



ANNEE UNIVERSITAIRE 20___ / 20___

Niveau d'études (Ex : 2^{ème} année) : _____

Épreuve de : _____

Note de
l'épreuve

(1) Le candidat doit inscrire ici : ses noms, prénoms, lieu et date de naissance, puis rabattre suivant le pointillé le coin de la copie et le coller.

Il est interdit au candidat de signer sa copie ou d'y inscrire un signe quelconque pouvant en indiquer la provenance.

Ne pas mettre de colle sur la partie grisée

(1) Nom :
Prénoms :
Né(e) à :
le :

Ouvrir ici ▲

Nombre d'intercalaires _____ A _____, le 16/01/ 20 24

lolo@univ.fr

APPRENTISSAGE STATISTIQUE

Préambule

Apprentissage Statistique = Machine Learning (ML)
= Data Science

Historique

* 1920 - 1970 : Stat Inférentielle } stat
- Expériences planifiées } paramétrique
- Test de modèle }

* 1970 - 1980 : 1^{ère} période des stats non paramétriques
- 1^{ère} apparition des réseaux de neurones

* 1990 : - Jeux de données non planifiés.
- Apprentissage de ML

* 2000 : Explosion du nombre de variables
(p = nbre de variable $\gg n$ = nombre de données)

- Sélection d'un modèle
- Sélection de dimension.

* 2010 : Explosion des ressources en données.

- Explosion des ressources en calcul

- Retour des réseaux de neurones
- Théorie de l'optimisation

II/ Estimation VS Apprentissage

* Estimation : On cherche à approcher au mieux le "vrai" modèle.

• $\leq 1 \quad y = f(x) + \varepsilon \rightarrow \text{bruit}$

On cherche $\hat{f}$ très proche de f .

* Apprentissage : On cherche à prédire y .

$$y = f(x) + \varepsilon$$

On veut f très proche de y .

II/ Apprentissage Supervisé VS non Supervisé.

* Supervisé : Soit le couple (X, Y) et :

$$y = f(x) + \varepsilon$$

On observe un échantillon iid, $(x_i, y_i)_{i=1}^n$

On veut prédire y à partir de x

2 cas possibles.

Régression	Classification
$y \in \mathbb{R} (\mathbb{R}^d)$	$y \in N (\mathbb{Z})$

* Non Supervisé : On cherche à "comprendre" x à partir d'un échantillon $(x_i, y_i)_{i=1}^n$ iid.

- Estimation de densité
- Clustering
- Recherche de lien causal

APPRENTISSAGE SUPERVISE

Soit (X, Y) un couple de v.a.

* But: prédire Y à partir de X .

* Matériel: des observations $\{(X_i, Y_i)\}_{i=1}^n$

Choix possible de X et Y

X peut être	Y peut être
numérique	numérique ($\mathbb{R}$): Régression
qualitatif	qualitatif (ou discret): classification
mix des 2	

I-1) Le problème basique

À partir des observations $\{(X_i, Y_i)\}_{i=1}^n$,

On veut construire ~~une~~ un prédicteur (machine)

p^n tel que $\hat{Y}_{\text{new}} = p^n(X_{\text{new}})$.

On apprend p^n à partir des observations

Propriétés souhaitées

- Précision sur les données.

⇒ Les prédictions faites sur les données d'apprentissage doivent être proches des vraies valeurs (connues).


(2)

* Généralisabilité


⇒ Les prédictions faites sur de nouvelles données doivent aussi être proches des vraies valeurs.

I.2) Sous apprentissage et Sur apprentissage

• Fonction à apprendre




• Les données qu'on aimerait avoir



NB: on a jamais cela en pratique.

• Les données qu'on a :



Pour avoir de bonnes performances

- * Avoir le meilleur algo (+)
- * Avoir de meilleurs variables (+++)
- * Avoir de meilleurs données (++++)

CLASSIFICATION Binaire

I Généralités

Soit (x, y) un couple de v.a.c. $\mathbb{R}^d \times \{0, 1\}$

On veut à partir de x prédire le label y (i.e prendre une décision).

D'un point de vue des maths :

une "règle de classification" est une fonction

$$g: \mathbb{R}^d \rightarrow \{0, 1\}.$$

On dit qu'il y a une erreur si $g(x) \neq y$.

On note la proba d'erreur d'une règle de classification par :

$$L(g) = \mathbb{P}(g(x) \neq y) \text{ avec } L = \text{"Loss"}.$$

On note (μ, π) la loi du couple (x, y)

$x \sim \mu$

π : régression conditionnelle y sur x ($\mathbb{E}(y|x)$).

$$\text{c-a-d: } \forall A \in \mathcal{B}(\mathbb{R}^d), \mu(A) = \mathbb{P}(x \in A)$$

$$\forall x \in \mathbb{R}^d, \pi(x) = \mathbb{P}(y=1|x=x) = \mathbb{E}(y|x=x)$$

$$\text{preuve: } \mathbb{E}(y|x=x) = 1 \times \mathbb{P}(y=1|x=x) + 0 \times \mathbb{P}(y=0|x=x)$$

③ 16.12.24

Question ? Existe-t-il une règle meilleure que toutes les autres ? Oui

II Règle de Bayes (Bonne règle)

On appelle règle de Bayes, la fonction g^* définie par:

$$g^*(x) = \begin{cases} 1, & \text{si } P(Y=1|X=x) > P(Y=0|X=x) \\ & (h(x) > 1/2) \\ 0, & \text{sinon} \end{cases}$$

Théorème:

$\forall g: \mathbb{R}^d \rightarrow \{0,1\}$ règle de décision

$$P(g^*(x) \neq y) \leq P(g(x) \neq y)$$

$$\text{i.e. } L^* = L(g^*), \quad L^* = \inf_g (L(g)).$$

Preuve:

Soit g une règle de décision

$$P(g(x) \neq y | X) = 1 - P(g(x) = y | X)$$

$$= 1 - (P(Y=1, g(x)=1 | X) + P(Y=0, g(x)=0 | X))$$

$$= 1 - (\mathbb{1}_{g(x)=1} P(Y=1|X) + \mathbb{1}_{g(x)=0} P(Y=0|X))$$

$$\text{or } h(x) = P(Y=1|X) \text{ et } P(Y=0|X) = 1 - h(x).$$

$$\text{Donc: } = 1 - (\mathbb{1}_{g(x)=1} h(x) + \mathbb{1}_{g(x)=0} (1-h(x))).$$

$$\text{D'autre part, } P(g(x) \neq y | X) - P(g^*(x) \neq y | X)$$

$$= h(x) (\mathbb{1}_{g^*(x)=1} - \mathbb{1}_{g(x)=1}) + (1-h(x)) (\mathbb{1}_{g^*(x)=0} - \mathbb{1}_{g(x)=0})$$

$$\text{Donc: } = \underbrace{(2h(x)-1)}_A \underbrace{(\mathbb{1}_{g^*(x)=1} - \mathbb{1}_{g(x)=1})}_{B}$$

