


Machine Learning & Text Mining

Année universitaire 2020-2021




Pr. Abdelali ZAKRANI

Professeur Habilité à ENSAM de Casablanca

Docteur en informatique de l'ENSIAS

Introduction à l'apprentissage automatique

Définition: Machine Learning (apprentissage automatique) concerne l'étude, la conception et le développement d'algorithmes qui permettent aux ordinateurs d'apprendre sans être explicitement programmés (Arthur Samuel).




Introduction à l'apprentissage automatique

Programmation classique:

- Développement de programmes pour la gestion de stock
- Administration d'une entreprise,
- Gestion d'un cabinet de formations,

On peut trouver un algorithme qui permet de trouver les résultats à partir des données saisies par l'utilisateur.


Exemple:



Introduction à l'apprentissage automatique

Machine Learning: On ne dispose pas d'une formule ou d'une méthode analytique qui permet de trouver les résultats à partir des données.

Connaissez vous une méthode analytique qui permet de reconnaître l'une des images suivantes ? S'agit-il du chiffre 6 ou 9 ou la lettre v ?



Quelques applications de Machine Learning

Exemples:

- **Prédiction des prix:** Estimer le prix d'une maison en fonction de sa superficie, sa localisation, possibilité de Parking ou non etc... Ces estimations sont faites en observant d'autres produits similaires pour en tirer des conclusions.
- **Diagnostic médical:** En se basant sur les données médicales d'un patient, l'algorithme peut diagnostiquer si le sujet est atteint d'une maladie donnée. Parfois, ces algorithmes peuvent alerter d'un incident grave de santé avant que cela n'arrive, notamment pour les crises cardiaques.

5

Quelques applications de Machine Learning

https://www.01net.com/actualites/ia-ces-chercheurs-ont-decouvert-un-puissant-antibiotique-grace-a-l-apprentissage-automatique-1862232.html?fbclid=IwAR0sdwCFrxJdMg2d75jAtGZ1EF_JH21ouRfr98v2hx2cEHpzYcH0R9QSTvM

Le 21 avril 2020, Des chercheurs du MIT (Massachusetts Institute of Technology) ont créé un algorithme capable de trouver automatiquement de nouveaux antibiotiques, ce qui devrait ravir l'industrie pharmaceutique en s'appuyant sur des techniques d'[apprentissage automatique](#).

Cette découverte est d'autant plus importante que les bactéries ont tendance à devenir de plus en plus résistantes. Cette nouvelle méthode fondée sur l'intelligence artificielle pourrait donc sauver les vies des millions de personnes.

6

Quelques applications de Machine Learning

- **Recommandation de produits:** Ce type de système se base sur les historiques d'achats, les recherches faites en ligne (Tracking Web) par un internaute pour lui recommander des produits qui pourront l'intéresser. Pour Amazon, cette fonctionnalité est critique car elle est au cœur de l'augmentation des volumes de vente et par conséquent des gains de la société.
- **Regroupement d'items:** Ce type de technique sert notamment pour l'application Iphoto d'Apple pour regrouper les images en fonction des gens qui s'y retrouvent. Généralement, les données n'ont pas d'étiquettes, et l'algorithme tentera de retrouver des items similaires et les regroupera dans un même groupe.

7

Quelques applications de Machine Learning

- **Conduite autonome:** En apprenant le comportement de conduite des humains, les algorithmes de Deep Learning avec l'apprentissage par renforcement (reinforcement learning) permettent d'apprendre des tâches complexes comme la conduite.
- **Banque et Assurance:**
 - Prédire qu'un client va quitter sa banque.
 - Définir ceux qui veulent changer leur assurance vie.
 - Améliorer la satisfaction client en proposant les offres les plus pertinentes possibles.
 - Prise de décision pour donner un crédit à un client ou non, prédire les risques,

8

Quelques applications de Machine Learning

Une banque reçoit quotidiennement plusieurs demandes d'approbation de crédit. Elle veut automatiser leurs processus d'évaluation. La banque n'a pas de formule magique pour savoir quand il faut accorder un crédit, mais il a beaucoup de données.

L'existence de données nous ramène à l'approche d'apprentissage des données. Donc, la banque utilise l'historique des documents des anciens clients pour trouver la bonne formule d'approbation de crédit.

9

Application du Machine Learning

1- Existence d'un modèle à apprendre: Il existe une corrélation entre les variables d'entrées et de sorties. On sait qu'un modèle existe même si on le connaît pas.

2-Modélisation mathématique est impossible: On ne peut pas résoudre le modèle mathématiquement (pas de solution analytique).

3- Existence des données: Il existe des données qui représentent le modèle.

Datasets: exemples


<https://archive.ics.uci.edu/ml/index.php>

<https://www.kaggle.com/datasets>

10

L'apprentissage automatique est une branche de l'intelligence artificielle


Le **Machine Learning** ou **Apprentissage automatique** est une branche de l'intelligence artificielle qui concerne la conception, l'analyse, le développement et l'implémentation de modèles, permettant à une machine d'apprendre à partir des données par un processus systématique afin de remplir une tâche.



11

Les types d'apprentissage automatique

- Apprentissage supervisé (supervised learning)
- Non supervisé (unsupervised learning)
- Semi supervisé (semi-supervised learning)
- Par renforcement(reinforcement learning)




Apprentissage supervisé (supervised learning)

Des données (entrées) annotées de leurs sorties pour entraîner le modèle, c'est-à-dire que à chaque **entrée** est associée à une classe **cible (sortie)**, une fois entraîné, le modèle (l'algorithme de ML) devient capable de prédire (éventuellement avec un pourcentage d'erreur) la cible sur de **nouvelles données** non annotées.

Exemple:


Les données d'entrée représentent des images et la cible (ou *target* en anglais) représente la catégorie de photos.

Apprentissage supervisé (supervised learning)



15

Apprentissage supervisé (supervised learning)



16

Apprentissage supervisé (supervised learning)

Techniques supervisées (prédictive)

Classification

**Régression
Estimation**

Arbre de décision

Réseaux de neurone

Naïve Bayes

**Machines à
vecteurs supports
(SVM)**

K-Nearest Neighbour (K-NN)


17

Apprentissage non supervisé (unsupervised learning)

En apprentissage non supervisé, les données d'entrées ne sont pas annotées. L'algorithme d'entraînement s'applique dans ce cas à trouver les similarités et distinctions au sein de ces données, et à regrouper ensemble celles qui partagent des caractéristiques communes. Dans notre exemple, les photos similaires seraient ainsi regroupées automatiquement au sein d'une même catégorie.

18

Apprentissage non supervisé (unsupervised learning)



19

Apprentissage non supervisé (unsupervised learning)

Techniques non supervisées (descriptive)

Clustering

Associations

**K-Means
K-moyennes**

**Apriori
Eclat, FP-growth
RElim, SaM, JIM**

**Expectation
Maximisation (EM)**

20

Apprentissage sem-supervisé (semi-supervised learning)

- L'**apprentissage semi-supervisé** est une classe de techniques d'apprentissage automatique qui utilise un ensemble de données étiquetées et non étiquetées. Il se situe ainsi entre l'apprentissage supervisé qui n'utilise que des données étiquetées et l'apprentissage non supervisé qui n'utilise que des données non étiquetées. Il a été démontré que l'utilisation de données non étiquetées, en combinaison avec des données étiquetées, permet d'améliorer significativement la qualité de l'apprentissage.
- Un autre intérêt provient du fait que l'étiquetage de données nécessite souvent l'intervention d'un utilisateur humain. Lorsque les jeux de données deviennent très grands, cette opération peut s'avérer fastidieuse. Dans ce cas, l'apprentissage semi-supervisé, qui ne nécessite que quelques étiquettes, revêt un intérêt pratique évident.

21

Apprentissage par renforcement(reinforcement learning)

L'**apprentissage par renforcement** consiste, pour un agent autonome (robot, etc.), à apprendre les actions à prendre, à partir d'expériences, de façon à optimiser une récompense quantitative au cours du temps. L'agent est plongé au sein d'un environnement, et prend ses décisions en fonction de son état courant. En retour, l'environnement procure à l'agent une récompense, qui peut être positive ou négative. L'agent cherche, au travers d'expériences itérées, un comportement décisionnel (appelé *stratégie* ou *politique*, et qui est une fonction associant à l'état courant l'action à exécuter) optimal, en ce sens qu'il maximise la somme des récompenses au cours du temps.

22

Les 7 étapes de l'apprentissage automatique

L'apprentissage automatique ne se résume pas à un ensemble d'algorithmes mais suit une succession d'étapes:

- 1) **L'acquisition de données** : l'algorithme se nourrissant des données en entrée, c'est une étape importante. Il en va de la réussite du projet, de récolter des données pertinentes et en quantité suffisante.
- 2) **La préparation et le nettoyage de la donnée** : les données recueillies doivent être retouchées avant utilisation. En effet, certains attributs sont inutiles, d'autre doivent être modifiés afin d'être compris par l'algorithme, et certains éléments sont inutilisables car leurs données sont incomplètes.

23


Les 7 étapes de l'apprentissage automatique

- 3) **Choix du modèle.**
- 4) **Formation et apprentissage du modèle**
- 5) **L'évaluation** : une fois l'algorithme d'apprentissage automatique entraîné sur un premier jeu de donnée, on l'évalue sur un deuxième ensemble de données afin de vérifier que le modèle ne fasse pas de surapprentissage.
- 6) **Réglage des paramètres**: Ajuster les paramètres pour de meilleures performances
- 7) **Le déploiement** : le modèle est déployé en production pour faire des prédictions, et potentiellement utiliser les nouvelles données en entrée pour se ré-entraîner et être amélioré.

24

Classification binaire

- La classification est une tâche très répandue en Machine Learning. Dans ce genre de problématique, on cherche à mettre une étiquette (un label) sur une observation : une tumeur est-elle maligne ou non, une transaction est-elle frauduleuse ou non... ces deux cas sont des exemples de classification.
- Quand on a deux choix d'étiquettes possibles (tumeur maligne ou non), on parle de Binary Classification (classification binaire). Par ailleurs, l'étiquette Y aura deux valeurs possibles 0 ou 1. En d'autres termes $Y \in \{0, 1\}$




25

Classification binaire et multiclass

Le but du jeu c'est qu'on trouve une ligne (Boundary Decision) séparant les deux groupes (les cercles et les carrés).


