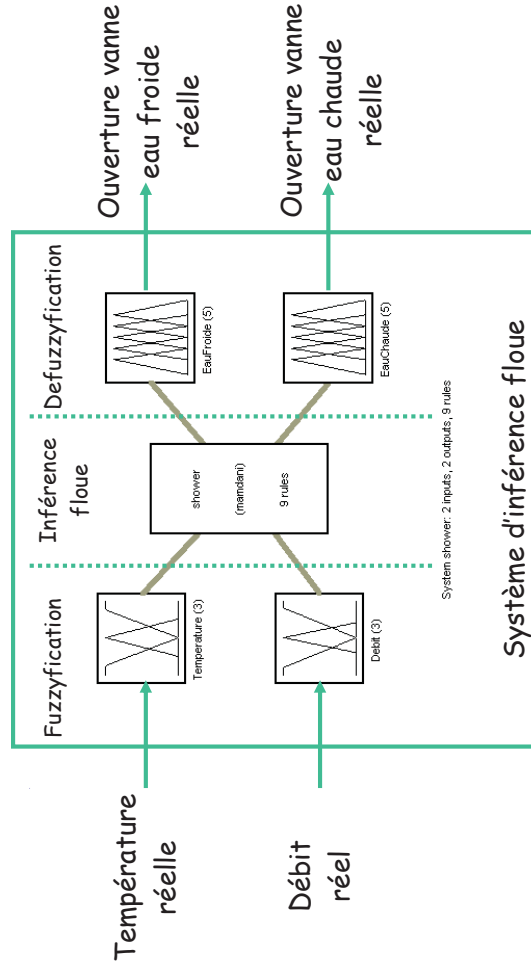
SI	p	$\rightarrow$	q	vrai
et	q		q	faux
alors	p		p	faux

## Système d'inférence floue

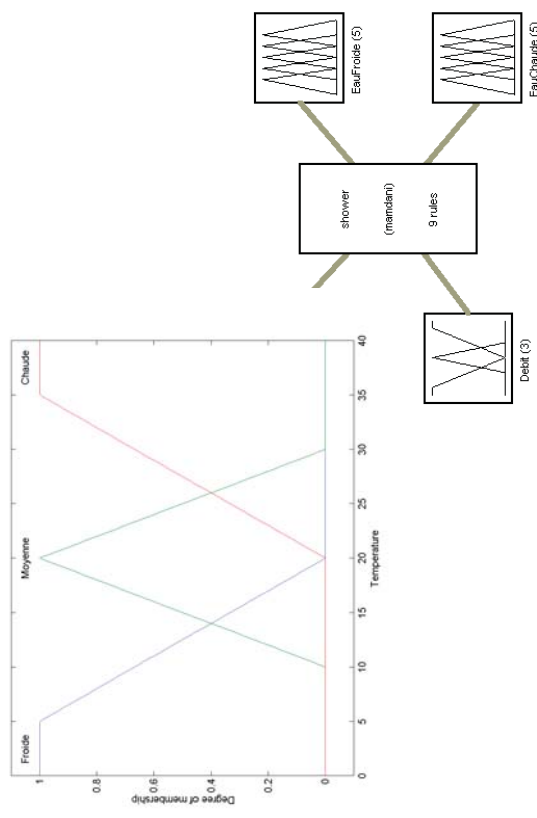
- Voici un exemple de relation d'implication :  
« il fait beau »  $\rightarrow$  « je suis heureux ».  
Cette proposition est vraie si je suis toujours heureux quand il fait beau.
- A ne pas confondre avec la relation d'équivalence ( $\leftrightarrow$ ) qui elle implique que je ne soit heureux QUE lorsqu'il fait beau.
- La relation d'implication représente le SI une condition suffisante dans un sens, une condition nécessaire dans l'autre : dans  $A \rightarrow B$ , A est une condition suffisante de B, et B est une condition nécessaire de A
- la relation d'équivalence représente le SI ET SEULEMENT SI ( $\leftrightarrow$ ), une condition nécessaire et suffisante ;  
 $A \leftrightarrow B$  équivaut à  $(A \rightarrow B)$  ET  $(B \rightarrow A)$

## Système d'inférence floue (SIF)

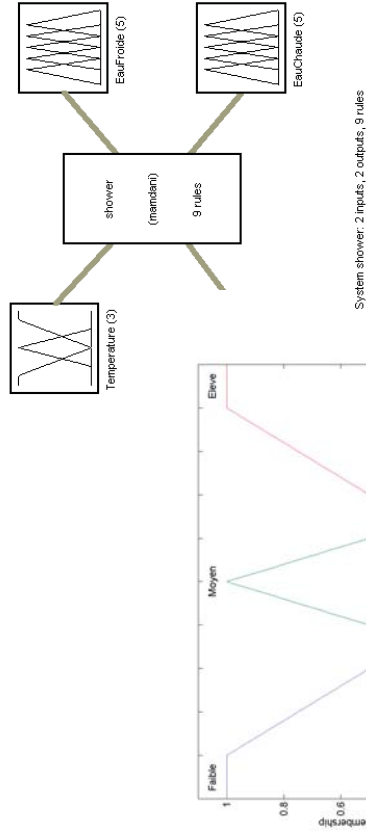
- Un exemple



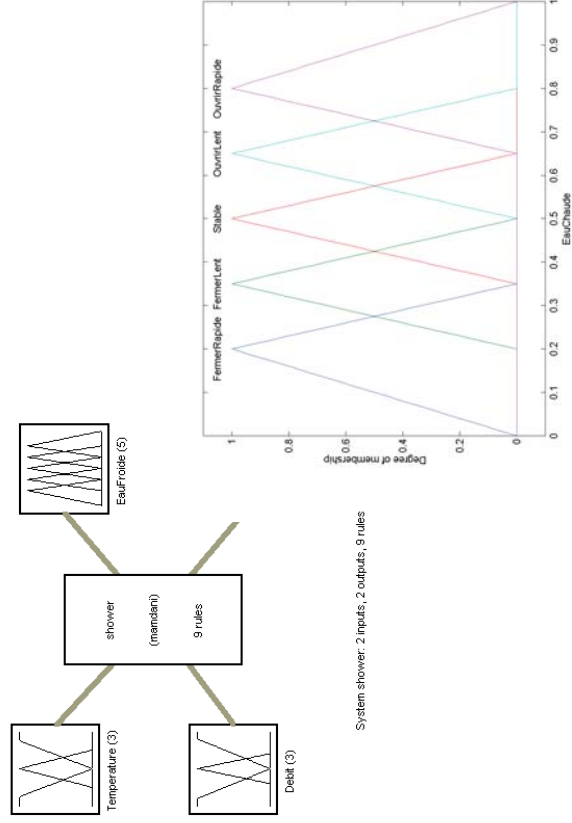
## Système d'inférence floue (SIF)