2 cas possibles

$$* A > 0 \Rightarrow g^*(x) = 1$$

$$\hookrightarrow \pi(x) > \frac{1}{2}$$

$$\Rightarrow B = 0 \text{ ou } 1 \Rightarrow A \times B > 0.$$

$$* A < 0 \Rightarrow g^*(x) = 0$$

$$\Rightarrow B = 0 \text{ ou } -1 \Rightarrow A \times B > 0.$$

$$R_7: \\ E(P(Y|X)) \\ = P(Y)$$

Dans tous les cas,

$$P(g(x) \neq Y | X) - P(g^*(x) \neq Y | X) > 0$$

$$\text{d'où: } E[P(g(x) \neq Y | X) - P(g^*(x) \neq Y | X)] > 0$$

$$E(P(g(x) \neq Y | X)) > E(P(g^*(x) \neq Y | X))$$

$$P(g(x) \neq Y) > P(g^*(x) \neq Y)$$

D'où le résultat.

Rq: On note L^* le risque de Bayes

$$L^* = E(\min(\pi(x), 1 - \pi(x)))$$

Problème: g^* dépend de la loi de (X, Y) qui est inconnue.

Et la place on dispose d'un échantillon

$$S_n = \{(X_i, Y_i)\}_{i=1}^n \text{ iid de même loi que } (X, Y)$$

On va chercher une règle $g_n(x, S_n)$ pour estimer Y à partir de x et S_n .

$$\text{On note } g_n(x) = g_n(x, S_n)$$

③ 16.01.24
ao

Le processus de création de g_n est appelé apprentissage supervisé.

La proba d'erreur :

$$L(g_n) = P(g_n(x) \neq g_n(x, s_n) | s_n).$$

On va vouloir g_n qui minimise L .

II) Consistance faible/universelle/forte

On veut approcher L^* ,

On voudrait que d'une certaine façon, $L(g_n) \xrightarrow{n \rightarrow +\infty} L^*$.

On parle de règle de consistance

Def 1. Consistance faible/forte

Etant donnée une distribution de couple (X, Y) , une règle g_n est dite faiblement consistante/convergente

* Si $\mathbb{E}[L(g_n)] = P(g_n(X) \neq Y) \xrightarrow{n \rightarrow +\infty} L^*$

et fortement consistante

* Si $L(g_n) \xrightarrow{n \rightarrow +\infty} L^*$ p.s

① Consistance forte $\Rightarrow$ Consistance faible

② Consistance faible $\Leftrightarrow$ Consistance en probab.

⚠ Ces nombres sont relatifs à distribution de (X, Y) fixée.

Def 2: Consistance universelle

g_n est universellement (fortement)

consistante si elle l'est pour toute distribution de (X, Y)

Probleme: Comment construire des règles vérifiant ces propriétés?

II: 1) Outils probabilistes

* Théo de Borel Cantelli (adapté)

Soit X une v.a., X_n une suite de v.a. Si $\forall \varepsilon > 0$,
$$\sum_{i=1}^n \mathbb{P}(|X_i - X| > \varepsilon) < \infty \Rightarrow X_n \rightarrow X \text{ p.s.}$$

Ainsi, pour avoir une consistance d'une règle g_n , on va chercher à avoir des inégalités du type

$$\mathbb{P}(|Z_n - Z^*| > \varepsilon) \leq k e^{-n c \varepsilon^2}$$

(k, c des cte > 0)

II.2) Méthode Plug-in

Soit (X, Y) couple de v.a., μ loi de X

π : régression conditionnelle de $Y|X$.

$$g^*(x) = \begin{cases} 1 & \text{si } \pi(x) > 1/2 \\ 0 & \text{sinon} \end{cases}$$

L'idée du plug-in, c'est de remplacer $\pi(x)$ par un estimateur $\pi_n(x)$.

$$g_n(x) = \begin{cases} 1 & \text{si } \pi_n(x) > 1/2 \\ 0 & \text{sinon} \end{cases}$$

L'espoir c'est que si $\pi_n(x)$ est proche de $\pi(x)$, alors g_n sera proche de g et Z_n sera proche de Z^* .

*Théorème:

(Soit π_n un estimateur de π , g_n la règle associée, alors
 $0 \leq g_n - Z^* \leq 2 \int_{\mathbb{R}^d} |\pi_n(x) - \pi(x)| p \, dx$

R_T : La majoration par $2 \int_{\mathbb{R}^d} |\pi_n(x) - \pi(x)| p \, dx$ n'est pas optimale.

Elle suffit pour montrer la consistance mais ne permet pas d'étudier des vitesses de convergence.

16.01.24

(4)

En fait, on a pas vraiment besoin que π_n soit très proche de π sur tout $\mathbb{R}^d$, ce qui est critique c'est que :

$$\begin{cases} \pi_n(x) > 1/2 & \text{si } \pi(x) > 1/2 \\ \pi_n(x) < 1/2 & \text{si } \pi(x) < 1/2. \end{cases}$$

La zone critique est la zone où $\pi(x) \approx 1/2$.

Une hypothèse utile est souvent

$$P(|\pi_n(x) - 1/2| \leq t) \leq C t^\alpha, \quad \forall 0 < t \leq t^*$$

avec $\alpha = C t_0 > 0$.

II.3) Théo de Stone (1977)

Le théo établit la consistance de certains estimateurs π_n de π .

On considère des estimateurs de type "moyenne locale", i.e qui s'écrivent

$$\pi_n(x) = \sum_{i=1}^n W_{n,i}(x) Y_i, \quad x \in \mathbb{R}^d \text{ avec}$$

$(W_{n,1}^{(x)}, \dots, W_{n,n}^{(x)})$ un vecteur de poids tel que chaque $W_{n,i}^{(x)}$ est une fct mesurable de x et $(X_1, \dots, X_n)$, mais $\perp$ de $Y_1, \dots, Y_n$.

Chp.

Intro

Les paires (X_i, Y_i) dont X_i est proche de x sont plus intéressantes que les autres.

Les poids devraient être plus importants pour les Y dont les X_i associés sont proches de x .