Note : Pour l'exemple de la tumeur, on peut attribuer arbitrairement la classe (étiquette) 1 pour dire qu'il s'agit d'une tumeur maligne et la valeur 0 pour les tumeurs bénignes.

Quand notre problème a plusieurs étiquettes possibles (par exemple classifier un article dans une catégorie ("sport", "politique", "High-Tech")...), on parle de Multi-class classification. Dans ce cas on peut attribuer arbitrairement les numéros des classes aux observations du Training Set. Dans l'exemple vu en TP en haut pour la reconnaissance des chiffres : dix classes: 0,1,2,3,4,5,6,7,8,9



26

Application de Machine Learning sur la reconnaissance des nombres manuscrits



27

Application de Machine Learning sur la reconnaissance des nombres manuscrits

Prenons des images en niveau de gris : chaque pixel est codé sur 8 bits

Pixel est représenté par un nombre compris entre 0 et 255.

Valeur du pixel proche de 0: noir

Valeur du pixel proche de 1: blanc

28

Application de Machine Learning sur la reconnaissance des nombres manuscrits

```
import numpy as np
import matplotlib.pyplot as plt
import pandas

from sklearn.tree import DecisionTreeClassifier

data=pandas.read_csv("d:\\train.csv").as_matrix()
clf=DecisionTreeClassifier()
x=data[0:21000,1:]
label=data[0:21000,0]
clf.fit(x,label)
xtest=data[21000:,1:]
actual_label=data[21000:,0]
p=clf.predict(xtest)
```

29


Application de Machine Learning sur la reconnaissance des nombres manuscrits

```
p=clf.predict(xtest)
count=0
for i in range(0,21000):
    count+=1 if p[i]==actual_label[i] else 0
print("Accuracy=", (count/21000)*100)
d=xtest[5]
Nombre_de_pixels_errones=100
for i in range(Nombre_de_pixels_errones):
    position=np.random.randint(0,784,1)[0]
    bruit=np.random.randint(-200,200,1)[0]
    d[position]+=bruit
    d[position]=d[position]%255
print(clf.predict([d]))
d.shape=(28,28)
plt.imshow(255-d,cmap='gray')
plt.show()
```

30

Application de Machine Learning sur la reconnaissance des nombres manuscrits

Avec un Nombre_de_pixels_errones=100 on obtient l'image suivante:




L'instruction `print(clf.predict([d]))` a donné la valeur 3 donc une reconnaissance réussie

31

Application de Machine Learning sur la reconnaissance des nombres manuscrits

Avec un Nombre_de_pixels_errones=500 on obtient l'image suivante:




L'instruction `print(clf.predict([d]))` a donné la valeur 5 donc une reconnaissance non réussie à cause du bruit très fort.

32

Application de Machine Learning sur la reconnaissance des nombres manuscrits

Le programme donné en haut a pu reconnaître l'image suivante: chiffre 2



33

Application de Machine Learning sur la reconnaissance des nombres manuscrits

Refaire le même TP avec un modèle d'apprentissage KNN

34

Supervised (inductive) learning

35


Régression linéaire

Les algorithmes de régression linéaire modélisent la relation entre des variables prédictives et une variable cible. La relation est modélisée par une fonction de prédiction. Le cas le plus simple est la régression linéaire univariée. Elle va trouver une fonction sous forme de droite pour estimer la relation.

La régression polynomiale permet de modéliser des relations complexes qui ne sont pas forcément linéaires.


36

Relation linéaire entre des variables prédictives et la variable cible



37

Relation non linéaire entre des variables prédictives et la variable cible



38


Régression linéaire

```
import pandas as pd
import matplotlib.pyplot as plt
from scipy import stats
df = pd.read_csv("d:\\univariate_linear_regression_dataset.csv")
X = df.iloc[:,0]
Y = df.iloc[:,1]
axes = plt.axes()
axes.grid()
plt.scatter(X,Y)
plt.show()
SL=stats.linregress(X, Y)
slope=SL.slope; intercept=SL.intercept; coef_correlation=SL.rvalue
def predict(x):
    return slope * x + intercept
axes = plt.axes()
axes.grid()
plt.scatter(X,Y)
fitLine = predict(X)
plt.plot(X, fitLine, c='r')
plt.show()
```

39

Régression linéaire

```
axes = plt.axes()
axes.grid()
plt.scatter(X,Y)
plt.show()
```

40


Régression linéaire

- Le fonction de prédiction pour une régression linéaire univariée est comme suit :

$$H(x) = \text{intercept} + \text{slope} * x$$

- avec : *slope*: représente la "pente" de la ligne de prédiction et *intercept* représente le point d'intersection avec l'axe des ordonnées

```
SL= stats.linregress(X, Y)
SL.slope est 1.2135472539083585
SL.intercept est -4.211504005424089
SL.rvalue:
0.8721572919685905
r= X.corr(Y)
print(r)
0.8721572919685905
```




Régression linéaire

- Prédiction d'une nouvelle observation:**

On voit que pour la valeur $x = 22.5$, la valeur de y est environ 25.


Utilisons la fonction *predict* pour trouver une estimation de $H(x=22.5)$:

`predict(22.5)` → 23.093309207513975



Régression linéaire avec l'algorithme de descente de gradient

Dans la pratique, les Data Scientists utilisent le package **sklearn**, qui permet d'écrire un tel code en 4 lignes, mais ici nous écrirons chaque fonction mathématique de façon explicite, ce qui est un **bon exercice** pour la compréhension du modèle.



43

Régression linéaire avec l'algorithme de descente de gradient

$$X = (x \ 1) \ ; \ \theta = \begin{pmatrix} a \\ b \end{pmatrix} \text{ et } f(x) = \theta \cdot X = (x \ 1) \begin{pmatrix} a \\ b \end{pmatrix} = a \cdot x + b$$

Objectif: trouver θ qui donne une bonne prédiction d'une entrée x .

Pour développer un modèle linéaire avec la descente de gradient, il faut implémenter les 4 fonctions clefs suivantes :

- la fonction de notre modèle : $f(x) = X \cdot \theta$
- la fonction Cout : $J(\theta) = \frac{1}{2m} \sum (X \cdot \theta - Y)^2$
- le gradient : $\frac{\partial J(\theta)}{\partial \theta} = \frac{1}{m} X^T \cdot (X \cdot \theta - Y)$
- la descente de gradient : $\theta = \theta - \alpha \times \frac{\partial J(\theta)}{\partial \theta}$

α : est appelé taux d'apprentissage: learning_rate

m : est la taille de l'ensemble d'apprentissage

Objectif: trouver θ qui minimise $J(\theta)$

44

Régression linéaire avec l'algorithme de descente de gradient

- la fonction de notre modèle : $f(x) = X.\theta$
- la fonction Cout : $J(\theta) = \frac{1}{2m} \sum (X.\theta - Y)^2$
- le gradient : $\frac{\partial J(\theta)}{\partial \theta} = \frac{1}{m} X^T.(X.\theta - Y)$
- la descente de gradient : $\theta = \theta - \alpha \times \frac{\partial J(\theta)}{\partial \theta}$

```
def f(X, theta):
    return X.dot(theta)
def erreur_somme_des_distances(X, y, theta):
    m = len(y)
    return (1/(2*m))*np.sum((f(X, theta)-y)**2)
def gradient(X, y, theta):
    m = len(y)
    return 1/m * X.T.dot(f(X, theta) - y)
```

45

Régression linéaire avec l'algorithme de descente de gradient

- la fonction de notre modèle : $f(x) = X.\theta$
- la fonction Cout : $J(\theta) = \frac{1}{2m} \sum (X.\theta - Y)^2$
- le gradient : $\frac{\partial J(\theta)}{\partial \theta} = \frac{1}{m} X^T.(X.\theta - Y)$
- la descente de gradient : $\theta = \theta - \alpha \times \frac{\partial J(\theta)}{\partial \theta}$

```
def gradient_descent(X, y, theta, learning_rate, n_iterations):
    # création d'un tableau de stockage pour enregistrer l'évolution des erreurs
    historique_des_erreurs = np.zeros(n_iterations)
    for i in range(0, n_iterations):
        theta = theta - learning_rate * gradient(X, y, theta) # mise a jour
        historique_des_erreurs[i] = erreur_somme_des_distances(X, y, theta)
    return theta, historique_des_erreurs
```

46

Régression linéaire avec l'algorithme de descente de gradient

```
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
df = pd.read_csv("d:\\univariate_linear_regression_dataset.csv")
x= df.iloc[:,0] ; n_samples = len(x); x=np.array(x).reshape((n_samples, 1)) #96
y= df.iloc[:,1] ; y=np.array(y).reshape((n_samples, 1))
x=np.array(x).reshape((n_samples, 1))
plt.scatter(x, y) # afficher les résultats. X en abscisse et y en ordonnée
plt.show()
# ajout de la colonne de biais a X
X = np.hstack((x, np.ones(x.shape)))
# création d'un vecteur parametre theta
theta = np.random.randn(2, 1)
print(theta)
```

47

Régression linéaire avec l'algorithme de descente de gradient

```
def f(X, theta):
    return X.dot(theta)
def erreur_somme_des_distances(X, y, theta):
    m = len(y)
    return (1/(2*m))*np.sum((f(X, theta)-y)**2)
def gradient(X, y, theta):
    m = len(y)
    return 1/m * X.T.dot(f(X, theta) - y)
def gradient_descent(X, y, theta, learning_rate, n_iterations):
    # création d'un tableau de stockage pour enregistrer l'évolution des erreurs
    historique_des_erreurs = np.zeros(n_iterations)
    for i in range(0, n_iterations):
        theta = theta - learning_rate * gradient(X, y, theta) # mise a jour du theta
        historique_des_erreurs[i] = erreur_somme_des_distances(X, y, theta)
    return theta, historique_des_erreurs
```