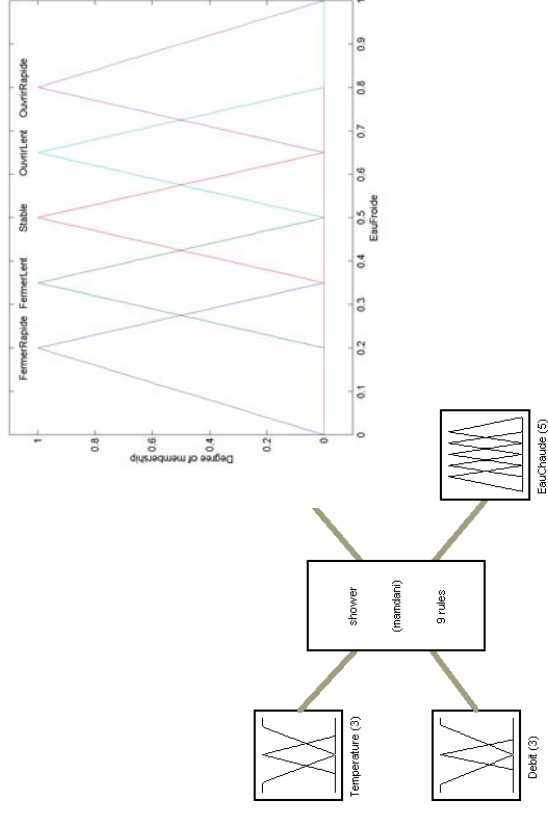
## Système d'inférence floue (SIF)



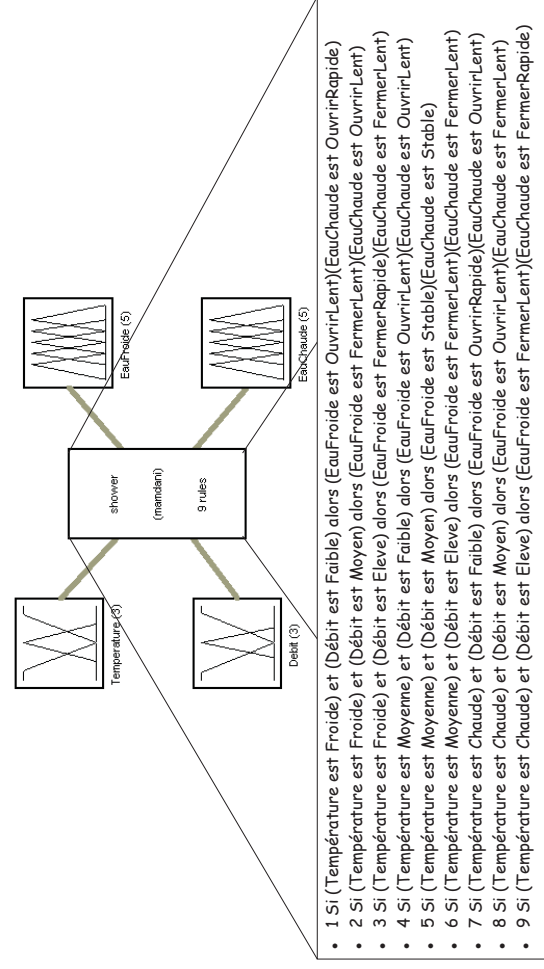
## Système d'inférence floue (SIF)



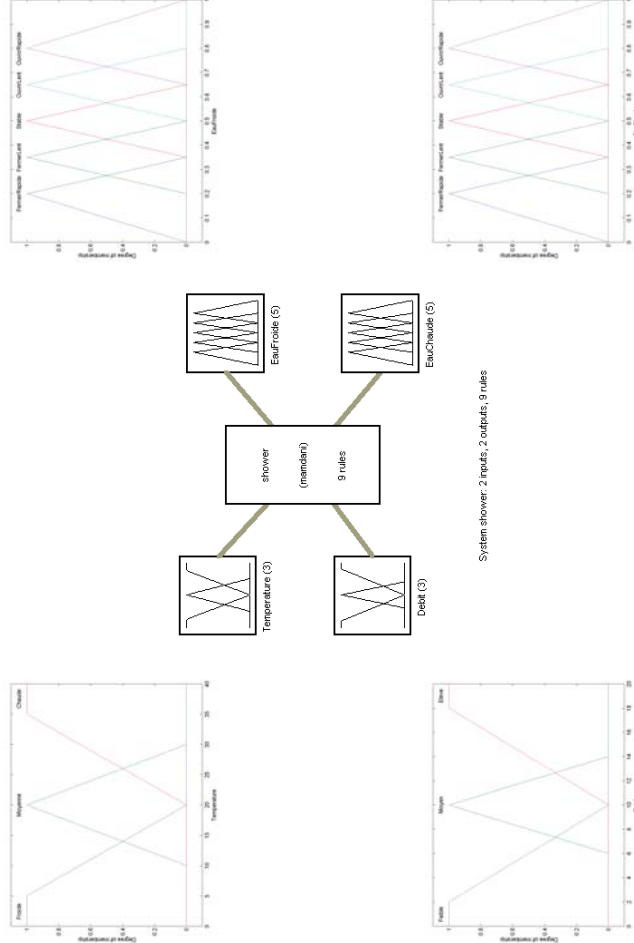
## Système d'inférence floue (SIF)



## Système d'inférence floue (SIF)




## Système d'inférence floue (SIF)

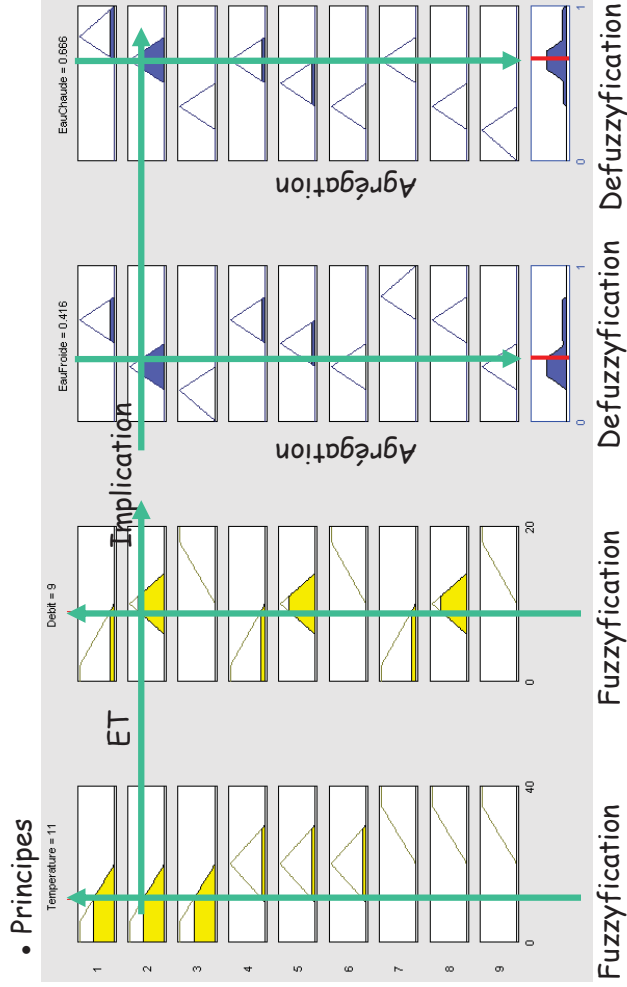


## Système d'inférence floue (SIF)

- Interface MATLAB commande fuzzy



## Système d'inférence floue (SIF)



- Principes

## SIF : Proposition Floue

- Une **proposition floue** s'exprime à partir d'une variable linguistique ( $E, X, T_E$ ) sous la forme "E est A", pour un terme de  $T_E$ , ou en appliquant un modificateur linguistique sur un élément de l'ensemble des termes.
- Exemples :
  - "L'âge est adulte"
  - "La température est très froide"