Ex: Estimateur à noyau naïf

$$\hat{\mu}_n(x) = \frac{\sum_{i=1}^n \mathbb{1}_{\|x - x_i\| \leq h} Y_i}{\sum_{i=1}^n \mathbb{1}_{\|x - x_i\| \leq h}} \quad \begin{matrix} h > 0 \\ h = \text{"fenêtre"} \end{matrix}$$

$$W_{n,i} = \frac{\mathbb{1}_{\{\|x - x_i\| \leq h\}}}{\sum_{i=1}^n \mathbb{1}_{\{\|x - x_i\| \leq h\}}} = \begin{cases} \frac{1}{\#B(x,h)} & \text{si } x_i \in B(x,h) \\ 0 & \text{sinon} \end{cases}$$

En moyenne les Y_i dont les X_i sont dans une boule de centre x et de rayon h .

Ex:



$$\begin{aligned} \hat{\Pi}_n(x) &= 1 \times \frac{1}{3} + 1 \times \frac{1}{3} + 0 \times \frac{1}{3} + \dots \\ \hat{\Pi}_n(x) &= \frac{2}{3} \end{aligned}$$

* Estimation à noyau (Nadaraya-Watson)

$$W_{n,i} = \frac{k\left(\frac{x - X_i}{h}\right)}{\sum_{i=1}^n k\left(\frac{x - X_i}{h}\right)}$$

$$\hat{\Pi}_n(x) = \frac{\sum_{i=1}^n Y_i k\left(\frac{x - X_i}{h}\right)}{\sum_{i=1}^n k\left(\frac{x - X_i}{h}\right)}$$

où k = un noyau (une densité de proba)

Ex: Dans $\mathbb{R}$, k est un noyau Gaussien.

* Estimation des k plus proches voisins

- On fait la moyenne des k y_i dont les x_i sont les plus proches de x .
- On peut prendre des poids $\propto \frac{1}{\|x - x_i\|}$ en fonction des distances $\|x - x_i\|$, mais $W_{n,i} = 0$ si x est pas dans les k -plus proches voisins.

23.01.24

P) On considère les hypothèses suivantes

i) $\exists c_1 > 0$ tq pour toute fonction $f: \mathbb{R}^d \rightarrow \mathbb{R}$ (bornée) avec $\mathbb{E}(\|f(X)\|) < \infty$, $\mathbb{E}(\sum |W_{n,i}(X)| \cdot \|f(X)\|) \leq c_1 \mathbb{E}(\|f(X)\|)$, $\forall n \geq 1$.

ii) $\exists c_2 > 0$ tq $\mathbb{P}(\sum |W_{n,i}(X)| \leq c_2) = 1$, $\forall n \geq 1$.

iii) $\forall \epsilon > 0$, $\sum |W_{n,i}(X)| \cdot \|x_i - x\| > \epsilon \xrightarrow[n \rightarrow \infty]{\mathbb{P}} 0$.

iv) $\sum W_{n,i}(X) \xrightarrow[n \rightarrow \infty]{\mathbb{P}} 1$.

v) $\max_{1 \leq i \leq n} |W_{n,i}(X)| \xrightarrow[n \rightarrow \infty]{\mathbb{P}} 0$.

23-09-24
-0-0-

③

• Si i) - iv) sont vérifiées pour toute distribution de X , alors Π est universellement L^p consistant ($\forall p \geq 1$).
i.e $\forall p \geq 1, E(|\Pi_n(X) - \Pi(X)|^p) \rightarrow 0$

Rq: C'est presque une condition nécessaire et suffisante.

Discussions des hypos

i) hypothèse technique pour éviter de supposer que Π est continue.

ii) et iv) disent que la somme des poids est bornée et tend $\mathbb{P} \rightarrow 1$.

iii) $\Rightarrow$ que le poids global des valeurs hors d'un voisinage de $X \rightarrow 0$.

Asymptotiquement, l'estimateur ne dépend que des données proches de lui-même (moyenne locale)

v) $\Rightarrow$ que tous les poids deviennent
petits quand n grandit
($\Rightarrow$ une ϕ donnée ne peut décider
seule)

Cas classique

$(w_{n,1}(x), \dots, w_{n,n}(x))$ est un vecteur de $\mathbb{P}$.

(i.e. $w_{n,i} \geq 0, \sum w_{n,i} = 1$).

ii) et iv) sont vérifiées.

Les autres sont une condition nécessaire
et suffisante pour la convergence.

- On va utiliser ce théo pour notre
problème de classification

Rappel: $\hat{g}(x) = \begin{cases} 1 & \text{si } \pi(x) > 1/2 \\ 0 & \text{sinon} \end{cases}$

Théo de Stone pour la classification

Si les hypo du théo de Stone sont
vérifiées pour toute distribution de (X, Y) ,
alors $\hat{g}$ est universellement consistante.

ie $\mathcal{H}(\mathcal{L}(\mathcal{S})) \rightarrow \mathcal{L}^*$ $\forall$ distribution (X, Y)

RÈGLES NON-PARAMÉTRIQUES ET DATA-SPLITTING

I | Règle des k plus proches voisins (kppv)

Soit (X, Y) couple de v.a. $\rightarrow \mathbb{R}^d \times \{0, 1\}$

$$S_n = \{(X_i, Y_i)\}_{i=1}^n \text{ iid.}$$

Pour x fixé ($x \in \mathbb{R}^d$), on réordonne l'échantillon $O_n(x) = \{(X_{(i)}^{(x)}, Y_{(i)}^{(x)})\}_{i=1}^n$

des distances croissantes $\|X_{(i)} - x\|$.

$$O_n(x): \|X_{(1)} - x\| \leq \|X_{(2)} - x\| \leq \dots \leq \|X_{(n)} - x\|$$

Def 1: Soit $(W_{n,1}, \dots, W_{n,n})$ un vecteur de poids de somme 1. La règle des kppv s'écrit $\forall x \in \mathbb{R}^d$.

$$\hat{g}_n(x) = \begin{cases} 1 & \text{si } \sum W_{n,i} \mathbb{1}_{\{Y_i=1\}} > \sum W_{n,i} \mathbb{1}_{\{Y_i=0\}} \\ 0 & \text{sinon} \end{cases}$$

Prq: On prend $W_{n,i} \propto \frac{1}{\|X_{(i)} - x\|}$ en i.

$\Rightarrow$ On ~~vote~~ fait un vote pondéré des plus proches voisins.

Le choix classique est de prendre

$$\{W_{n,i}\}_{i=1}^n = \underbrace{\left\{ \frac{1}{k}, \frac{1}{k}, \dots, \frac{1}{k}; 0, \dots, 0, 0 \right\}}_{k \text{ fois}}$$

① On obtient la règle classique des k pr.

$$\hat{g}_{n,k}(x) = \begin{cases} 1 & \text{si } \sum_{i=1}^k y_i = 1 \\ 0 & \text{sinon} \end{cases} \rightarrow \sum_{i=1}^k y_i = 0$$

⚠ On privilégie k impaire

I.2) Théo de convergence

* Théo de Stone

Si $k_n \xrightarrow{n \rightarrow \infty} +\infty$ et $\frac{k_n}{n} \xrightarrow{n \rightarrow \infty} 0$, alors

pour toute loi (X, Y) , $\mathbb{E}(\hat{g}_{n,k}) \rightarrow \mathbb{E}^*$
 c'est la consistance faible universelle.