48



Régression linéaire avec l'algorithme de descente de gradient

```
# Exemple de test :
n_iterations = 10000
learning_rate = 0.01
theta_final, historique_des_erreurs=gradient_descent(X, y, theta,
    learning_rate, n_iterations)
print(theta_final) # theta une fois que la machine a été entraînée
# création d'un vecteur prédictions qui contient les prédictions de notre modele final
predictions = f(X, theta_final)
# Affiche les résultats de prédictions (en rouge) par rapport a notre Dataset (en bleu)
plt.scatter(x, y)
plt.plot(x, predictions, c='r')
plt.show()
plt.figure()
plt.plot(range(n_iterations), historique_des_erreurs)
plt.show()
print(f(np.array([22.5,1]), theta_final))
```

49

Régression linéaire avec l'algorithme de descente de gradient

`f(np.array([22.5,1]), theta_final)` → donne: `array([23.09330913])`




50

Régression linéaire avec l'algorithme de descente de gradient

$f(x) = x^2 - x + 1 \Rightarrow \nabla f(x) = \frac{\partial f(x)}{\partial x} = f'(x) = 2x - 1$


Minimum au point x: $f(x)=0$
 $x=0.5$





Régression linéaire avec l'algorithme de descente de gradient

$f(x) = x^2 - x + 1 \Rightarrow \nabla f(x) = \frac{\partial f(x)}{\partial x} = f'(x) = 2x - 1$

Minimum au point x: $f(x)=0$
 $x=0.5$





Régression polynomiale:

Relation non linéaire entre des variables prédictives et la variable cible

Régression polynomiale

```
def afficher_pol(LPol):
    L=LPol[:]; L.reverse()
    L=[round(e,2) for e in L]
    for i in range(len(L)):
        print('(' +str(L[i])+'*X^'+str(i)+')',end='+')
def Evaluer_pol(LPol,x):
    s=0
    L=LPol[:];
    L.reverse()
    for i in range(len(LPol)):
        s+=L[i]*(x**i)
    return(s)
```

```
P=[-4.04264497e-03, 1.26341942e+00, -7.46569108e+00,
1.36046931e+01, -7.39512820e+00]
```

```
Afficher_pol(P)→(-7.4*X^0)+(13.6*X^1)+(-7.47*X^2)+(1.26*X^3)+(-0.0*X^4)
```

55



Régression polynomiale:



Relation non linéaire entre des variables prédictives et la variable cible

```
import numpy as np
import matplotlib.pyplot as plt
import pandas
data=pandas.read_csv("d:\\dataset_polynomial3.csv").as_matrix()
x=data[1:1001,0]
y=data[1:1001,1]
degre_polynome=5
p= np.poly1d(np.polyfit(x, y,degre_polynome))
LPol=list(p)
afficher_pol(LPol)
les_x= np.linspace(min(x), max(x), 100)
plt.scatter(x, y)
plt.plot(les_x, p(les_x), c='r')
plt.show()
```

```
P(x)=(-7.36*X^0)+(13.35*X^1)+(-7.01*X^2)+(0.96*X^3)+(0.08*X^4)+(-0.01*X^5)
```


56





Sigmoid Function : La fonction pour la régression Logistique

la fonction sigmoid (Sigmoid Function) produit des valeurs comprises entre 0 et 1.



$$\text{sigmoide}(x) = \frac{1}{1 + e^{-x}}$$

61

Sigmoid Function : La fonction pour la régression Logistique

- La régression logistique est utilisée pour trouver la probabilité d'un événement. On veut déterminer le succès ou l'échec d'un événement.
- Largement utilisé pour les problèmes de classification
- Ne nécessite pas de relation linéaire entre les variables dépendantes et indépendantes.
- La régression logistique permettra de répondre à des problèmes comme :

Est-ce que le client est solvable pour lui accorder un crédit ou non?

Est-ce que la tumeur diagnostiquée est bénigne ou maligne ?

Est-ce qu'un message est spam ou non ?

62

Sigmoid Function : La fonction pour la régression Logistique

- La fonction hypothèse:

$$S(X^{(i)}) = \theta_0 + \theta_1 x_1 + \theta_2 x_2 + \theta_3 x_3 + \dots + \theta_n x_n$$

- $X^{(i)}$: une observation (du *Training Set* ou du *Test Set*), cette variable est un vecteur contenant:
 $[x_1, x_2, x_3, \dots, x_n]$
- x_i : est une variable prédictive (feature) qui servira dans le calcul du modèle prédictif
- θ_i : est un poids/paramètre de la fonction hypothèse. Ce sont ces θ_i qu'on cherche à calculer pour obtenir notre fonction de prédiction.
- θ_0 : est une constante nommée le **bias (biais)**

63

Sigmoid Function : La fonction pour la régression Logistique

- On peut réécrire $\theta_0 = \theta_0 * x_0$: avec $x_0=1$, Cela nous permet de réécrire notre fonction $S(X)$ de façon plus compacte comme suit :

$$S(X) = \sum_{i=0}^{n+1} \theta_i * x_i$$

On appelle cette fonction hypothèse : **la fonction score**. L'idée est de trouver des coefficients: $[\theta_0, \theta_1, \theta_2, \theta_3, \dots, \theta_n]$

de sorte que :

- $S(X^{(i)}) > 0$: quand la classe (étiquette) vaut 1
- $S(X^{(i)}) < 0$: quand la classe (étiquette) vaut 0

$$\text{Pr obabilité}(X \in \text{Classe "1"}) = \text{Sigmoide}(\theta.X)$$

$$= \frac{1}{1 + \exp(-S(X))} = \frac{1}{1 + \exp(-\theta.X)}$$

Le résultat obtenu par la fonction **sigmoid** ($\theta.X$) est interprété comme la **probabilité que l'observation X soit d'un label (étiquette) 1**.

64

la régression Logistique implémenté dans sklearn

```

import numpy as np # Chargement de numpy
import matplotlib.pyplot as plt # import de Matplotlib
from sklearn import datasets
from sklearn.linear_model import LogisticRegression
iris = datasets.load_iris()
X = iris.data[:, :2] # avoir un problème de classification binaire.
# re-etiquetage des fleurs pour se retrouver avec deux classes au lieu de trois
y = []
for e in iris.target:
    if e==0:        y+= [0]
    else:           y+= [1]
y=np.array(y)

```

65

la régression Logistique implémenté dans sklearn


```

plt.figure(figsize=(10,6)) # Taille de la figure
plt.scatter(X[y == 0][:, 0], X[y == 0][:, 1], color='g')
# En Vert les fleurs ayant l'étiquette 0
plt.scatter(X[y == 1][:, 0], X[y == 1][:, 1], color='y')
# en Jaune les fleurs ayant l'étiquette 1
plt.legend(labels = ("classe 0", "classe 1"));
plt.xlabel("x")
plt.ylabel("y")

```

66

la régression Logistique implémenté dans sklearn



57

la régression Logistique implémenté dans sklearn

```

model = LogisticRegression(C=1e20)#tester avec 0.01
x_train, x_test, y_train, y_test = train_test_split(X,y, test_size=0.2, random_state=0)
#La fonction train_test_split mélange les données avant de faire la répartition
#si on fixe random_state sur une valeur précise, on exécute sur deux machines différentes
#Les le mélange sera fait de la même façon sur les deux machines et on obtient les mêmes
model.fit(x_train, y_train)
score=cross_val_score(model,x_train, y_train, cv=5,scoring='accuracy')
score1=model.score(x_test, y_test)
score2=model.score(x_train, y_train)
print("score sur test-set =" +str(score1*100)+'%')
print("score sur train-set =" +str(score2*100)+'%')
theta0=model.intercept_; theta1=model.coef_[0][0]; theta2=model.coef_[0][1]
Iries_To_Predict = [ [5.5, 2.5], [7, 3], [3,2], [5,3]]
# demande de prédiction
print(model.predict(Iries_To_Predict))

```

```

score sur test-set =100.0%
score sur train-set =100.0%
[1 1 0 0]

```

68

la régression Logistique implémenté dans sklearn

```
score=cross_val_score(model,x_train, y_train, cv=5,scoring='accuracy')
print(score)
print(score.mean())
def fct_reg_logistic(x1,x2):
    z=(theta0)+theta1*x1+(theta2*x2)
    return(z)
print([fct_reg_logistic(e[0],e[1]) for e in Iries_To_Predict])
```

[1. 0.95833333 1. 1. 1.]
 0.9916666666666668
 [array([24.57979467]), array([60.629162]), array([-45.97305733]), array([-8.37780735])]

69

la régression Logistique implémenté pas à pas

La probabilité de prédiction de la classe positive est déterminée par:

$$h(\theta, x) = \frac{1}{1 + e^{-\theta \cdot x}}$$

La fonction de coût à minimiser :

$$j(\theta) = \frac{1}{m} \sum_1^m [(0 - y^i) * \log(h(x^i)) - (1 - y^i) * \log(1 - h(x^i))]$$

Le gradient est:
$$\frac{\partial J(\theta)}{\partial \theta_j} = \frac{1}{m} \sum_{i=1}^m (h(\theta, x^{(i)}) - y^{(i)}) \cdot x_j^{(i)}$$

70

la régression Logistique implémenté pas à pas

```


import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
from sklearn import datasets
iris = datasets.load_iris()
x= iris.data[:, :2] # avoir un problème de classification binaire.
y = []
for e in iris.target:
    if e==0:y+= [0]
    else:y+= [1]
y=np.array(y)

plt.figure(figsize=(10,6)) # Taille de la figure
plt.scatter(x[y == 0][:, 0], x[y == 0][:, 1], color='g', label='0')
# En Vert les fleurs ayant l'étiquette 0
plt.scatter(x[y == 1][:, 0], x[y == 1][:, 1], color='y', label='1')
# en Jaune les fleurs ayant l'étiquette 1
plt.legend(labels = ("classe 0", "classe 1"));
plt.xlabel("x")
plt.ylabel("y")