## SIF : Règles Floues

- Les **règles floues** expriment un lien entre des propositions floues élémentaires ou des conjonctions de propositions élémentaires :

Si E est A alors U est B

Si E' est A' ET E'' est A'' ET ... alors U est B

Exemples :

"Si Température est Froide alors Vanne\_Eau\_Chaude est Ouvrir\_rapide"

"Si Température est Chaude ET Débit est faible alors Vanne\_Eau\_Chaude est Fermer\_lent"

## SIF : Opérateurs d'implication

### • Opérateurs d'implication floue

- Opérateur de Reichenbach  $I(a,b) = 1 - a + ab$
- Opérateur de Willmott  $I(a,b) = \max(1 - a, \min(a,b))$
- Opérateur de Rescher-Gaines  $I(a,b) = \begin{cases} 1 & \text{si } a \leq b \\ 0 & \text{si } a > b \end{cases}$
- Opérateur de Kleene-Dienes  $I(a,b) = \max(1 - a, b)$

## SIF : Opérateurs logiques

### • Opérateurs Logiques

Classiques	Flous
ET	T-norme
OU	T-conorme
NON	négation
$\forall$	inf
$\exists$	sup
Implication	Implication floue

## SIF : Opérateurs d'implication

### • Opérateurs d'implication floue

- Opérateur de Brouwer-Gödel  $I(a,b) = \begin{cases} 1 & \text{si } a \leq b \\ b & \text{si } a > b \end{cases}$
- Opérateur de Goguen  $I(a,b) = \begin{cases} 1 & \text{si } a = 0 \\ \min(b/a, 1) & \text{si } a \neq 0 \end{cases}$
- Opérateur de Lukasiewicz  $I(a,b) = \min(1 - a + b/a, 1)$
- Opérateur de Mamdani  $I(a,b) = \min(a,b)$
- Opérateur de Larsen  $I(a,b) = ab$

## SIF : Modus Ponens Binaire et Généralisé

### • Modus Ponens Binaire

prémisse1	Si E	→ U	vrai
prémisse2	Et E		vrai
Conclusion			Alors U
			vrai

### • Modus Ponens Généralisé

Expressions linguistiques		Opérateurs	
prémisse1	Si E est A	Alors	U est B
prémisse2	Or E est A'		
Conclusion		Donc	U est B'
			Proposition Floue

## SIF : Modus Ponens Généralisé

### Décomposition du Modus Ponens Généralisé

<b>Règle</b>	<b>Si</b>	<b>E est A</b>	<b>Alors U est B</b>
Univers	X	F <sub>A</sub> (x)	Y
Fonctions d'appartenance		F <sub>A</sub> (x)	F <sub>B</sub> (y)
<b>Observation</b>	<b>E est A'</b>		
Univers	X		
Fonction d'appartenance	F <sub>A</sub> (x)		
<b>Conclusion</b>			<b>U est B'</b>
Univers			Y
Fonction d'appartenance			F <sub>B</sub> (y)

## SIF : Modus Ponens Généralisé

### Calcul de F<sub>B</sub>(Y)

#### Règle Floue

Calcul de la relation floue R décrivant le lien causal entre les valeurs de E et celles de U, à l'aide d'un opérateur d'implication floue

#### Proposition floue

Pour l'observation E est A', on détermine la fonction d'appartenance F<sub>A</sub>(x)

#### Proposition floue

Pour tous les y de Y F<sub>B</sub>(y) = sup<sub>x ∈ X</sub> T(F<sub>A</sub>(x), R(x,y))

T est une t-norme appelée opérateur de modus ponens généralisé

## SIF : Modus Ponens Généralisé

### • Choix de T opérateur de modus ponens généralisé

Le choix de T doit rendre le modus ponens généralisé compatible avec le modus ponens ordinaire, c'est à dire que l'on doit obtenir F<sub>B</sub>' identique à F<sub>B</sub> dès que F<sub>A</sub>' est identique à F<sub>A</sub>.

Les choix possibles sont :

Opérateurs T	Implication R
Lukasiewicz : T(u, v) = max(u + v - 1, 0)	Reichenbach, Willmott, Rescher-Gaines, Kleene-Dienes, Brouwer-Gödel, Goguen, Lukasiewicz, Mamdani, Larsen
Zadeh : T(u, v) = min(u, v)	Rescher-Gaines, Brouwer-Gödel, Mamdani, Larsen
Probabiliste : T(u, v) = u.v	Rescher-Gaines, Brouwer-Gödel, Goguen, Mamdani, Larsen

## SIF : Modus Ponens Généralisé



- **Exemple:**
- Si la Température est Froide alors EauChaude est OuvrirRapide
- Or la Température est de 11 °C
- Donc EauChaude est ?

## SIF : Modus Ponens Généralisé

### Règle Floue

R : Si la Température est Froide Alors EauChaude est OuvrirRapide  
 Si E est A Alors U est B  
 Univers [0°C, 40°C] [0,1]  
 Appartenance  $F_A(x)$   $F_B(y)$

Opérateur d'implication :  $\min(F_A(x), F_B(y))$




## SIF : Modus Ponens Généralisé

**Proposition floue :** Or la Température est de 11 °C ,  $F_A(x)$

$$F_B(y) = \sup_{x \in X} [T(F_A(x), R(x,y))]$$


Choix de l'opérateur de modus ponens généralisé : Zadeh  $T = \min(u,v)$

$$\begin{aligned} F_B(y) &= \sup_{x \in X} [\min(F_A(x), \min(F_A(x), F_B(y)))] \\ &= \sup_{x \in X} [\min(F_A(x), F_A(x), F_B(y))] \\ &= \min(\sup_{x \in X} [\min(F_A(x), F_A(x))], F_B(y)) \end{aligned}$$



## SIF : Modus Ponens Généralisé

**Proposition floue :** Or la Température est de 11 °C ,  $F_A(x)$





### SIF : Modus Ponens Généralisé

• Un autre exemple :

- Si la Distance est courte alors le Freinage est Puissant
- Or la distance est de 70m
- Or la Distance est d'environ 100m
- Donc le Freinage est ?