• $k_n \rightarrow +\infty \Rightarrow$ On prend suffisamment de voisins pour ne pas rester dans un voisinage temps de x .

Cela évite le sur-apprentissage.

• $\frac{k_n}{n} \rightarrow 0 \Rightarrow$ On prend relativement peu de voisins pour ne pas considérer un voisinage temps grand

Cela évite le sous-apprentissage.

23.01.24

⑥

⚠ Difficulté : Calibren $\frac{1}{2}$.

Théo I.3.1 / $\lim_{n \rightarrow +\infty} L(g_n, \mathbb{R}) = L_{\text{ENN}}$

On connaît L_{ENN} en fait de τ (Esiap)

Théo I.3.2

$$L^* \leq \dots \leq L(2k+1)_{nn} \leq L(2k-1)_{nn} \leq L_{3nn} \leq L_{1nn} \leq 2L^*$$

Cela est intéressant pour ce que ça dit que si $L^* \approx 0$, les règles R_{nn} sont bonnes.

Théo I.3.3 : Pour toute distribution de (X, Y) et $R \geq 3$

$$L_{Rnn} \leq L^* \left(1 + \frac{cte}{\sqrt{R}} \right) \text{ à peu près !}$$

30.04.24!

Solut^o des paramètres Datto Splitting V. total

Toutes les méthodes précédentes dépendent des paramètres à calibrer $(R, h, \dots)$.

I/ Risque Empirique

On décompose l'erreur

$$L(g_n) - L^* = \underbrace{(L(g_n) - \inf_{g \in \mathcal{C}} L(g))}_{(1)} + \underbrace{(\inf_{g \in \mathcal{C}} L(g) - L^*)}_{(2)}$$


$\mathcal{C}$ une famille de règles possible
(par exemple $\mathcal{C} = R_{PPV}$)

(1) = erreur d'estimation

(2) = erreur d'approximation

↳ erreur structurelle que l'on connaît en se restreignant à une famille de règles.

Elle est indépendante du choix du paramètre.



on se focalise sur l'erreur d'estimateur.

On voudrait choisir g_n^* la meilleure règle dans $\mathcal{Z}$:

$$g_n^* \in \underset{g \in \mathcal{L}}{\operatorname{argmin}} L(g).$$

Cela est impossible parce qu'on ne connaît pas la loi de (X, Y) et donc on ne peut pas calculer $L(g)$.

A la place, on minimise le risque empirique :

$$\hat{L}_n(g) = \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{\{g(X_i) \neq Y_i\}} \quad \left(\begin{array}{l} \text{approximatif} \\ \text{Moyenne - Central} \end{array} \right)$$

$$\hat{g}_n^* \in \underset{g \in \mathcal{Z}}{\operatorname{argmin}} \hat{L}_n(g)$$

I.1) Cas des KPPV

$g_{n,k}$ règle des KPPV $\{ (X_{(i)}^{(n)}, Y_{(i)}^{(n)}) \}_{i=1}^n$

échantillon ordonné selon les distances croissantes $\|X_i - x\|$.

$$g_{n,k}^{(n)} = \begin{cases} 1 & \text{si } \sum_{i=1}^k \mathbb{1}_{\{Y_i = 1\}} > \sum_{i=1}^k \mathbb{1}_{\{Y_i = 0\}} \\ 0 & \text{sinon.} \end{cases}$$

$$g_{n,k}^* \in \operatorname{argmin} \hat{L}_n(g)$$

$$\Leftrightarrow k^* \in \operatorname{argmin}_{k \in \{1, \dots, n\}} \hat{L}(g_n, k)$$

$$\text{Alors, } g_{n,k}^* = g_{n,k^*}$$

Pourquoi ça ne marche pas ?

On cherche à optimiser + estimateur sur les données qui ont servi à la ~~construction~~ construire.

$\hat{L}_n$ n'est pas consistant car $\hat{L}_n$ et $g_{n,k}$ dépendent des mêmes données.

$$\frac{1}{n} \sum_{i=1}^n \ell(g_{n,k}(x_i) \neq y_i) \rightarrow L^* \text{ si } g_{n,k} \perp (x_i, y_i)$$

On sur-apprend.

II. Validation croisée

II-1) Hold-out (Data-splitting)

13.02.24

APP. STAT

①

II.3 / constance

* Data splitting

On veut calculer / contrôler

$$L(g_n^*) = \inf_{g_m \in \mathcal{L}_m} L(g_m)$$

$$\downarrow$$

taille de A_m

$$L(g_n^*) = P(g_n^*(x) \neq y | S_n)$$

$$L(g_m) = P(g_m(x) \neq y | A_m) \quad | A_m \notin S_n$$

Il est facile de montrer que

$$L(g_n^*) - \inf_{g_m \in \mathcal{L}_m} L(g_m) \leq 2 \sup_{g_m \in \mathcal{L}_m} |\hat{L}_{m,l}(g_m) - L(g_m)|$$

on contrôle facilement les choses

si $\# \mathcal{L}_m$ est fini.

$$P \left\{ \sup_{g_m \in \mathcal{L}_m} |\hat{L}_{m,l}(g_m) - L(g_m)| > \varepsilon | S_n \right\} \leq 2 \times \# \mathcal{L}_m \cdot e^{-2\varepsilon^2}$$

$$\text{si } m = l = \frac{n}{2}$$

$$\mathbb{E}(L(g_m^*) - \inf_{g_m \in \mathcal{M}_m} L(g_m)) \leq 2 \sqrt{\frac{\log(2e \# \mathcal{M}_m)}{m}}$$

Lorsq $\# \mathcal{M}_m$ est infini, on utilise la théorie de Vapnik-Chervonenkis

Dimension V.C

I/Erreur Estimation / Approximation

Soit $\mathcal{C}$ une famille de règles et
On veut choisir une règle dans $\mathcal{C}$.

fg:

$$L(g) = \mathbb{P}(g(x) \neq y) \quad \text{soit proba de}$$

$$\inf_{g \in \mathcal{C}} \mathbb{P}(g(x) \neq y).$$

On minimise le risque empirique

$$g_n^* \in \arg \min_g \underbrace{\frac{1}{n} \sum_{i=1}^n \mathbb{1}_{g(x_i) \neq y_i}}_{\hat{L}_n(g)}$$