```

71

la régression Logistique implémenté pas à pas

72

la régression Logistique implémenté pas à pas

$$h(\theta, x) = \frac{1}{1 + e^{-\theta \cdot x}}$$

$$j(\theta) = \frac{1}{m} \sum_1^m [(0 - y^i) * \log(h(x^i)) - (1 - y^i) * \log(1 - h(x^i))]$$

```
X=np.concatenate((np.ones((y.shape[0],1)),x),axis=1)
theta = np.zeros(X.shape[1])
def h(theta,x):
    return 1/(1+np.exp(-np.dot(theta.T,x)))

def Erreurs_j_theta(x,y,theta):
    m=x.shape[0]
    s=0
    for i in range(m):
        s+=y[i]*np.log(h(theta,x[i]))+(1-y[i])*np.log(1-h(theta,x[i]))
    return(-s/m)
```

73

la régression Logistique implémenté pas à pas

Le gradient est: $\frac{\partial J(\theta)}{\partial \theta_j} = \frac{1}{m} \sum_{i=1}^m (h(\theta, x^{(i)}) - y^{(i)}) \cdot x_j^{(i)}$

```
def gradient_D_j_theta(x,y,theta,j):
    m=x.shape[0]
    s=0
    for i in range(m):
        s+=(h(theta,x[i])-y[i])*x[i][j]
    return(s/m)
```

74

la régression Logistique implémenté pas à pas

$$\frac{\partial J(\theta)}{\partial \theta_j} = \frac{1}{m} \sum_{i=1}^m (h(\theta, x^{(i)}) - y^{(i)}) \cdot x_j^{(i)}$$

```
def gradient_descent(X, y, theta, learning_rate, n_iterations):
    # création d'un tableau de stockage pour enregistrer l'évolution des erreurs
    historique_des_erreurs = np.zeros(n_iterations)
    for i in range(0, n_iterations):
        H=np.array([h(theta,x) for x in X])
        Hy=[abs(H[u]-y[u]) for u in range(X.shape[0])]
        theta[0] = theta[0] - (learning_rate/X.shape[0]) * sum(Hy)
        for j in range(X.shape[1]):
            theta[j] = theta[j] - learning_rate*gradient_D_j_theta(X, y, theta,j)
        historique_des_erreurs[i] = Erreurs_j_theta(X,y,theta)
    return theta, historique_des_erreurs
```

75

la régression Logistique implémenté pas à pas

```
# Exemple de test :
n_iterations = 10000
learning_rate = 0.01
theta_final, historique_des_erreurs=gradient_descent(X, y,theta, learning_rate, n_iterations)
print(theta_final) # thetaune fois que la machine a été entraînée
def h_avec_ajout_biais_a_x(theta,x):
    XX=np.concatenate((np.array([1]),x),axis=0)
    return 1/(1+np.exp(-np.dot(theta.T,XX)))
```

```
[-12.42617591  4.4185545 -3.6335506]
```

76

la régression Logistique implémenté pas à pas


```
#calcul du taux de réussite sur l'ensemble d'apprentissage:
cpt=0
for i in range(y.shape[0]):
    t=h_avec_ajout_biais_a_x(theta_final,x[i])
    if t<0.5:
        target=0
    else:
        target=1
    if target!=y[i]:
        cpt+=1
    else:
        print('Problème au point:',x[i])
print((cpt/y.shape[0])*100)
plt.plot(range(n_iterations),historique_des_erreurs)
plt.show()
```

100.0

77

la régression Logistique implémenté pas à pas

l'évolution des erreurs au cours des itérations



78

Représentation des données textuelles

Il existe principalement deux méthodes qui permettent de transformer et d'extraire de l'information grâce à la tokenization. On parle de représentation sparse des données qui sont réalisés grâce à deux méthodes : bags-of-words & TF-IDF.

bags-of-words(Sacs-de-mots):

```
1 from sklearn.feature_extraction.text import CountVectorizer
2 texte = ["La vie est douce","La vie est tranquille, est belle, est douce"]
3 vect = CountVectorizer()
4 T= vect.fit_transform(texte)
5 dictionnaire_des_mots=vect.vocabulary_
6 print("dictionnaire_des_mots :", dictionnaire_des_mots)
7 liste_des_mots=list(dictionnaire_des_mots.keys())
8 print("liste_des_mots :", liste_des_mots)
9 Matrice_sparse_correspondante=T.toarray()
10 print("Matrice_sparse_correspondante:\n",Matrice_sparse_correspondante)
```

```
dictionnaire_des_mots : {'la': 3, 'vie': 5, 'est': 2, 'douce': 1, 'tranquille':
4, 'belle': 0}
liste_des_mots : ['la', 'vie', 'est', 'douce', 'tranquille', 'belle']
Matrice_sparse_correspondante:
[[0 1 1 1 0 1]
 [1 1 3 1 1 1]]
```

Représentation des données textuelles

Matrice sparse binaire: **CountVectorizer(binary=True)**

```
1 from sklearn.feature_extraction.text import CountVectorizer
2 texte = ["La vie est douce","La vie est tranquille et est belle"]
3 vect = CountVectorizer()
4 T= vect.fit_transform(texte)
5 dictionnaire_des_mots=vect.vocabulary_
6 print("dictionnaire_des_mots :", dictionnaire_des_mots)
7 liste_des_mots=list(dictionnaire_des_mots.keys())
8 print("liste_des_mots :", liste_des_mots)
9 Matrice_sparse_correspondante=T.toarray()
10 print("Matrice_sparse_correspondante:\n",Matrice_sparse_correspondante)
```

```
dictionnaire_des_mots : {'la': 4, 'vie': 6, 'est': 2, 'douce': 1, 'tranquille':
5, 'et': 3, 'belle': 0}
liste_des_mots : ['la', 'vie', 'est', 'douce', 'tranquille', 'et', 'belle']
Matrice_sparse_correspondante:
[[0 1 1 0 1 0 1]
 [1 0 2 1 1 1 1]]
```


Représentation des données textuelles

TF-IDF (term frequency-inverse document frequency)

Les distances basées sur des tokens

- Une mesure qui est largement employée dans le domaine de la recherche d'informations, semble convenable ici. Il s'agit du TF/IDF.
- La fréquence de terme, TF, dans un document donné montre l'importance de ce terme dans le document en question.
- La fréquence inverse de document, IDF, est une mesure de l'importance générale du terme dans l'ensemble des documents.
- Les mesures de TF et TF/IDF sont définies comme suit :

Soit D un corpus des documents et t un terme à considérer:

le nombre
d'occurrences du
terme t dans un
document

le nombre des
termes dans ce
document

$$TF = \frac{n(t)}{N} \text{ et } TF/IDF = TF \times \log\left(\frac{|D|}{d(t)}\right)$$

dénote le nombre des
documents dans le
corpus D

le nombre des
documents qui
contiennent au moins
une fois le terme t.

Représentation des données textuelles

```
import string
import nltk
nltk.download('stopwords')
from nltk.corpus import stopwords
def netoyage(corpus_ensemble_documents):
    for i in range(len(corpus_ensemble_documents)):
        corpus_ensemble_documents[i]=corpus_ensemble_documents[i].lower()
    for i in range(len(corpus_ensemble_documents)):
        for c in string.punctuation:
            x=corpus_ensemble_documents[i].replace(c, ' ')
            corpus_ensemble_documents[i]=x
    stopwords_anglais=stopwords.words('english') #ou french
    for i in range(len(corpus_ensemble_documents)):
        L=corpus_ensemble_documents[i].split()
        for mot in L:
            if mot in stopwords_anglais:
                while mot in L:
                    L.remove(mot)
        corpus_ensemble_documents[i]=" ".join(L)
    return(corpus_ensemble_documents)
```

Représentation des données textuelles

```
from numpy import *
def TF(terme,corpus,numero_document):
    x=corpus[numero_document].count(terme)
    y=len(corpus[numero_document].split())
    return x/y

def IDF(terme,corpus,numero_document):
    D=len(corpus)
    d_t=0
    for document in corpus:
        if terme in document:
            d_t+=1
    TF_val=TF(terme,corpus,numero_document)
    return TF_val*log(1+(D/d_t))

def cles_correspondante_a_valeur(valeur,dictionnaire):
    for cle in dictionnaire.keys():
        if dictionnaire[cle]==valeur:
            return cle
```

83

Représentation des données textuelles

```
def matrice_sparse(dictionnaire,corpus_ensemble_documents):
    M=numpy.zeros((len(corpus_ensemble_documents),len(dictionnaire.values()))
    for i in range(len(corpus_ensemble_documents)):
        for j in dictionnaire.values():
            x=cles_correspondante_a_valeur(j,dictionnaire)
            M[i,j]=IDF(x,corpus_ensemble_documents,i)
    return M

def affiche(M):
    (n,p)=M.shape
    for i in range(n):
        for j in range(p):
            M[i,j]=round(M[i,j],2)
    print(M)
```

84

Représentation des données textuelles

```
from sklearn.feature_extraction.text import TfidfVectorizer
import nltk
texte = ["La vie est douce","La vie est tranquille, est belle, est douce",
        "le corona-virus est méchant"]
texte=netoyage(texte)
vect = TfidfVectorizer()
T= vect.fit_transform(texte)
dictionnaire_des_mots=vect.vocabulary_
print("dictionnaire_des_mots :", dictionnaire_des_mots)
liste_des_mots=list(dictionnaire_des_mots.keys())
print("liste_des_mots :", liste_des_mots)
Matrice_sparse_correspondante=T.toarray()
print("Matrice_sparse_methode_predefinie:\n")
affiche(Matrice_sparse_correspondante)
#on donne un poids important aux tokens qui apparaissent souvent dans un
#document en particulier mais pas dans tous les documents du corpus
print("Matrice_sparse obtenue par notre methode:\n")
affiche(matrice_sparse(dictionnaire_des_mots,texte))
```

```
dictionnaire_des_mots : {'vie': 5, 'douce': 2, 'tranquille': 4, 'belle': 0, 'corona': 1, 'virus': 6,
                        'méchant': 3}
liste_des_mots : ['vie', 'douce', 'tranquille', 'belle', 'corona', 'virus', 'méchant']
Matrice_sparse_methode_predefinie:

[[0.  0.  0.71 0.  0.  0.71 0. ]
 [0.56 0.  0.43 0.  0.56 0.43 0. ]
 [0.  0.58 0.  0.58 0.  0.  0.58]]
Matrice_sparse obtenue par notre methode:

[[0.  0.  0.46 0.  0.  0.46 0. ]
 [0.35 0.  0.23 0.  0.35 0.23 0. ]
 [0.  0.46 0.  0.46 0.  0.  0.46]]
```