### SIF : Modus Ponens Généralisé

**Règle Floue R :**  
 Si la Distance est Courte  
 E est A  
 [0m, 120m]  
 F<sub>A</sub>(x)  
 Alors  
 U est B  
 [0N, 100N]  
 F<sub>B</sub>(y)




### SIF : Modus Ponens Généralisé

• Propositions floues :

Or la distance est de 70m F<sub>A</sub>'(x)  
 E est A'

Or la Distance est d'environ 100m F<sub>A</sub>''(x)  
 E est A''





### SIF : Modus Ponens Généralisé

Proposition floue : Or la distance est de 70m, F<sub>A</sub>'(x)


$$F_B(y) = \sup_{x \in X} [\min(F_A'(x), R(x, y))] = \sup_{x \in X} [\min(F_A'(x), \min(F_A(x), F_B(y)))]$$

$$= \sup_{x \in X} [\min(F_A'(x), F_A(x), F_B(y))] = \min(\sup_{x \in X} [\min(F_A'(x), F_A(x))], F_B(y))$$




### SIF : Modus Ponens Généralisé

Proposition floue : Or la distance est de 70m,  $F_A(x)$



### SIF : Modus Ponens Généralisé


Proposition floue : Or la Distance est d'environ 100m,  $F_A(x)$



### SIF : Modus Ponens Généralisé

Proposition floue : Or la Distance est d'environ 100m,  $F_A(x)$

$$F_{B'}(y) = \sup_{x \in X} T(F_{A'}(x), R(x, y)) = \sup_{x \in X} [\min(\min(F_{A'}(x), F_A(x)), F_B(y))] = \min(\sup_{x \in X} [\min(F_{A'}(x), F_A(x))], F_B(y))$$




### SIF : Modus Ponens Généralisé

- Exemple une règle avec plusieurs prémices :
- Si (Température est Froide) ET (Débit est Faible) alors (EauChaude est OuvrirRapide)
- Or la Température est de 11 °C ET le débit est 1m3/mn
- Donc EauChaude est ?

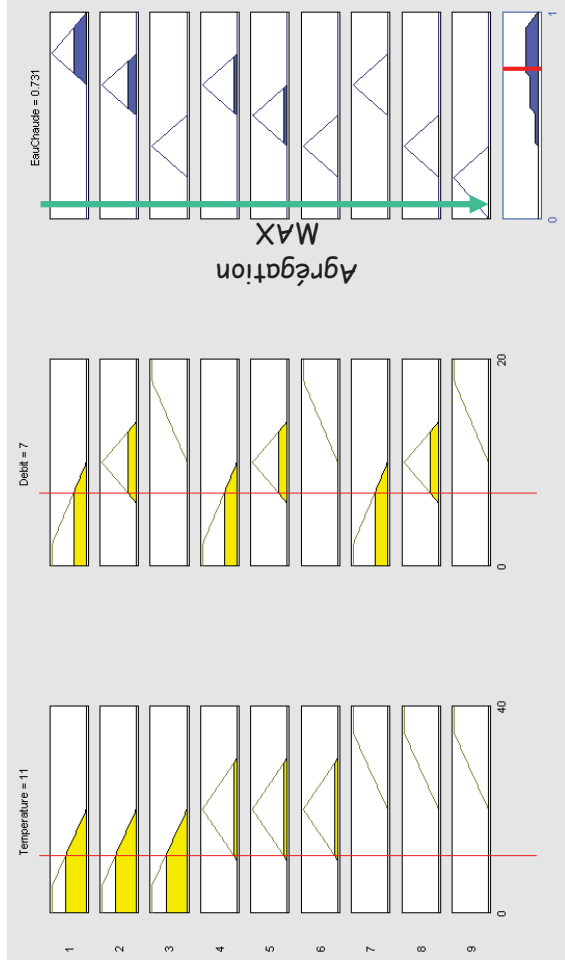
### SIF : Déduction floue

- Mécanisme de déduction




### SIF : Déduction floue

- Exemple : plusieurs règles avec plusieurs prémices



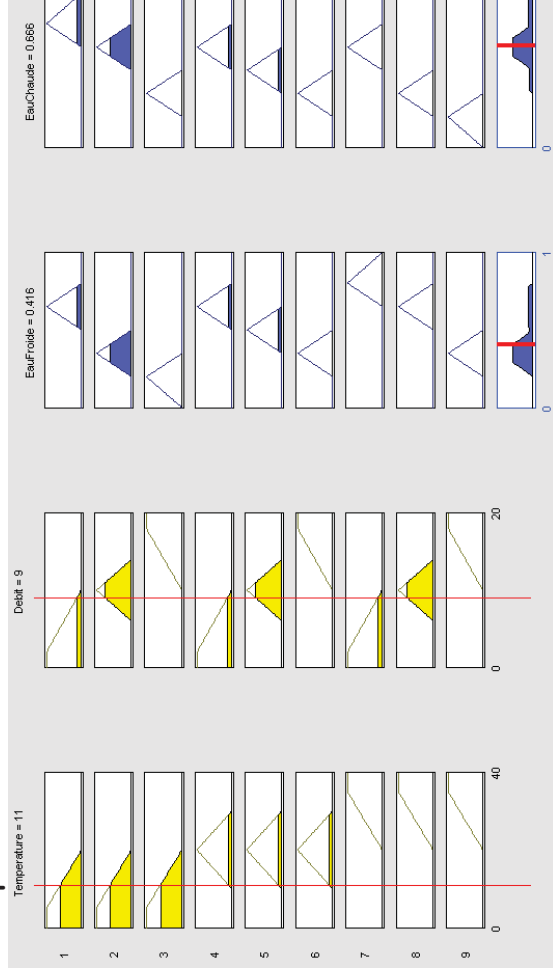
### SIF : Déduction floue

- Exemple : plusieurs règles avec plusieurs prémices




### SIF : Déduction floue

- Exemple : plusieurs règles avec plusieurs prémices et plusieurs conclusions




## SIF : Dédution floue

- Exemple : plusieurs règles avec plusieurs prémices et plusieurs conclusions




## SIF : Defuzzification



- Centroid : barycentre de la surface
- Bisector : bissectrice de la surface
- Som smallest of maximum : plus petite valeur des maxima
- Mom mean of maximum : moyenne des maxima
- Lom largest of maximum : plus grande valeur des maxima

## SIF : Dédution floue

- Exemple : plusieurs règles avec plusieurs prémices et plusieurs conclusions



## SIF : types de modèles classiques

### • MODELE DE TYPE MADMANI

Les règles sont du type :

SI x est A et y est B alors z est C

Modélisation intuitive

Adapté au raisonnement humain

### • MODELE DE TYPE SUGENO

Les règles sont du type:

Si x est A et y est B alors B alors  $z=f(x,y)$

Sugeno d'ordre 0 :  $f(x,y)=k$


Sugeno d'ordre 1 :  $f(x,y)=p.x+q.y+r$

Efficacité de calcul

Bonne performance

Garantie continuité des sorties

## SIF : Obtention des règles




## Clustering flou

• Méthode de Clustering


• Méthode : « Subtractive clustering » (SC)

• Méthode : « Fuzzy C-means » (FCM)