(en utilisant une procédure de validation croisée)

$$L(g_n^*) = \mathbb{P}(g_n^*(x) \neq y | S_n)$$

on espère que

$$L(g_m^*) \approx \inf_{g \in C} L(g) \text{ [vrai si } C \text{ est fini]}$$

Rappel: $L(g_m^*) - L^*$

$$= \underbrace{\left\{ L(g_m^*) - \inf_{g \in C} L(g) \right\}}_{\text{Erreur d'estimation}} + \underbrace{\left\{ \inf_{g \in C} L(g) - L^* \right\}}_{\text{Erreur d'approximation}}$$

• On se concentre sur l'erreur d'estimation

Lemme (Important)

$$1) L(g_n^*) - \inf_{g \in C} L(g) \leq 2 \sup_{g \in C} |\hat{L}_n(g) - L(g)|$$

$$2) |\hat{L}_n(g_n^*) - L(g_n^*)| \leq \sup_{g \in C} |\hat{L}_n(g) - L(g)|$$

Preuve

2) $\Rightarrow$ trivial

$$\begin{aligned} 1) & |L(g_n^*) - \inf_{g \in C} L(g)| \\ & \leq \underbrace{|L(g_n^*) - \hat{L}_n(g_n^*)|}_{(1)} + \underbrace{|\hat{L}_n(g_n^*) - \inf_{g \in C} L(g)|}_{(2)} \end{aligned}$$

$$\text{ona: } (1) \leq \sup_{g \in C} |\hat{L}(g) - L(g)|$$

$$\textcircled{2} = \left| \inf_{g \in C} \hat{L}_n(g) - \inf_{g \in C} L(g) \right| \leq \sup_{g \in C} |\hat{L}_n(g) - L(g)|$$

Exo

$$\text{Prouver q: } \left| \inf_{x \in A} f(x) - \inf_{x \in A} g(x) \right| \leq \sup_{x \in A} |f(x) - g(x)|$$

q.q prouve (*).

Indicatio:

$$f(x) - g(x) \leq |f(x) - g(x)| \leq \sup_x |f(x) - g(x)|$$

$$\forall x, g(x) - f(x) \leq \sup_x |f(x) - g(x)| \quad \forall x$$

$$\Rightarrow f(x) \leq \sup_x |f(x) - g(x)| + g(x) \quad \forall x$$

$$g(x) \leq \sup_x |f(x) - g(x)| + f(x) \quad \forall x$$

Prendre l'inf intelligemment

II. Classe C de taille finie.

Tout repose sur l'inégalité de Hoeffding.

13.02.24

APP - STAT

②

Théorème II.1

$X_1, \dots, X_n$ v.a. ind bornées b.g. $f(a_i, b_i)_{i=1}^n$
 $P(X_i \in [a_i, b_i]) = 1$. on pose $S_n = \sum_{i=1}^n X_i$

$\forall \varepsilon > 0$

$$① P\{S_n - E(S_n) \geq \varepsilon\} \leq e^{\frac{-2\varepsilon^2}{\sum (b_i - a_i)^2}}$$

$$② P\{S_n - E(S_n) \leq -\varepsilon\} \leq e^{\frac{-2\varepsilon^2}{\sum (b_i - a_i)^2}}$$

$$③ P\{|S_n - E(S_n)| \geq \varepsilon\} \leq 2 e^{\frac{-2\varepsilon^2}{\sum (b_i - a_i)^2}}$$

Preuve

① Admis

② découle de ① (Exo).

③ découle de ① et ② (Exo).

Rq: $X_1, \dots, X_n$ n'ont pas besoin d'avoir la même loi.

Exemple fondamental (Exo)

$X_1, \dots, X_n$ iid $\sim B(p)$, alors

$$P\left(\left|\frac{S_n}{n} - p\right| \geq \varepsilon\right) \leq 2e^{\frac{-2n\varepsilon^2}{p(1-p)}}$$

on a.

$$X \sim \mathcal{B}(p) \Rightarrow [a_i, b_i] = [0, 1],$$

$$p = \mathbb{E}(X) = \mathbb{E}\left(\frac{S_n}{n}\right).$$

soit $\varepsilon > 0$.

$$\left|\frac{S_n}{n} - p\right| \geq \varepsilon \Leftrightarrow |S_n - np| \geq n\varepsilon$$

$$\Leftrightarrow \cancel{P(|S_n - \mathbb{E}(S_n)| \geq n\varepsilon)}$$

$$\Leftrightarrow P(|S_n - \mathbb{E}(S_n)| \geq n\varepsilon) \leq 2 e^{-\frac{2\varepsilon^2 n}{\mathbb{E}(X - p)^2} = n}$$

$$\Leftrightarrow P(|S_n - \mathbb{E}(S_n)| \geq n\varepsilon) \leq 2 e^{-2n\varepsilon^2}.$$

Théorème II.2

soi $\#C \leq N$, alors $\forall \varepsilon > 0$

$$P\left(\sup_{g \in C} |\hat{L}_n(g) - L(g)| > \varepsilon\right) \leq 2N e^{-2n\varepsilon^2}.$$

Preuve

• Soit de $Z_i = \mathbb{1}_{\{g(x_i) \neq y_i\}}$?

• Hoeffding sur $\sum Z_i$ (exemple fonctionnelle)

$$\begin{aligned} \bullet P\left(\sup_{g \in C} |\hat{L}_n(g) - L(g)| > \varepsilon\right) &= P(|\hat{L}_n(g) - L(g)| > \varepsilon) \\ &\leq \sum_{g \in C} P(|\hat{L}_n(g) - L(g)| > \varepsilon) \end{aligned}$$

ona: $z_i \sim p(\underbrace{p(g(x_i) \neq y_i)}_{L(\theta)})$

$$S_n = \sum z_i$$

$$\frac{S_n}{n} = \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{\{g(x_i) \neq y_i\}} = \hat{L}_n(\theta)$$

$$p = L(\theta)$$

Donc

$$\frac{S_n}{n} - p = \hat{L}_n(\theta) - L(\theta) \quad \text{Donc,}$$

$$\forall \theta, P(|\hat{L}_n(\theta) - L(\theta)| > \varepsilon) \\ = P\left(\left|\frac{S_n}{n} - p\right| > \varepsilon\right) \leq 2e^{-2n\varepsilon^2}$$

avec S_n somme de Bernoulli i.i.d

$$\text{Aussi, } P\left(\sup_{g \in C} |\hat{L}_n(g) - L(g)| > \varepsilon\right)$$

$$= P(\forall g \in C, |\hat{L}_n(g) - L(g)| > \varepsilon)$$

$$\leq \sum_{g \in C} P(|\hat{L}_n(g) - L(g)| > \varepsilon)$$

$$\leq \sum_{g \in C} 2e^{-2n\varepsilon^2} \leq 2N e^{-2n\varepsilon^2}$$

(parce que $\# C \leq N$)

NB: Cela est bien car nous pouvons intégrer sur $\mathbb{R}$.