85

Application de la régression Logistique sur les Spams

```
import numpy as np
import pandas
spams = pandas.read_table("D:\\SMS SpamCollection.txt",sep="\t",header=0)
spamsTrain, spamsTest = train_test_split(spams,train_size=0.7,random_state=1)
from sklearn.feature_extraction.text import CountVectorizer
parseur = CountVectorizer()
XTrain = parseur.fit_transform(spamsTrain['message'])
mdtTrain = XTrain.toarray()
from sklearn.linear_model import LogisticRegression
modelFirst= LogisticRegression()
#essayer cette version, pourquoi ça ne marche pas ?
#modelFirst.fit(spamsTrain['message'],spamsTrain['classe'])
modelFirst.fit(mdtTrain,spamsTrain['classe'])
score1=modelFirst.score(mdtTrain, spamsTrain['classe'])
print("score sur data train:"+str(score1))
mdtTest = parseur.transform(spamsTest['message'])
#predTest = modelFirst.predict(mdtTest)
score2=modelFirst.score(mdtTest, spamsTest['classe'])
print("score sur data test:"+str(score2))
```

```
score sur data train:0.9976923076923077
score sur data test:0.9838516746411483
```

Sans binary=True

86

Application de la régression Logistique sur les Spams

```
import numpy as np
import pandas
spams = pandas.read_table("D:\\SMSSpamCollection.txt", sep="\t", header=0)
spamsTrain, spamsTest = train_test_split(spams, train_size=0.7, random_state=1)
from sklearn.feature_extraction.text import CountVectorizer
parseur = CountVectorizer(binary=True)
XTrain = parseur.fit_transform(spamsTrain['message'])
mdtTrain = XTrain.toarray()
from sklearn.linear_model import LogisticRegression
modelFirst = LogisticRegression()
#essayer cette version, pourquoi ça ne marche pas ?
#modelFirst.fit(spamsTrain['message'], spamsTrain['classe'])
modelFirst.fit(mdtTrain, spamsTrain['classe'])
score1 = modelFirst.score(mdtTrain, spamsTrain['classe'])
print("score sur data train:" + str(score1))
mdtTest = parseur.transform(spamsTest['message'])
#predTest = modelFirst.predict(mdtTest)
score2 = modelFirst.score(mdtTest, spamsTest['classe'])
print("score sur data test:" + str(score2))
```

```
score sur data train:0.9976923076923077
score sur data test:0.9838516746411483
```

Avec binary=True

87

Application de la régression Logistique sur les Spams

```
from sklearn import metrics
parseurBis = CountVectorizer(stop_words='english')
XTrainBis = parseurBis.fit_transform(spamsTrain['message'])
mdtTrainBis = XTrainBis.toarray()
modelBis = LogisticRegression()
modelBis.fit(mdtTrainBis, spamsTrain['classe'])
mdtTestBis = parseurBis.transform(spamsTest['message'])
score3 = modelBis.score(mdtTrainBis, spamsTrain['classe'])
print("score sur data train:" + str(score3))
score4 = modelBis.score(mdtTestBis, spamsTest['classe'])
print("score sur data test:" + str(score4))
```

```
score sur data train:0.9956410256410256
score sur data test:0.976076550239234
```

Sans stop_words

88

Application de la régression Logistique sur les Spams

```

1 from sklearn.feature_extraction.text import TfidfVectorizer
2 from sklearn import metrics
3 parseur3 = TfidfVectorizer()
4 XTrain3 = parseur3.fit_transform(spamsTrain['message'])
5 mdtTrain3 = XTrain3.toarray()
6 model3 = LogisticRegression()
7 model3.fit(mdtTrain3, spamsTrain['classe'])
8 mdtTest3 = parseur3.transform(spamsTest['message'])
9 score5=model3.score(mdtTrain3, spamsTrain['classe'])
10 print("score sur data train:"+str(score5))
11 score6=model3.score(mdtTest3, spamsTest['classe'])
12 print("score sur data test:"+str(score6))

```

```

score sur data train:0.9743589743589743
score sur data test:0.9712918660287081

```

Avec TfidfVectorizer

89

Application de la régression Logistique sur la reconnaissance des chiffres manuscrits


Refaire le TP 1 et remplacer le modèle par LogisticRegression

```
from sklearn.linear_model import LogisticRegression
```

90

Les arbres de décision


L'arbre de décision est un algorithme qui se base sur **un modèle d'arbre** pour définir la décision finale. Chaque nœud comporte une condition (une question), et les branchements sont en fonction de cette condition. Plus on descend dans l'arbre, plus on cumule les conditions.



91

Les arbres de décision

Considérez un scénario dans lequel une personne vous demande de lui prêter votre voiture pour une journée, et vous devez décider de lui prêter ou non ta voiture.



92

Les arbres de décision

L'utilisation des arbres de décision pour l'analyse prédictive présente plusieurs avantages:


- Les arbres de décision peuvent être utilisés pour prédire des valeurs continues et discrètes, c'est-à-dire qu'ils fonctionnent bien pour les tâches de régression et de classification.
- Ils nécessitent relativement moins d'efforts pour former l'algorithme.
- Ils peuvent être utilisés pour classer des données séparables de manière non linéaire.
- Ils sont rapides et efficaces par rapport à KNN et à d'autres algorithmes de classification (revoir TP1-TP2).

93


Choix de l'attribut de partitionnement

A	B	Classe
0	1	C1
0	0	C1
1	1	C2
1	0	C2

Partitionnement selon l'attribut A



Partitionnement selon l'attribut B



94

Choix de l'attribut de partitionnement

- Un arbre de décision représente **la suite** ($\neq$ de ensemble) de questions à poser pour classer un nouveau exemple.
- Dans l'exemple précédent c'est l'attribut A qui apporte plus d'information à la classification, il est mieux que l'attribut B.
- **L'objectif est de minimiser le nombre de questions à poser.**
- **Question:** comment quantifier l'information apportée par chaque attribut ?

95

Les algorithmes de construction d'un arbre de décision:

- ID3
- CART
- C4.5
- OC1
- SLIQ
- SPRINT

96

Les algorithmes de construction d'un arbre de décision:

L'entropie

- Une formule pour calculer l'homogénéité d'un échantillon.
- Un échantillon complètement homogène a une entropie de 0.
- La formule pour l'entropie est:

$$Entropie(S) = -1 * \sum_{c \in Classes} portion(c) * \log_2(portion(c))$$

Avec S est l'ensemble des instances (les lignes du data_train...)

Choix de l'attribut de partitionnement

Numéro de ligne	A	B	Classe
L1	0	1	C1
L2	0	0	C1
L3	1	1	C2
L4	1	0	C2

S: l'ensemble des instances contient les lignes L1,L2,L3 et L4.

Classes={C1,C2}

$$Entropie(S) = -1 * \sum_{c \in Classes(S)} portion(c) * \log_2(portion(c))$$

$$Entropie(S) = -1 * (0.5 * \log_2(0.5) + 0.5 * \log_2(0.5))$$

```
from math import *
>>> -1*(0.5*log2(0.5)+0.5*log2(0.5))
>>> 1.0
```

Choix de l'attribut de partitionnement

```
1 from numpy import *
2 import pandas
3 df = pandas.DataFrame([[0,1,'C1'],[0,0,'C1'],
4 [1,1,'C2'],[1,0,'C2']],columns=['A', 'B', 'Classes'])
5 df=df.to_numpy()
```

Numéro de ligne	A	B	Classe
L1	0	1	C1
L2	0	0	C1
L3	1	1	C2
L4	1	0	C2

```
1 def Entropie(S):
2     classes_distinctes=set(S[:,-1])
3     classes=list(S[:,-1])
4     s=0
5     for c in classes_distinctes:
6         p=classes.count(c)/len(classes)
7         s+=p*log2(p)
8     return(-1.0*s)
9 print(Entropie(df))
```

1.0

T15

99

Les algorithmes de construction d'un arbre de décision:
calcul du Gain d'information

- Il faut sélectionner l'attribut **avec le plus grand gain d'information**.
- Si on fait un partitionnement de l'ensemble d'instances **S** selon l'attribut **Attribut** nous obtenons des sous ensembles d'instances **S_i** avec i compris entre 1 et le nombre k de valeurs distincts de l'attribut **Attribut**:

$$S = \bigcup_{i=1}^k$$

- Il permet d'avoir l'attribut qui crée les branches les plus homogènes.
- Le gain d'information est basé sur la diminution de l'entropie après la division d'un ensemble de données par rapport à un attribut.