## Clustering flou : Subtractive clustering


Exemple : échantillon 300 individus, 3 caractères



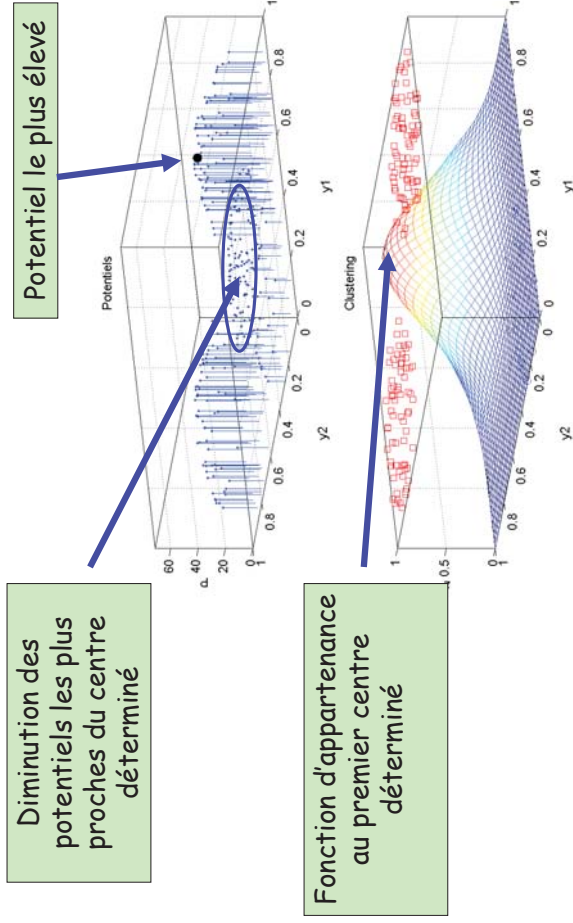
## Clustering flou : Subtractive clustering

Potentiel d'un point:  
fonction du nombre  
de voisins et de leurs  
distances

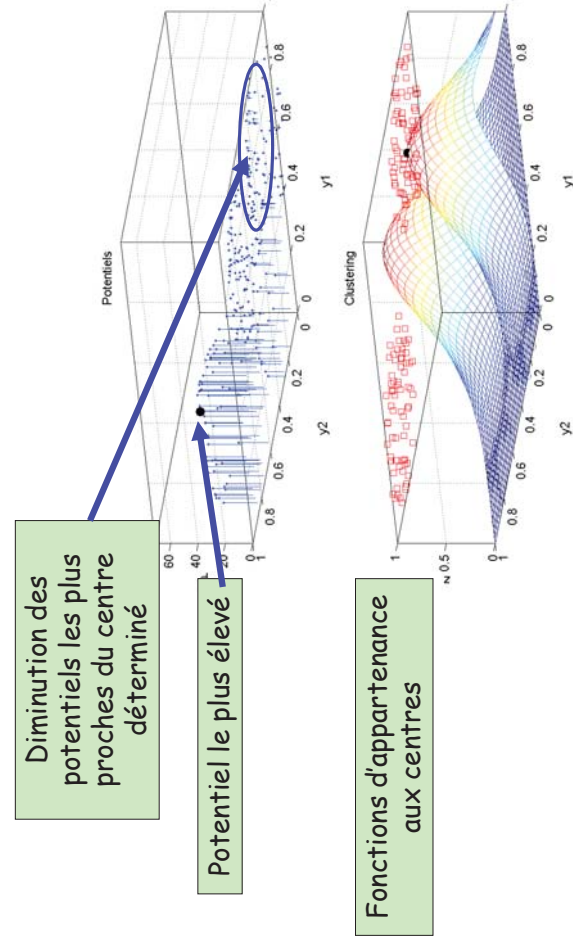
Potentiel le plus élevé  
Détermine le premier centre




### Clustering flou : Substructive clustering




### Clustering flou : Substructive clustering



### Clustering flou : Substructive clustering




### Clustering flou : Substructive clustering




### Clustering flou : Substructive clustering

Résultat du clustering




### Clustering flou : Substructive clustering

Fonctions d'appartenance associées à chaque centre




### Clustering flou : Substructive clustering

Pondération des fonctions d'appartenance par les valeurs des sorties



### Clustering flou : Substructive clustering

Identification du SIF Final




## Clustering flou : Substructive clustering

- Format des données

n points    m entrées/sorties    p entrées    m-p sorties

$$X = \begin{bmatrix} [X_1] & \dots & [X_j] & \dots & [X_n] \\ x_1^1 & \dots & x_1^j & \dots & x_1^n \\ \dots & \dots & \dots & \dots & \dots \\ x_j^1 & \dots & x_j^j & \dots & x_j^n \\ \dots & \dots & \dots & \dots & \dots \\ x_m^1 & \dots & x_m^j & \dots & x_m^n \end{bmatrix} = \begin{bmatrix} Y \\ Z \end{bmatrix}$$



m-p sorties

$$\begin{bmatrix} Y_1 \\ Z_1 \\ \dots \\ Y_j \\ Z_j \\ \dots \\ Y_n \\ Z_n \end{bmatrix} \dots \begin{bmatrix} Y_1^n \\ Z_1^n \\ \dots \\ Y_j^n \\ Z_j^n \\ \dots \\ Y_n^n \\ Z_n^n \end{bmatrix}$$

## Clustering flou : Substructive clustering


- Algorithme de clustering

$$1) \quad k=0 \\ P_i = \sum_{j=1}^n e^{-\alpha \|x_j - x_i\|^2}, \alpha = \frac{4}{r_a^2}$$

- 2)  $k=k+1$   
Choisir le point avec le  $P_i$  le plus grand  
Ce point devient un centre :  
Coordonnées :  $x_k^*$ , et de potentiel :  $P_k^*$


$$3) \quad \text{Modifier les } P_i : \\ P_i = P_i - P_k^* e^{-\beta \|x_i - x_k^*\|^2}, \beta = \frac{4}{r_b^2}$$

- 4) Répéter 2 et 3 jusqu'à :  $P_k^* < \varepsilon P_1^*$



## Clustering flou : Substructive clustering

- Identification du modèle mathématique



$$\mu_i(Y) = e^{-\alpha \|Y - Y_i^*\|^2}$$

$$Z(Y) = \frac{\sum_{i=1}^c \mu_i(Y) Z_i^*}{\sum_{i=1}^c \mu_i(Y)}$$

c : nombre de clusters

## Clustering flou : Substructive clustering

## Clustering flou : Substructive clustering

- Identification du SIF

- A chaque centre  $X_k^*$  est associé une règle floue  
Si  $y_1^k$  est  $A_1^k$  et  $y_2^k$  est  $A_2^k$  et ... alors  $z_1^k$  est  $B_1^k$  et  $z_2^k$  est  $B_2^k$  et ...