Problème: général de cas $\# C = \infty$

$\Rightarrow$ théorie de V.C

III. La dimension en V.C

III.1) Passer de $\sup_{g \in C}$ à $\sup_{A \in \mathcal{A}}$

• ν la loi du couple (X, Y) .

$\forall A \in \mathcal{B}(\mathbb{R}^d) \times \{0, 1\}$

$$\nu(A) = \mathbb{P}((X, Y) \in A)$$

• ν_n la mesure empirique

$$\nu_n(A) = \frac{1}{n} \sum_{i=1}^n \mathbb{1}_{\{(X_i, Y_i) \in A\}}$$

$$L(g) = \mathbb{P}(g(X) \neq Y) = \mathbb{P}((X, Y) \in \{(x, y) : g(x) \neq y\})$$

$$= \nu(\underbrace{\{(x, y) : g(x) \neq y\}}_{A_g})$$

$$\hat{L}_n(g) = \nu_n(A_g)$$

13.02.24

APP. STAT

③

On peut réécrire

$$A_g = (\{x: g(x) = 1\} \times \{0\}) \cup (\{x: g(x) = 0\} \times \{1\})$$

On note: $\mathcal{A} = \{A_g, g \in \mathcal{C}\}$ ~~$\mathcal{A} = \{A_g, g \in \mathcal{C}\}$~~

$$\sup_{g \in \mathcal{C}} |\hat{L}_n(g) - L(g)| = \sup_{A \in \mathcal{A}} |\hat{V}_n(A) - V(A)|.$$

On se ramène à l'étude de la convergence de la mesure empirique

Propriétés:

1) $\forall A$ mesurable

$$|\hat{V}_n(A) - V(A)| \xrightarrow[n \rightarrow \infty]{P.S.} 0 \quad (LGN)$$

$$2) P(|\hat{V}_n(A) - V(A)| > \varepsilon) \leq 2e^{-2n\varepsilon^2} \quad (\text{Hoeffding})$$

3) Si $\mathcal{A}$ est de # fini (cardinal fini),

$$P(\sup_{A \in \mathcal{A}} |\hat{V}_n(A) - V(A)| > \varepsilon) \leq 2\#\mathcal{A} e^{-2n\varepsilon^2} \quad (\text{Théorème II.2})$$

4) Si $\mathcal{A}$ est l'ensemble de tous les boîtes de $\mathbb{R}^d \times [0, 1]$ (ENCLOSURE)

alors $\sup_{A \in \mathcal{A}} |V_n(A) - V(A)|$ ne peut cv
pour $\forall V$.

Conclusion: Il faut contrôler la
taille de $\mathcal{A}$

- On veut $\mathcal{A}$ grande pour
l'erreur d'approximati^{on}
- On veut $\mathcal{A}$ pas trop grande
pour contrôler $\sup_{A \in \mathcal{A}} |V_n(A) - V(A)|$

III.2) coefficient de sur-existence et dimension V.C.

On se donne $\mathcal{A}$ une famille
d'ensemble de $\mathbb{R}^d$, $z_1, \dots, z_n$ iid $\in \mathbb{R}^d$

$$\forall V(A) = P(Z \in A)$$

$$V_n(A) = \frac{1}{n} \sum \mathbb{1}_{\{Z_i \in A\}}$$

On veut des résultats sur la
convergence de $\sup_{A \in \mathcal{A}} |V_n(A) - V(A)|$

Def 1)


Soit $\mathcal{A}$ une famille d'ensemble mesurable de $\mathbb{R}^2$ et $(z_1, \dots, z_n) \in (\mathbb{R}^2)^n$

$N_{\mathcal{A}}(z_1, \dots, z_n)$ cardinal de $\{ \{z_1, \dots, z_n\} \cap A, A \in \mathcal{A} \}$


Lorsque $N_{\mathcal{A}}(z_1, \dots, z_n) = 2^n$, on dit que $\mathcal{A}$ pulvérise $\{z_1, \dots, z_n\}$.

Exemple :


Soit $\mathbb{R}^2$, $\mathcal{A} =$ ensemble des $1/2$ espaces de $\mathbb{R}^2$




$$\rightarrow \{ \{z_1, z_2\} \cap A \} = \emptyset$$



$$\rightarrow \{ \{z_1, z_2\} \cap A \} = \{z_1\}$$



$$\rightarrow \{z_1, z_2 \cap A\} = \{z_2\}$$



$$\rightarrow \{z_1, z_2 \cap A\} = \{z_1, z_2\}$$

Ainsi, $\mathcal{N}(z_1, z_2) = 2^2 = 4$

L'ensemble des $1/2$ espaces pulvérisée $\{z_1, z_2\}$.

Def 2

Le coeff de pulvérisation de A est

$$J_A(n) = \max_{(z_1, \dots, z_n) \in (\mathbb{R}^d)^n} \mathcal{N}_A(z_1, \dots, z_n)$$

Def 3

Soit une famille d'ensemble (mesurable)
le plus grand entier $k \geq 1$ tq

$S_A(k) = 2^k$ est appelé dimension v.c

13.02.24

APP - STAT

④

il est noté $\sqrt{A}$.



Si $S_A(k) = 2^k \quad \forall k > 1$, $\sqrt{A} = \infty$.

Rq:

• Plus A est grande, et plus on va pouvoir pulvériser en grand nombre de points.

• Pulvériser n points, c'est être capable d'isoler n'importe quelle sous-partie de ces n points.

Exemple 1 $A =$ disque de $\mathbb{R}^2$.