- **Le Gain d'information est donné par la formule:**

$$Gain(S, Attribut) = Entropie(S) - \sum_{i=1}^k p_i * Entropie(S_i)$$

Avec pi est la portion du sous ensemble d'instances **S_i** par rapport à l'ensemble d'instances **S**:

$$p_i = \frac{\text{Nombre de lignes de } S_i}{\text{Nombre de lignes de } S}$$


100

Choix de l'attribut de partitionnement

S: l'ensemble des instances
contient les lignes L1,L2,L3 et L4.
Classes={C1,C2}

Numéro de ligne	A	B	Classe
L1	0	1	C1
L2	0	0	C1
L3	1	1	C2
L4	1	0	C2

Partitionnement selon l'attribut A



S1 contient
{L1==C1
L2==C1}

S2 contient
{L3==C2
L4==C2}

$$E(S1) = -1 * (\text{portion}(C1) * \log_2(\text{portion}(C1)) + \text{portion}(C2) * \log_2(\text{portion}(C2)))$$
$$= -1 * (1 * \log_2(1)) = 0$$
$$\text{Gain}(S,A) = 1 - (\text{portion}(S1) * E(S1) + \text{portion}(S2) * E(S2))$$
$$= 1 - ((2/4) * E(S1) + (2/4) * E(S2))$$
$$= 1 - ((2/4) * (0) + (2/4) * (0))$$

Gain(S,A)= 1

101

Choix de l'attribut de partitionnement

```
1 def Gain_d_information(S,numero_colon_attribut):
2     classes=list(set(S[:,-1]))
3     valeurs_attribut=list(set(S[:,numero_colon_attribut]))
4     Si=[]
5     for i in range(len(valeurs_attribut)):
6         e=list(e)
7         val_attribut_pour_e=e[numero_colon_attribut]
8         numero_sous_ensemble=valeurs_attribut.index(val_attribut_pour_e)
9         Si[numero_sous_ensemble].append(e)
10    Si=array(Si) ; som=0
11    for sous_ensemble in Si:
12        som+=(len(sous_ensemble)/len(S))*Entropie(sous_ensemble)
13    return(Entropie(S)-som)
```

Numéro de ligne	A	B	Classe
L1	0	1	C1
L2	0	0	C1
L3	1	1	C2
L4	1	0	C2

```
1 print(Gain_d_information(df,0))
```

1.0

T15


102

Choix de l'attribut de partitionnement

S: l'ensemble des instances
contient les lignes L1,L2,L3 et L4.
Classes={C1,C2}

Número de ligne	A	B	Classe
L1	0	1	C1
L2	0	0	C1
L3	1	1	C2
L4	1	0	C2

Partitionnement selon l'attribut B



S1

{L2==C1
L4==C2}

S2

{L1==C1
L3==C2}

$$E(S1) = -1 * (\text{portion}(C1) * \log_2(\text{portion}(C1)) + \text{portion}(C2) * \log_2(\text{portion}(C2))) \\ = -1 * (0.5 * \log_2(0.5) + 0.5 * \log_2(0.5)) = 1.0$$

$$E(S2) = -1 * (\text{portion}(C1) * \log_2(\text{portion}(C1)) + \text{portion}(C2) * \log_2(\text{portion}(C2))) \\ = -1 * (0.5 * \log_2(0.5) + 0.5 * \log_2(0.5)) = 1.0$$

$$\text{Gain}(S,B) = 1 - (\text{portion}(S1) * E(S1) + \text{portion}(S2) * E(S2)) \\ = 1 - ((2/4) * E(S1) + (2/4) * E(S2)) = 1 - ((2/4) * (1.0) + (2/4) * (1.0)) = 0$$

Gain(S,B)=0 < Gain(S,A)=1 donc on doit faire le partitionnement selon A qui donne le plus grand gain.

103

Choix de l'attribut de partitionnement

```

1 def Gain_d_information(S,numero_colon_attribut):
2     classes=list(set(S[:,-1]))
3     valeurs_attribut=list(set(S[:,numero_colon_attribut]))
4     Si=[[ ] for i in range(len(valeurs_attribut))]
5     for e in S:
6         e=list(e)
7         val_attribut_pour_e=e[numero_colon_attribut]
8         numero_sous_ensemble=valeurs_attribut.index(val_attribut_pour_e)
9         Si[numero_sous_ensemble].append(e)
10    Si=array(Si) ; som=0
11    for sous_ensemble in Si:
12        som+=(len(sous_ensemble)/len(S))*Entropie(sous_ensemble)
13    return(Entropie(S)-som)

```

```
1 print(Gain_d_information(df,1))
```

0.0

T15

104

Choix de l'attribut de partitionnement

	A	B	C
1	Douleur	Inanime	Infarctus
2	poitrine	oui	oui
3	ailleurs	oui	oui
4	poitrine	non	oui
5	poitrine	oui	oui
6	ailleurs	non	oui
7	poitrine	non	non
8	ailleurs	non	non
9	poitrine	oui	non
10	ailleurs	non	non
11	ailleurs	non	non

La répartition sera faite alors avec l'attribut 1 (colonne infarctus) qui donne le plus grand gain d'information

```
1 from numpy import *
2 import pandas
3 fich=pandas.read_csv('D:\\donneesAD1.csv',sep=';')
4 Data_train=fich.iloc[:,:]
5 Data_train=Data_train.to_numpy()
6 print(Gain_d_information(Data_train,0))
7 print(Gain_d_information(Data_train,1))
```

0.02904940554533142
0.12451124978365313

T16

105

Choix de l'attribut de partitionnement: Indice de GINI

- Si on fait un partitionnement de l'ensemble d'instances **S** selon l'attribut **Attribut** nous obtenons des sous ensembles d'instances **S_i** avec i compris entre 1 et le nombre k de valeurs distincts de l'attribut **Attribut**:

$$S = \bigcup_{i=1}^k$$

- **L'indice de GINI** qui mesure le désordre est donné par la formule:

$$GINI(S) = 1 - \sum_{c \in \text{Classes}} (\text{portion}(c))^2$$

- On prend l'attribut qui donne la plus petite mesure de désordre:

$$\text{Mesure_de_Désordre}(S, \text{Attribut}) = \sum_{i=1}^k p_i * GINI(S_i)$$

Avec pi est la portion du sous ensemble d'instances **S_i** par rapport à l'ensemble d'instances **S**:

$$p_i = \frac{\text{Nombre de lignes de } S_i}{\text{Nombre de lignes de } S}$$

106

Choix de l'attribut de partitionnement: **Indice de GINI**

S: l'ensemble des instances
contient les lignes L1,L2,L3 et L4.
Classes={C1,C2}

Numéro de ligne	A	B	Classe
L1	0	1	C1
L2	0	0	C1
L3	1	1	C2
L4	1	0	C2

$$GINI(S) = 1 - \sum_{i=1}^k (p_i)^2$$

$$\begin{aligned} GINI(S) &= 1 - ((\text{portion}(C1))^2 + (\text{portion}(C2))^2) \\ &= 1 - ((0.5)^2 + (0.5)^2) \\ &= 0.5 \end{aligned}$$

107

Choix de l'attribut de partitionnement: **Indice de GINI**

```

1 def GINI(S):
2     clone_des_classes=list(S[:,-1])
3     classes=list(set(S[:,-1]))
4     k=len(classes) ; s=0
5     for i in range(k):
6         pi=clone_des_classes.count(classes[i])/len(S[:,-1])
7         s+=pi**2
8     return 1-s

```

```

1 from numpy import *
2 import pandas
3 df = pandas.DataFrame([[0,1,'C1'],[0,0,'C1'],
4 [1,1,'C2'],[1,0,'C2']],columns=['A', 'B', 'Classes'])
5 df=df.to_numpy()
6 print(GINI(df))

```

0.5

T17


108

Choix de l'attribut de partitionnement: **Indice de GINI**

S: l'ensemble des instances
contient les lignes L1,L2,L3 et L4.
Classes={C1,C2}

Numéro de ligne	A	B	Classe
L1	0	1	C1
L2	0	0	C1
L3	1	1	C2
L4	1	0	C2

Partitionnement selon l'attribut A



S1 contient
{L1===C1
L2===C1}

S2 contient
{L3===C2
L4===C2}

$$\text{GINI}(S1)=1-((\text{portion}(C1)*(\text{portion}(C1))) =0$$

$$\text{GINI}(S2)=1-((\text{portion}(C2)*(\text{portion}(C2))) =0$$


$$\text{GINI}(S)=1-\sum_{i=1}^k (p_i)^2$$

109

Choix de l'attribut de partitionnement: **Indice de GINI**

Numéro de ligne	A	B	Classe
L1	0	1	C1
L2	0	0	C1
L3	1	1	C2
L4	1	0	C2

Partitionnement selon l'attribut A



S1 contient
{L1===C1
L2===C1}

S2 contient
{L3===C2
L4===C2}

$$\text{GINI}(S1)=1-((\text{portion}(C1)*(\text{portion}(C1))) =0$$

$$\text{GINI}(S2)=1-((\text{portion}(C2)*(\text{portion}(C2))) =0$$

$$\text{Mesure_de_Désordre}(S, \text{Attribut}) = \sum_{i=1}^k p_i * \text{GINI}(S_i)$$

$$\text{Mesure_de_desordre}(S,A)=0.5*0+0.5*0=0$$

110

Choix de l'attribut de partitionnement: **Indice de GINI**

```
1 def Mesure_desordre(S,numero_colon_attribut):
2     classes=list(set(S[:,-1]))
3     valeurs_attribut=list(set(S[:,numero_colon_attribut]))
4     Si=[] for i in range(len(valeurs_attribut))
5     for e in S:
6         val_attribut_pour_e=e[numero_colon_attribut]
7         numero_sous_ensemble=valeurs_attribut.index(val_attribut_pour_e)
8         Si[numero_sous_ensemble].append(e)
9     Si=array(Si)
10    s=0
11    for sous_ensemble in Si:
12        s+=(len(sous_ensemble)/len(S))*GINI(sous_ensemble)
13    return(s)

1 from numpy import *
2 import pandas
3 df = pandas.DataFrame([[0,1,'C1'],[0,0,'C1'],
4 [1,1,'C2'],[1,0,'C2']],columns=['A', 'B', 'Classes'])
5 df=df.to_numpy()
6 A=Mesure_desordre(df,0);print(A)
```

0.0

T17


111

Choix de l'attribut de partitionnement: **Indice de GINI**

S: l'ensemble des instances
contient les lignes L1,L2,L3 et L4.
Classes={C1,C2}

Numéro de ligne	A	B	Classe
L1	0	1	C1
L2	0	0	C1
L3	1	1	C2
L4	1	0	C2

Partitionnement selon l'attribut B



S1
{L2==C1
L4==C2}

S2
{L1==C1
L3==C2}

$$GINI(S) = 1 - \sum_{i=1}^k (p_i)^2$$

GINI(S1)=1-((portion(C1)*(portion(C1) +(portion(C2)*(portion(C2)) = 1-(0.5²+0.5²) = 0.5
GINI(S2)= 1-((portion(C1)*(portion(C1) +(portion(C2)*(portion(C2)) = 1-(0.5²+0.5²) = 0.5


112

Choix de l'attribut de partitionnement: **Indice de GINI**

S: l'ensemble des instances
contient les lignes L1,L2,L3 et L4.
Classes={C1,C2}

Número de ligne	A	B	Classe
L1	0	1	C1
L2	0	0	C1
L3	1	1	C2
L4	1	0	C2

Partitionnement selon l'attribut B



S1

{L2==C1
L4==C2}

S2

{L1==C1
L3==C2}

$GINI(S1)=1-((\text{portion}(C1)*(\text{portion}(C1)) + (\text{portion}(C2)*(\text{portion}(C2))) = 1-(0.5^2+0.5^2) = 0.5$
 $GINI(S1)= 1-((\text{portion}(C1)*(\text{portion}(C1)) + (\text{portion}(C2)*(\text{portion}(C2))) = 1-(0.5^2+0.5^2) = 0.5$

$$\text{Mesure_de_Désordre}(S, \text{Attribut}) = \sum_{i=1}^k p_i * GINI(S_i)$$

$$\text{Mesure_de_desordre}(S,B)=0.5*0.5+0.5*0.5=0.5$$

Mesure_de_desordre(S,B)> Mesure_de_desordre(S,A) donc on doit faire le partitionnement selon A qui donne la plus petite mesure de désordre.