- Pour la kème règle associée à  $X_k^*$

Les  $A_i^k$  sont des fonctions d'appartenance exponentielle  $A_i^k(q) = e^{-\alpha \|q - y_i^k\|^2}$   
les  $B_i^k$  sont des singletons  $B_i^k = z_i^k$

## Clustering flou : Substructive clustering

- Optimisation d'ordre 0

$$z_i^* = G_i \gamma + h_i$$


- Optimisation d'ordre 1

$$z_i^* = h_i$$

## Clustering flou : Substructive clustering


- Un exemple d'application : prévision de série chronologique

Première étape : pré traitement des données




## Clustering flou : Substructive clustering

Deuxième étape : Clustering




## Clustering flou : Substructive clustering

Deuxième étape : Clustering




## Clustering flou : Substructive clustering

Troisième étape : Modélisation




## Clustering flou : Substructive clustering

Troisième étape : Modélisation




## Clustering flou : Substructive clustering

Résultats



## Clustering flou : Substructive clustering

Quatrième étape : identification du SIF



SI  $z(t)$  est Faible ALORS  $z(t+10)$  est 0  
 SI  $z(t)$  est Moyen ALORS  $z(t+10)$  est 0.3  
 SI  $z(t)$  est Elevé ALORS  $z(t+10)$  est 0.78

## Clustering flou : Substructive clustering

- Algorithme efficace et peu complexe mais :
- Les paramètres  $\{r_a, r_b, \varepsilon\}$  sont difficiles à estimer
- Les clusters sont tous de la même forme
- Les clusters sont tous de la même taille

## Clustering flou

- Méthode de Clustering
  - Méthode : « Substructive clustering » (SC)
  - Méthode : « Fuzzy C-means » (FCM)



## Clustering flou : Fuzzy C-means

- Algorithme inspiré du k-means
- On considère l'espace de  $n$  points de dimension  $p$  suivant :

$$X : \begin{matrix} X_1 & \dots & X^j & \dots & X^p \\ x_1^1 & \dots & x_1^j & \dots & x_1^p \\ \dots & \dots & \dots & \dots & \dots \\ x_k^1 & \dots & x_k^j & \dots & x_k^p \\ \dots & \dots & \dots & \dots & \dots \\ x_n^1 & \dots & x_n^j & \dots & x_n^p \end{matrix}$$

- On suppose que les  $n$  points peuvent être groupés en  $c$  clusters  $c < n$
- Les clusters sont déterminés par leurs centres

$$V_i = [v_i^1, v_i^2, \dots, v_i^p], 1 \leq i \leq c$$

## Clustering flou : Fuzzy C-means

- On considère la matrice de proximité suivante :

$$U = \begin{bmatrix} u_{11} & \dots & u_{1k} & \dots & u_{1n} \\ \dots & \dots & \dots & \dots & \dots \\ u_{i1} & \dots & u_{ik} & \dots & u_{in} \\ \dots & \dots & \dots & \dots & \dots \\ u_{c1} & \dots & u_{ck} & \dots & u_{cn} \end{bmatrix}, \text{ avec } k = 1, \dots, n \text{ et } i = 1, \dots, c$$

$u_{ik}$  représente le degré d'appartenance du point  $X_k$  au centre  $V_i$

$$u_{ik} = \left[ \sum_{j=1}^c \left( \frac{d_{ik}^2}{d_{jk}^2} \right)^{m-1} \right]^{-1}, d_{ik} \text{ représente la distance entre } V_i \text{ et } X_k$$

$$u_{ik} = \left[ \sum_{j=1}^c \left( \frac{\|X_k - V_i\|^2}{\|X_k - V_j\|^2} \right)^{m-1} \right]^{-1}, \text{ si on choisit la distance euclidienne}$$

## Clustering flou : Fuzzy C-means

- Algorithme :

1) Initialiser la position des centres :  $V_i = [v_i^1, v_i^2, \dots, v_i^j, \dots, v_i^p], 1 \leq i \leq c$   
 $l=0$ , initialiser la matrice :  $U^{(l)}$

2) Calculer la position des centres  $V_i = \frac{\sum_{k=1}^n (u_{ik})^m x_k}{\sum_{k=1}^n (u_{ik})^m}, 1 \leq i \leq c$

3) Calculer la matrice :  $U^{(l+1)}$

4) Si  $\|U^{(l+1)} - U^{(l)}\| < \varepsilon$  Arrêter l'algorithme


Sinon  $l=l+1$  et retourner en 2)

## Clustering flou : Fuzzy C-means

- Algorithme simple mais :
- L'initialisation des positions des centres conditionne la convergence et le résultat final
- Le résultat dépend de la métrique utilisée pour calculer la distance
- Le nombre de clusters  $c$  doit être fixé a priori

## Clustering flou : Fuzzy C-means

- Exemple :



## Applications de la logique floue

- Systèmes experts
- Modélisation de processus non-linéaires
- Contrôle/Commande de processus
- Classification
- Prédiction de séries chronologiques

## Conclusion sur la logique floue

- **Avantages**
  - Expression des connaissances sous forme de règles
  - Un modèle analytique n'est pas nécessaire
- **Inconvénients**
  - Difficulté d'obtention des règles
  - Risque d'explosion combinatoire

## Réseaux de neurones artificiels

- Concepts de base :
  - Imiter la structure et le fonctionnement du cerveau humain
  - Trois des caractéristiques fondamentales du cerveau :
    - La connaissance est distribuée sur plusieurs neurones
    - Les neurones peuvent communiquer avec leurs voisinages
    - Le cerveau est adaptatif
  - La terminologie utilisée pour les réseaux de neurones artificiels est issue de ces caractéristiques :
    - Structure d'un neurone
    - Topologie d'un réseau
    - Règle d'adaptation ou d'apprentissage

## Organisation du cours


- Introduction
  - Bases du KDD et du DM
- Bases de l'analyse des données
  - Analyse factorielle
  - Classification
  - Clustering
  - Logique floue

## Réseaux de neurones artificiels

Conclusion

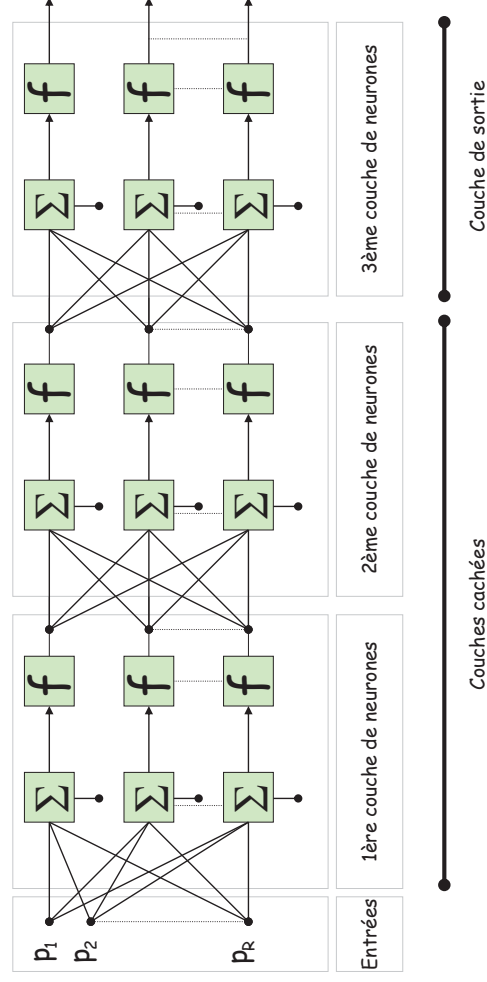
## Réseaux de neurones artificiels

- Principe général




## Réseaux de neurones artificiels

- Structure d'un réseau multi-couches feedforward






## Réseaux de neurones artificiels

- Structure et fonctionnement d'un neurone



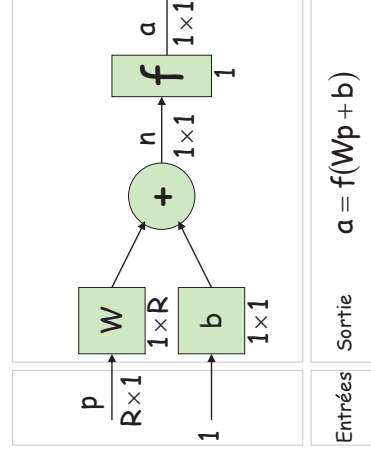
## Réseaux de neurones artificiels

- Fonctions d'activation classiques :