$\cdot z_1$

$\cdot z_2$

$$\rightarrow S_A(u) < 16.$$

$\cdot z_4$

$\cdot z_3$

$$\text{Donc, } V_A = 3$$

Exemple 2 : $A = \text{ellipse de } \mathbb{R}^2$

$\cdot z_1$

$\cdot z_2$

$$S_A(u) = 16$$



$$\text{Rq : } S_A(5) < 32.$$

$$\text{Donc } V_A = 4.$$

III- 3 | Exemple important

1) si A est de cardinal fini

$$S_A(n) \leq \#A, \forall n \geq 4.$$

pour definition $S_A(V_A) = 2^{V_A}$
 (car $\forall V_A \leq \max_k k \text{ t.f. } S_A(k) = 2^k$)

$$\Rightarrow 2^{V_A} \leq \#A$$

$$\Rightarrow V_A \leq \frac{\ln(\#A)}{\ln(2)} = \log_2(\#A)$$

2) Dans $\mathbb{R}$, $A = \{]-\infty, x], x \in \mathbb{R}\}$

$$S_A(\emptyset) = \emptyset \rightarrow \{\emptyset, \{x_1\}\}$$

$n=2$

$$\{\emptyset, \{x_1\}, \{x_1, x_2\}\} \rightarrow \{\emptyset, \{x_1\}, \{x_1, x_2\}\}$$

$$\rightarrow S_A(\emptyset) < 4$$

$$\Rightarrow V_A = 2$$

$$S_A(n) = n+1$$

3) Dans $\mathbb{R}$, $A = [a, b], a, b \in \mathbb{R}$.

$$x_1, \dots, x_n \Rightarrow \emptyset$$

$$\{x_1\}, \{x_2\}, \dots, \{x_n\}$$

$$\{x_1, x_2\}, \{x_2, x_3\}, \dots, \{x_{n-1}, x_n\}$$

$$\{x_1, x_2, x_3\}, \{x_2, x_3, x_4\}, \dots$$

$$\begin{matrix} 1 \\ \vdots \\ n \\ \vdots \\ n-1 \\ \vdots \\ 1 \end{matrix}$$

$$S_n(1) = 2^1 = 2$$

$$S_n(2) = 2^2 = 4$$

$$S_n(3) = 7 < 2^3 = 8$$

$$\sqrt{4} = 2$$

4) Résultat dans $\mathbb{R}^d$;

$$\bullet A = \{ [-\infty; a_1] \times \dots \times [-\infty; a_d] \}$$

$$\sqrt{A} = 1$$

$$\bullet A = \{ \text{rectangles de } \mathbb{R}^d \}, \sqrt{A} = d$$

$$\bullet A = \{ \text{famille des } \frac{1}{2} \text{ spaces linéaires} \\ \{ x \mid a_1 x_1 + a_2 x_2 + \dots + a_d x_d + b \geq 0 \} \}$$

$$\sqrt{A} \leq d + 1.$$

20/02/24 : IV : Convergence uniforme
de la mesure empirique

IV.1 : Le théorème de Vapnik-
Chervonenskis

théo: IV.1 (1971)

Théor

ν une mesure de proba sur $\mathbb{R}^d$,

$$N_n = \frac{1}{n} \sum_{i=0}^n \mathbb{1}_{\{x_i \in A\}},$$

$\mathcal{A}$ une famille d'ensemble mesurables.

$\forall \varepsilon > 0 \quad \forall n \geq 1, \quad \varepsilon > 0,$

$$P\left\{\sup_{A \in \mathcal{A}} |\bar{V}_n(A) - \nu(A)| > \varepsilon\right\} \leq 8 \int_{\mathcal{A}} \nu e^{-\frac{n\varepsilon^2}{32}}$$

①

Rep: ① Si $\mathcal{A}$ est de

$$\int_{\mathcal{A}} \nu \leq \# \mathcal{A} \quad \text{et donc}$$

la série $\int_{\mathcal{A}} \nu e^{-\frac{n\varepsilon^2}{32}}$ est une série convergente ($\sum_{n=1}^{\infty} < \infty$),

et donc $\sup_{A \in \mathcal{A}} |\bar{V}_n(A) - \nu(A)| \xrightarrow{p.s.} 0$

② Si $\int_{\mathcal{A}} \nu$ est un polynôme en n degré fini, la série converge.

$$(S_A^{(n)} = \sum_{i=0}^n a_i n^i) : \text{VIA}$$

⑧ si $S_A^{(n)} = 2^n$, la série ne converge pas.

IV.2 Application

* si $A =]-\infty; z]$, $z \in \mathbb{R}$, $S_A^{(n)} = n+1$

$$P\left\{\sup_{A \in \mathcal{A}} |U_n(A) - V(A)| > \varepsilon\right\} \leq 8(n+1) e^{-\frac{n\varepsilon^2}{32}}$$

$$P\left\{\sup_{z \in \mathbb{R}} |F_n(z) - F(z)| > \varepsilon\right\}.$$

Convergence uniforme de la
fonction de répartition empirique
(Glivenko - Cantelli)

$$\sup |F_n - F| \rightarrow 0 \text{ p.s.}$$

* Cas général

Lemme IV.4

X une v.a positive tq $\forall \varepsilon > 0$

$$P(X > \varepsilon) \leq C e^{-2n\varepsilon^2}$$

$$\text{Alors } E[X^2] \leq \frac{\log(Ce)}{2n}$$

$$E[X] \leq \sqrt{\frac{\log(Ce)}{2n}}$$

Preuve

$$E[X^2] = \int_0^{+\infty} P(X^2 > \varepsilon) d\varepsilon$$

$$= \int_0^u \underbrace{P(X^2 > \varepsilon)}_{\leq 1} d\varepsilon + \int_u^{+\infty} P(X^2 > \varepsilon) d\varepsilon$$

$$\leq u + \int_u^{+\infty} P(X > \sqrt{\varepsilon}) d\varepsilon$$

$$\leq u + \int_u^{+\infty} C e^{-2n\varepsilon} d\varepsilon$$

Il faut trouver u^* qui minimise cette borne.

On trouve sur $E[X^2] \leq \frac{\log(Ce)}{2n}$.

Rq: $E(f(Z)) \geq f(E(Z))$ si f est convexe

$E(f(Z)) \leq f(E(Z))$ si f est concave.

C'est l'inégalité de JENSEN

$$z = x^2, f(x) = \sqrt{x} \text{ concave}$$

$$\mathbb{E}(x) = \mathbb{E}(\sqrt{x^2}) \leq \sqrt{\mathbb{E}(x^2)}$$

Corollaire IV.1 (IMPORTANT)

$$\mathbb{P}\left(\sup_{A \in \mathcal{A}} |V_n(A) - V(A)| \leq 8 \sqrt{\frac{\log(8eS_n(\mathcal{A}))}{n}}\right)$$

IV.3 Coefficient de pulvérisation et dimension Vapnick - C

$$S_n(\mathcal{A}) = \text{coef de pulvérisation}$$

$$= \max_{(z_1, \dots, z_n) \in (\mathbb{R}^d)^n} K_n(z_1, \dots, z_n)$$

~~V_A~~ = dimension V.C de $\mathcal{A}$

= le plus grand k tq

$$f_A(k) = 2^k$$

$$= \infty \text{ si } S_n(\mathcal{A}) = 2^k \forall k$$

20/02/24

App - STAT

(2)

Propriété (Importante)

* Si ~~V_A~~ $V_A < \infty$, $S_A(n) \leq (n+1)^{V_A}$
 $\Rightarrow \begin{cases} \text{soit } S_A(n) = 2^n \quad \forall n \geq 1 \quad (V_A \neq \infty) \\ \text{soit } S_A(n) \leq (n+1)^{V_A}, \quad \forall n \geq 1 \quad (V_A < \infty) \end{cases}$

$\Rightarrow$ soit $S_A(n) = 2^n$, soit il est polynomial en n .