113

Choix de l'attribut de partitionnement: **Indice de GINI**

```
1 def Mesure_desordre(S,numero_colon_attribut):
2     classes=list(set(S[:,-1]))
3     valeurs_attribut=list(set(S[:,numero_colon_attribut]))
4     Si=[] for i in range(len(valeurs_attribut))
5     for e in S:
6         val_attribut_pour_e=e[numero_colon_attribut]
7         numero_sous_ensemble=valeurs_attribut.index(val_attribut_pour_e)
8         Si[numero_sous_ensemble].append(e)
9     Si=array(Si)
10    s=0
11    for sous_ensemble in Si:
12        s+=(len(sous_ensemble)/len(S))*GINI(sous_ensemble)
13    return(s)
```

```
1 from numpy import *
2 import pandas
3 df = pandas.DataFrame([[0,1,'C1'],[0,0,'C1'],
4 [1,1,'C2'],[1,0,'C2']],columns=['A', 'B', 'Classes'])
5 df=df.to_numpy()
6 A=Mesure_desordre(df,1);print(A)
```

0.5

T17

114

Choix de l'attribut de partitionnement: **Indice de GINI**

	A	B	C
1	Douleur	Inanime	Infarctus
2	poitrine	oui	oui
3	ailleurs	oui	oui
4	poitrine	non	oui
5	poitrine	oui	oui
6	ailleurs	non	oui
7	poitrine	non	non
8	ailleurs	non	non
9	poitrine	oui	non
10	ailleurs	non	non
11	ailleurs	non	non

La répartition sera faite alors avec l'attribut 1 (colonne infarctus) qui donne la plus petite mesure de désordre

```

1 from numpy import *
2 import pandas
3 fich=pandas.read_csv('D:\\donneesAD1.csv', sep=';')
4 Data_train=fich.iloc[:, :]
5 Data_train=Data_train.to_numpy()
6 print(Mesure_desordre(Data_train,0))
7 print(Mesure_desordre(Data_train,1))

```

0.48

0.4166666666666667

T18

115Choix de l'attribut de partitionnement: **Indice de GINI**

```

1 from numpy import *
2 import pandas
3 f = pandas.read_csv('D:\\balance-scale1.data')
4 print(f.shape[0])
5 Data_train=f.iloc[0:8,: ]
6 Data_train=Data_train.to_numpy()
7
8 def GINI(S):
9     S=array(S)
10    clone_des_classes=list(S[:,-1])
11    classes=list(set(S[:,-1]))
12    k=len(classes)
13    s=0
14    for i in range(k):
15        pi=clone_des_classes.count(classes[i])/len(S[:,-1])
16        s+=pi**2
17    return 1-s


```

T20

116

Choix de l'attribut de partitionnement: Indice de GINI

- Dans les exemples précédents nous avons considéré des attributs catégoriels: Douleur(poitrine, ailleurs), inanime(oui, non)
- Attributs continus (age, poids, taux de réussite,)
- Ici nous considérons que les attributs A,B et C sont continus




Si on prend un attribut Note_du_Bac (avec deux chiffres après la virgule), si on a un data set qui contient cet attribut. Combien de sous ensemble obtenez vous si vous faites un regroupement selon cet attribut ?

Exemple: Note_du_Bac Note_du_Bac=[8,9.2,9.6,11.5,13,14,15,17,16.6,18,19]
Gain d'information si on utilise la formule précédente ? Est-il maximal ?

117

Choix de l'attribut de partitionnement: Indice de GINI

```
22 def Mesure_desordre(S,numero_colon_attribut):
23     Bonne_mesure_desordre=+inf
24     Bonne_valeur_de_repartition=0
25     classes=list(set(S[:, -1]))
26     valeurs_attribut=list(set(S[:, numero_colon_attribut]))
27     valeurs_attribut.sort()
28     Gauche=[]; Droite=[]
29     for i in range(len(valeurs_attribut)-1):#Le dernier est le max !
30         v=valeurs_attribut[i]; Gauche.clear(); Droite.clear()
31         for e in S:
32             val_attribut_pour_e=e[numero_colon_attribut]
33             if val_attribut_pour_e<=v:
34                 Gauche.append(e)
35             else:
36                 Droite.append(e)
37         pGau=len(Gauche)/len(S)
38         pDr=len(Droite)/len(S)
39         mesure=(pGau)*GINI(Gauche)+(pDr)*GINI(Droite)
40         if mesure<Bonne_mesure_desordre:
41             Bonne_mesure_desordre=mesure
42             Bonne_valeur_de_repartition=v
43     return(Bonne_mesure_desordre,Bonne_valeur_de_repartition)
```




Exemple: numero_colonne=1(B) et valeur=4
Gauche=[L1,L2,L3,L5,L8] et Droite=[L4,L6,L7]

118

Choix de l'attribut de partitionnement: Indice de GINI

```
1 print(Mesure_desordre(Data_train,0))
2 print(Mesure_desordre(Data_train,1))
3 print(Mesure_desordre(Data_train,2))
```

```
(0.1875, 1)
(0.20833333333333326, 1)
(0.35714285714285715, 2)
```




T20

119

Choix de l'attribut de partitionnement: Indice de GINI

```
42 def meilleur_attribut_meilleure_valeur(S):
43     meilleur_attribut=0
44     meilleure_val=0
45     meilleure_mesure=-inf
46     for num_attribut in range(len(S[0])-1):
47         mesure,valeur=Mesure_desordre(S,num_attribut)
48         if mesure<meilleure_mesure:
49             meilleure_val=valeur
50             meilleure_mesure=mesure
51             meilleur_attribut=num_attribut
52     return meilleur_attribut,meilleure_val
53 print(meilleur_attribut_meilleure_valeur(Data_train))
```

```
(0, 1)
```



T20

120

Matrice de confusion

Définition: Matrice de confusion

Soit un Data_test qui contient m échantillons (m exemples) dont les classes sont "Positif " ou " Négatif ". Avec un modèle de ML on classe ces m échantillons. Ces échantillons seront réparties en 4 groupes:

- Le premier groupe contient les Vp échantillons +(positifs) qui sont classés +
- Le deuxième contient les Fp échantillons + qui sont classés -
- Le troisième groupe contient les Vn échantillons - qui sont classés -
- Le quatrième groupe contient les Fn échantillons - qui sont classés +

Matrice de confusion :

	Classé +	Classé -
Exemple +	V _p	F _n
Exemple -	F _p	V _n

Taux d'erreur = 1 - taux de réussite(accuracy) = $\frac{F_p + F_n}{F_p + F_n + V_p + V_n}$

121

Matrice de confusion

Exemple: Matrice de confusion

Supposons dans l'exemple de détection des SMS spam (faux sms) des SMS ham (vrai SMS). Le classificateur a été testé par exemple sur 200 SMS.

		Classe estimée - (par le classificateur)	
		Ham	Spam
Classe réelle - (selon le destinataire humain des sms)	Ham	95 (vrais positifs)	5 (faux négatifs)
	Spam	3 (faux positifs)	97 (vrais négatifs)

Taux d'erreur = 1 - taux de réussite(accuracy) = accuracy = $\frac{\text{+} + \text{+}}{\text{+} + \text{+} + \text{+} + \text{+}}$

122

Les arbres de décision

```

1 import numpy as np
2 import pandas as pd
3 from sklearn.metrics import confusion_matrix
4 from sklearn.tree import DecisionTreeClassifier
5 from sklearn.metrics import *

data = pd.read_csv('D:\\balance-scale1.data').as_matrix()
# Printing the dataset shape
print ("Dataset Length: ", len(data))
print ("Dataset Shape: ", data.shape)
print(data)

```

[1 1 2 'oui']
[1 4 6 'oui']
[1 1 3 'oui']
[1 5 7 'non']
[2 2 3 'non']
[2 6 5 'non']
[2 8 9 'non']
[2 3 3 'non']
[2 6 9 'non']
[2 8 9 'non']
[1 8 7 'oui']
[1 9 6 'oui']
[1 0 4 'oui']

T19

Les arbres de décision

```

1 X = data[:,0:3]; Y = data[:,3] ; X_test=data[8:,0:3]; y_test=data[8:,3]
2 clf_gini = DecisionTreeClassifier(criterion = "gini")
3 clf_gini.fit(X, Y)
4 clf_entropy = DecisionTreeClassifier(criterion = "entropy")
5 clf_entropy.fit(X, Y)
6 print("Results Using Gini Index:")
7 y_pred_gini = clf_gini.predict(X_test)
8 print("Confusion Matrix: ",confusion_matrix(y_test, y_pred_gini))
9 print(X_test,y_test,y_pred_gini)
10 print ("Accuracy : ",accuracy_score(y_test,y_pred_gini)*100)
11 print("Results Using Entropy:")
12 y_pred_entropy = clf_entropy.predict(X_test)
13 print("Confusion Matrix: ",confusion_matrix(y_test, y_pred_entropy))
14 print ("Accuracy : ",accuracy_score(y_test,y_pred_entropy)*100)

```

T19

124

Les arbres de décision

Results Using Gini Index:

Confusion Matrix:

	prédite non	prédite oui
Les non	[2	0]
Les oui	[1	2]]

Classes correctes données par l'expert ['non' 'non' 'oui' 'oui' 'oui']

Classes prédites par AD-Gini ['non' 'non' 'non' 'oui' 'oui']