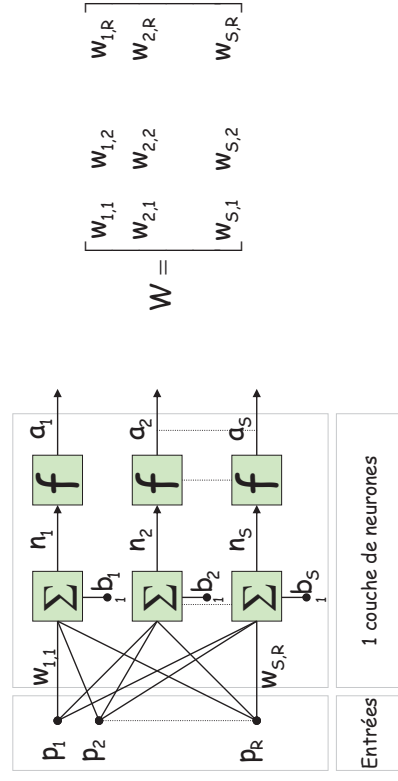
## Réseaux de neurones artificiels

- Notation



## Réseaux de neurones artificiels de neurones artificiels


- Structure d'une couche de neurones



R : nombre d'entrées  
S: nombre de neurones


## Réseaux de neurones artificiels de neurones artificiels

- Fonctionnement d'une couche c




## Réseaux de neurones artificiels de neurones artificiels

- Fonctionnement de la première couche



## Réseaux de neurones artificiels de neurones artificiels

- Fonctionnement d'un réseau multi-couches feedforward



$$y = a^3 = f^3(IW^{3,2}f^2(LW^{2,1}f^1(IW^{1,1}p + b^1) + b^2) + b^3)$$

## Réseaux de neurones artificiels

- Algorithme d'apprentissage : « Backpropagation »

- Principes

- Appliquer un vecteur d'entrée
- Calculer la sortie
- Modifier les poids des neurones pour minimiser l'erreur en partant des neurones de sortie (Backpropagation)

$$E = \frac{1}{2} \sum_i (y_i - o_i)^2$$

$y_i$  : sorties cibles

$o_i$  : sorties calculées

## Réseaux de neurones artificiels

- Algorithme d'apprentissage : « Backpropagation »

$$w_{j,i} = w_{j,i} + \Delta w_{j,i}$$

$$\Delta w_{j,i} = -\alpha \delta_j o_i$$

$$\delta_j = \begin{cases} f'(e_j) \times (t_j - s_j) & \text{si l'unité } j \text{ est une unité de sortie} \\ f'(e_j) \times \left( \sum_k \delta_k w_{k,j} \right) & \text{si l'unité } j \text{ est une unité cachée} \end{cases}$$

$j$  : indice de l'unité courante

$i$  : indice de l'unité précédente de  $j$  avec un poids  $w_{j,i}$  de  $i$  à  $j$

$k$  : indice de l'unité suivante de  $j$  avec un poids  $w_{k,j}$  de  $j$  à  $k$


$s_j$  : sortie de l'unité  $j$

$e_j$  : entrée de l'unité  $j$

$\delta_j$  : erreur de l'unité  $j$

$\alpha$  : facteur d'apprentissage

$t_j$  : valeur cible de l'unité de sortie  $j$



## Réseaux de neurones artificiels


- Algorithme d'apprentissage « Backpropagation » : exemple

$$\Delta w_{7,4} = \alpha \delta_7 s_4$$

$$\Delta w_{8,4} = \alpha \delta_8 s_4$$

$$e_7 = s_4 w_{7,4}$$

$$e_8 = s_4 w_{8,4}$$



$$\delta_7 = f'(e_7) \times (t_7 - s_7) \quad \delta_8 = f'(e_8) \times (t_8 - s_8)$$


$$e_4 = s_1 w_{4,1} + s_2 w_{4,2} + s_3 w_{4,3}$$

$$\delta_4 = f'(e_4) \times (\delta_7 w_{7,4} + \delta_8 w_{8,4})$$

$$\Delta w_{4,1} = \alpha \delta_4 s_1$$

## Réseaux de neurones artificiels

- Un exemple d'apprentissage sur la base des iris



## Applications des réseaux de neurones artificiels

277

- Reconnaissance de formes
- Modélisation de processus non-linéaires
- Contrôle/Commande de processus
- Classification
- Prédiction de séries chronologiques

## Une méthode hybride : ANFIS

279

- ANFIS : « Adaptive-Network-Based Fuzzy Inference System »
- Combinaison des approches logique floue et réseaux de neurones
- L'objectif est d'optimiser un ensemble de règles floues par apprentissage
- L'idée principale est de considérer un FIS comme un réseau de neurones spécialisé et d'appliquer des règles classiques d'apprentissage

## Conclusion sur les réseaux de neurones artificiels


278

- **Avantages**
  - Approximateur universel
  - Modèle non-linéaire
  - Champ d'application étendu
- **Inconvénients**
  - Difficultés de mise en œuvre
  - Problème de convergence
  - Approche boîte noire


## Une méthode hybride : ANFIS

280

- Un exemple simple : FIS de type SUGENO avec 2 règles



### Réseau ANFIS



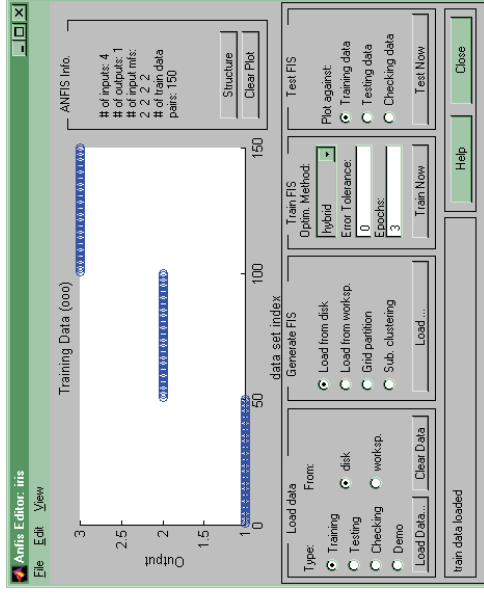
- Couche 1 : application de la fonction d'appartenance
- Couche 2 : Application du ET flou (multiplication)
- Couche 3 : Moyenne des sortie du ET
- Couche 4 : Calcul de la conclusion de chaque règle (type SUGENO)
- Couche 5 : Agrégation des règles

$$f = \frac{w_1 f_1 + w_2 f_2}{w_1 + w_2}$$

Par une méthode d'apprentissage les paramètres :  $w_1, w_2, p_1, p_2, q_1, q_2, r_1, r_2$  peuvent être modifiés pour s'adapter à un jeu de données

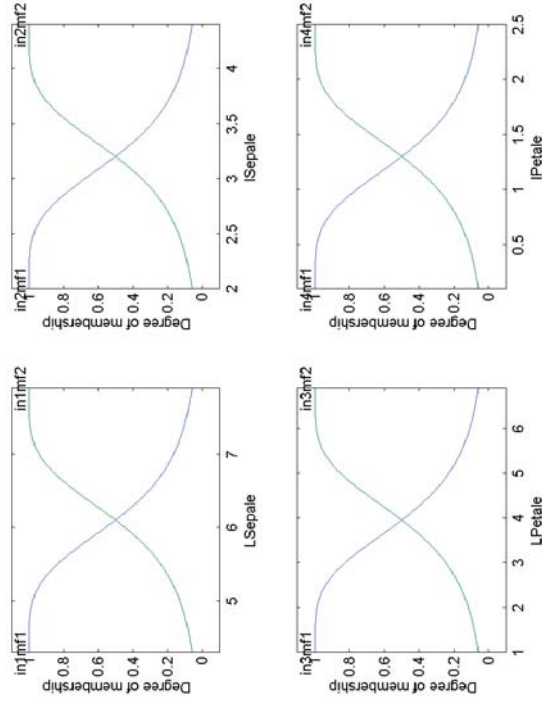
## Une méthode hybride : ANFIS

- Un exemple : classification des iris




## Une méthode hybride : ANFIS

- Un exemple : classification des iris



## Une méthode hybride : ANFIS

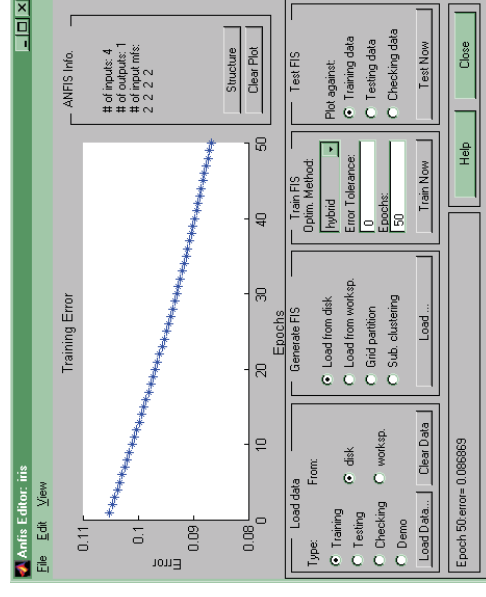
- Un exemple : classification des iris



System iris: 4 inputs, 1 outputs, 16 rules

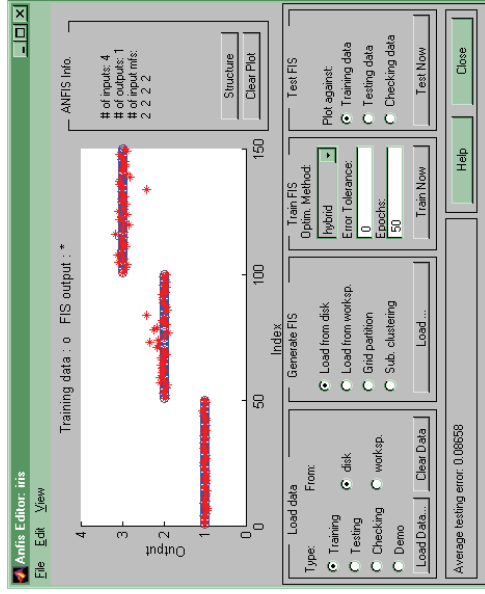
## Une méthode hybride : ANFIS

- Un exemple : classification des iris




## Une méthode hybride : ANFIS

- Un exemple : classification des iris



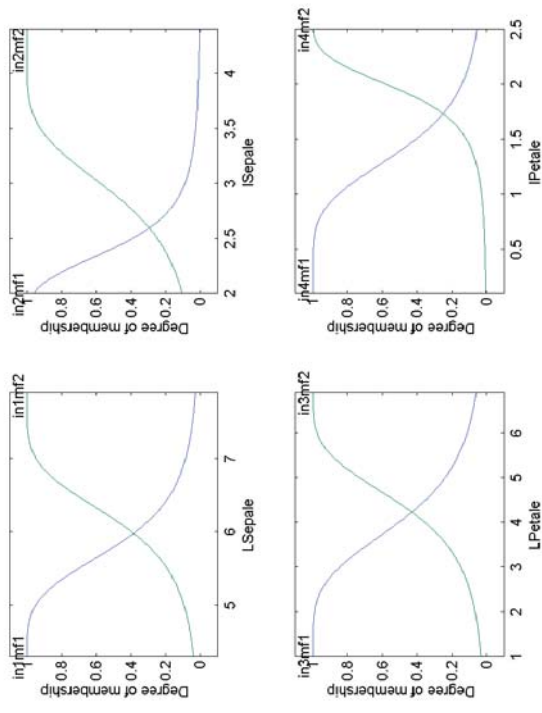
## Une méthode hybride : ANFIS

- Un exemple : classification des iris



## Une méthode hybride : ANFIS

- Un exemple : classification des iris



## Organisation du cours

- Introduction
- Bases du KDD et du DM
- Bases de l'analyse des données
- Analyse factorielle
- Classification
- Clustering
- Logique floue
- Réseaux de neurones artificiels

Conclusion

## Sources

- Denis, François et Gilleron, Rémi.  
<http://www.grappa.univ-lille3.fr/polys/apprentissage/index.html>.
- Tommassi, Marc et Gilleron, Rémi.  
<http://www.grappa.univ-lille3.fr/polys/fouille/index.html>.

## Bibliographie

- Statistiques et analyses de données
  - « Probabilité, analyse des données et statistique », G. Saporta, éditions Technip
  - « Analyse des données », M. Voille, Economica
  - « Le data mining », René Lefébure et Gilles Venturi, Eyrolles
- Cornuéjols A. & Miclet L. (2010) Apprentissage artificiel Concepts et algorithmes. - Editeur : Eyrolles - Collection : Algorithmes - 03/06/2010 (2e édition) - EAN13 : 9782212124712
- Logique Floue et réseaux de neurones
  - « Fuzzy Logic & Neural Network Handbook », C.H. Chen McGraw-Hill
  - « La logique floue et ses applications », Bernadette Bouchon Meunier Addison-Wesley
  - « La logique floue », Bernadette Bouchon Meunier, Que sais-je ?
  - « Réglage par logique floue », Hansruedi Bühler Presses Polytechniques et Universitaires Romandes
  - « ANFIS: Adaptive-Network-Based Fuzzy Inference system », Jyh-Shing Roger Jang IEEE Trans. On Systems, Man, and Cybernetics, Vol. 23, N°3, May/June 1993
  - « Fuzzy Model Identification Based on Cluster Estimation », Stephen L. Chiu, Journal of Intelligent and Fuzzy Systems, Vol 2, p. 267-278, 1994