Accuracy : 80.0

Results Using Entropy:

Confusion Matrix: $\begin{bmatrix} 2 & 0 \\ 2 & 1 \end{bmatrix}$

Accuracy : 60.0

Le nombre d'exemples qui sont bien classés est égal à la trace de la matrice de confusion: $\text{trace}(\text{MC}) = \text{somme de la diagonale}(\text{MC})$

T19

125

Les arbres de décision


```
1 from sklearn.externals.six import StringIO
2 from IPython.display import Image
3 from sklearn.tree import export_graphviz
4 import pydotplus
```

```
1 dot_data = StringIO()
2 export_graphviz(clf_gini, out_file=dot_data,
3                 filled=True, rounded=True,
4                 special_characters=True)
5 graph = pydotplus.graph_from_dot_data(dot_data.getvalue())
6
7 svg_graph = graph.create_svg()
8 svg = open('gini_tree.svg', 'wb')
9 svg.write(svg_graph)
10 svg.close()
11 Image(graph.create_png())
```

T19

126


Les arbres de décision



Le data train $S = \{L1, L2, L3, L4, L5, L6, L7, L8\}$ contient 8 échantillons (samples=8)
 5 échantillons ont la classe "non" et 3 échantillons ont la classe "oui" (value=[5,3])

127

Les arbres de décision



La condition $X_0 \leq 1.5$ (ici X_0 = colonne A) permet de diviser l'ensemble $S = \{L1, L2, L3, L4, L5, L6, L7, L8\}$ en deux ensembles de cardinal 4:
 $S1 = \{L1, L2, L3, L4\}$ et $S2 = \{L5, L6, L7, L8\}$


Les échantillons de $S1$ sont ceux qui vérifient la condition:

$X_0 \leq 1.5$ (le mot True), dans $S1$: 3 échantillons ont la classe "oui" et

1 échantillon a la classe "non", donc l'ensemble $S1$ n'est pas homogène !

128


Les arbres de décision



La condition $X_2 \leq 6.5$ (ici X_2 = colonne C) permet de diviser l'ensemble $S1=\{L1,L2,L3,L4\}$ en deux ensembles :
 $S3=\{L1,L2,L3\}$ et $S4=\{L4\}$
Les échantillons de $S3$ sont ceux qui vérifient la condition: $X_2 \leq 6.5$
dans $S3$, tous les échantillons ont la classe "oui" et $S3$ est homogène
Les échantillons de $S4$ sont ceux qui ne vérifient pas la condition: $X_2 \leq 6.5$
dans $S4$, tous les échantillons ont la classe "non" et $S4$ est homogène

129


Les arbres de décision



La condition $X_0 \leq 1.5$ (ici X_0 = colonne A) permet de diviser l'ensemble $S=\{L1,L2,L3,L4,L5,L6,L7,L8\}$ en deux ensembles de cardinal 4:
 $S1=\{L1,L2,L3,L4\}$ et $S2=\{L5,L6,L7,L8\}$
Les échantillons de $S2$ sont ceux qui ne vérifient pas la condition: $X_0 \leq 1.5$ (le mot False) et ils sont tous dans la classe "non"

130


Les arbres de décision



Les échantillons de S2 sont ceux qui ne vérifient pas la condition: $X_0 \leq 1.5$ (le mot False) et ils sont tous dans la classe "non" donc S2 est homogène,

131

Les arbres de décision




```
1 fich=pandas.read_csv('D:\\balance-scale1.data')
2 Data_train=fich.iloc[:8,:]
3 Data_train=Data_train.to_numpy()
4 print(GINI(Data_train))
5 print(meilleur_attribut_meilleure_valeur(Data_train))
```

0.46875
(0, 1)

Tp 21

132

Les arbres de décision



```

1 Data_train=array([[1, 1, 2, 'oui'],[1, 4, 6, 'oui'],
2                   [1, 1, 3, 'oui'],[1, 5, 7, 'non']])
3 print(GINI(Data_train), end=' ')
4 print(Mesure_desordre(Data_train,0), end=' ')
5 print(Mesure_desordre(Data_train,1), end=' ')
6 print(Mesure_desordre(Data_train,2), end=' ')
7 print('--->'+str(meilleur_attribut_meilleure_valeur(Data_train)))


```

0.375 (inf, 0) (0.0, '4') (0.0, '6') --->(1, '4')

Tp 21

133

Les arbres de décision



```

1 from numpy import *
2 import pandas
3 fich=pandas.read_csv('D:\\balance-scale1.data')
4 Data_train=fich.iloc[:8,:]
5 Data_train=Data_train.to_numpy()
6 print(Entropie(Data_train))
7 print(Mesure_Gain_d_information_continue(Data_train,0), end=' ')
8 print(Mesure_Gain_d_information_continue(Data_train,1), end=' ')
9 print(Mesure_Gain_d_information_continue(Data_train,2), end=' ')


```

Tp 22

0.954434002924965

(0.5487949406953987, 1) (0.46691718668869947, 1) (0.20443400292496505, 6)

Les arbres de décision



S1

A,B,C,Y	
1,1,2,oui	L1
1,4,6,oui	L2
1,1,3,oui	L3
1,5,7,non	L4

```

1 Data_train=array([[1, 1, 2, 'oui'],[1, 4, 6, 'oui'],
2                   [1, 1, 3, 'oui'],[1, 5, 7, 'non']])
3 print(Entropie(Data_train))
4 print(Mesure_Gain_d_information_continue(Data_train,0), end=' ')
5 print(Mesure_Gain_d_information_continue(Data_train,1), end=' ')
6 print(Mesure_Gain_d_information_continue(Data_train,2), end=' ')
7

```

0.8112781244591328

(0, 0) (0.8112781244591328, '4') (0.8112781244591328, '6')

Tp 22

135

Les arbres de décision

```

1 def transformer_colText_Num(Data,num):
2     if(type(Data[0][num])==str):
3         Valeurs=list(set(Data[:,num]))
4         for i in range(len(Data[:,num])):
5             Data[i][num]=Valeurs.index(Data[i][num])

```

```

1 data = pd.read_csv('D:\\donneesAD.csv',sep=';').as_matrix()
2 print(data)
3 for i in range(data.shape[1]-1):
4     transformer_colText_Num(data,i)
5 print(data)

```

Tp 23

	Douleur	Age	Inanime	Infarctus	
	poitrine	45	oui	oui	[0 45 1 'oui']
	ailleurs	25	oui	oui	[2 25 1 'oui']
	poitrine	35	non	oui	[0 35 0 'oui']
	Tete	70	oui	oui	[1 70 1 'oui']
	ailleurs	34	non	oui	[2 34 0 'oui']
	poitrine	60	non	non	[0 60 0 'non']
	ailleurs	67	non	non	[2 67 0 'non']
	Tete	52	oui	non	[1 52 1 'non']
	ailleurs	58	non	non	[2 58 0 'non']
	ailleurs	34	non	non	[2 34 0 'non']

136

Les arbres de décision

```

1 X = data[:,0:3]; Y = data[:,3] ; X_test=data[8:,0:3]; y_test=data[8:,3]
2 clf_gini = DecisionTreeClassifier(criterion = "gini")
3 clf_gini.fit(X, Y)
4 print("Results Using Gini Index:")
5 y_pred_gini = clf_gini.predict(X_test)
6 print("Confusion Matrix: ",
7       confusion_matrix(y_test, y_pred_gini))
8 print ("Accuracy : ",
9       accuracy_score(y_test,y_pred_gini)*100)

```

Results Using Gini Index:
 Confusion Matrix: [[1 1]
 [0 0]]
 Accuracy : 50.0

```

1 from sklearn.externals.six import StringIO |
2 from IPython.display import Image
3 from sklearn.tree import export_graphviz
4 import pydotplus

```

Tp 23

137

Les arbres de décision

```

1 from sklearn.externals.six import StringIO |
2 from IPython.display import Image
3 from sklearn.tree import export_graphviz
4 import pydotplus

```

```


1 dot_data = StringIO()
2 export_graphviz(clf_gini, out_file=dot_data,
3                 filled=True, rounded=True,
4                 special_characters=True)
5 graph = pydotplus.graph_from_dot_data(dot_data.getvalue())
6
7 svg_graph = graph.create_svg()
8 svg = open('gini_tree.svg', 'wb')
9 svg.write(svg_graph)
10 svg.close()
11
12 Image(graph.create_png())

```

Tp 23

138

Les arbres de décision



Tp 23

139

Les arbres de décision: Credit Scoring

Le processus d'acceptation d'un crédit à la consommation doit être très rapide en particulier lorsque les clients ont besoin d'un crédit en magasin au moment de leur achat (exemple : paiement en trois fois sans frais, etc.).

Depuis très longtemps, les banques et les organismes de crédit ont développé des méthodes automatiques et instantanées de notation de la solvabilité des clients et de leur capacité à rembourser le crédit. Ces outils sont très utiles pour une acceptation rapide d'octroi de crédit, mais également pour déterminer le montant de l'enveloppe d'autorisation de crédit ou pour effectuer le suivi du risque des clients et des portefeuilles de prêts.

Le score de crédit est une fonction qui attribue une valeur de qualité de crédit à un client ou un prêt en fonction de variables explicatives telles que le ratio d'endettement de l'emprunteur, son comportement de compte ou tout autre grandeur qui est corrélée au défaut de l'emprunteur.

140

Les arbres de décision

```

1 X_test=np.array(x_basic_te); y_test=np.array(y_te)
2 print(X_test[127])
3 print(model.predict([X_test[127]]),end=' '); print(y_test[127])

```

```

[1.57000000e+04 8.77540000e+04 1.03045000e+05 2.10000000e+01
 0.00000000e+00 0.00000000e+00 1.47450177e+02 4.00000000e+00
 2.30000000e+01 2.91817426e+01]
[0] 0

```

```

1 print(X_test[0])
2 print(model.predict([X_test[0]]),end=' '); print(y_test[0])

```

```

[2.16000000e+04 1.54991000e+05 1.01776049e+05 8.92226814e+00
 2.00000000e+00 4.00000000e+00 1.65600830e+02 0.00000000e+00
 4.30000000e+01 3.80149173e+01]
[1] 1

```

143