Résultat final

Si $V_A < \infty$, $\exists c > 0$ tq
 $\mathbb{P}(\sup_{A \in \mathcal{A}} |V_n(A) - V(A)| \leq c \sqrt{\frac{V_A \log(n)}{n}})$

Si $V_A < \infty$, on a une convergence
en $\sqrt{\frac{\log(n)}{n}}$

05/03/24

App Stat. Maths

①

II/ Probleme de Robustesse

III. 1 Existence d'adversaires

Principal contributeur: Ian Goodfellow

2013: "Intriguing properties of
Neural Networks"

Possible de perturber très fortement
les prédictions d'un réseau en
perturbant très faiblement les
données à classer.

La perturbation dépend de
la données à classer.

La perturbation dépend de la
donnée d'entrée.

2017: "Universal Adversarial perturbations"
→ perturbation est $\perp$ de la donnée d'entrée.

La principale méthode: Goodfellow 2015
 "Adversarial training"

Principe général:

On considère une fct de coût J
 (pour $J = \hat{L}_n$), $J(w, x, y)$
 poids entrée label.

on veut minimiser J en

w , on va regarder une
 version perturbée.


$$\tilde{J}(w, x, y) = \alpha J(w, x, y) + (1-\alpha) J(w, \underset{x+v}{\text{perturb}(x)}, y)$$

$$\alpha \in [0, 1].$$

en essayant de prendre la
 perturbation qui "embête" le
 plus le réseau.

N. 1. Generative adversarial Network

Le but est de générer des fausses données les plus "vraies possible".



La fonction cible $V(G, D)$

$$V(G, D) = \mathbb{E}_x [\log(D(x))]$$

$$+ \mathbb{E}_z [\log(1 - D(G(z)))]$$

On optimise le F.A.N. en cherchant $\min_G \max_D V(G, D)$

En pratique

- 1) on part d'un jeu de données réelles et on entraîne D (on vise $D(x) = 1$).
- 2) on génère avec G et on entraîne D (on vise $D(G(z)) = 0$).
- 3) on fixe D et on entraîne G (on vise $D(G(z)) = 1$).

max
 D

min
 G

On itère (1) + (2), et 3.

Autre schéma de sur-apprentissage

On part d'un échantillon


$\{(x_i, y_i)\}_{i=1}^n$ et on veut

construire une règle g de $\mathbb{R}^d \rightarrow \mathbb{R}$ minimisant $P(g(x) \neq y)$

On a vu que selon la complexité
de la famille de règles
(et le choix des paramètres)

On peut aller du sous-
apprentissage (trop simple et on
prédit tjr même chose)
au sur-apprentissage

(temps spécifique aux données
d'apprentissage)



Pour le projet
cocher noyau naïf & moyenne
mobile.

$$\frac{1}{\#B(x, h)} \sum_{x' \in B(x, h)} \{ y_i = 1 \}$$

12.03.24

Cours App-STAT

①

Marie 2/04/24
pas
cours

Apprentissage flou

Ref. * Michel Grabisch, 2020

* Louis Laogne, "Éléments de logique

* Fuzzy models for pattern recognition

Intro

La théorie des ensembles flous développée en 1965 par Lotfi Zadeh. C'est une théorie de l'algèbre abstraite qui a pour but de représenter l'imprécision relative à l'appartenance à certaines classes d'objets. Cette théorie sert de fondement à la logique floue.

Très rapidement en apprentissage on s'est aperçu que la notion de classes

(notamment pour la reconnaissance de flous) pouvait bénéficier de cette théorie.

En effet, une classe est souvent représentée comme un groupe d'individus partageant certaines similitudes. Ces similitudes peuvent $\pm$ fortes entre les individus d'une même classe, et un individu peut présenter des similitudes avec des individus d'autres classes.

Ainsi, l'appartenance d'un individu ne peut être réduite à une seule classe mais "distribuée" sur plusieurs classes. Cela rejoint le formalisme des ensembles flous.

Cependant, si les ensembles flous peuvent
sembler constituer un cadre
naturel pour la notion de classes,
force est de constater que les
algo classiques considèrent
implicitement les classes comme l'ont été.

Les méthodes Bayésiennes donnent
bien une proba d'appartenance à une
classe, mais cette notion de
proba (associé à la notion de
fréquence d'apparition d'un événement
lorsqu'on répète une expérience)
est ~~fortement~~ fondamentalement
différente de la notion d'appartenance
à une classe (par laquelle
repose la théorie "floue").

Exemple: L l'ensemble des liquides
 $\mathcal{L}$ le sous-ensemble pour les
liquides potables
 $\bar{\mathcal{L}}$ le sous-ensemble pour des
poisson.

On est dans le désert, sans
eau depuis longtemps et on
trouve 2 bouteilles A et B. Il
faut choisir laquelle boire.

On a 2 infos.

* Le degré d'appartenance de B
à $\mathcal{L}$ est 0,9 (Echelle $= [0, 1]$)

* La proba que $A \in \mathcal{L}$ est 0,9.

Si on choisit B, on sait que le
liquide est "probablement" potable
(ne contiendra pas les substances
les plus toxiques),

Si on choisit A, on a 9 chances sur
10 d'avoir un liquide parfaitement

12.03.24

Cours App - STAT

②

possible, mais 1 chance de mourir

II - Ensemble flous - Relation flous

II.1) Ensemble flous (1965)

Dans le cadre de la théorie des ensembles conventionnels, les éléments appartiennent ou non (de manière binaire) à des ensembles.

Dans le cadre de la théorie floue, l'appartenance à un ensemble n'est pas si tranchée.

Pour représenter ça mathématiquement, en introduisant une fonction "d'appartenance" d'un élément à un ensemble, les ensembles flous sont définis de la

manière suivante.

Def II.1 : Ensemble flou

Un ensemble flou A est un ensemble, caractérisé par une fonction d'appartenance $f_A: E \rightarrow [0, 1]$, où E est un espace quelconque.

Si $f_A(x)$ est proche de 1, x a un fort degré d'appartenance à A .

Si $f_A(x)$ est proche de 0, x a un faible degré d'appartenance à A .

Si $f_A: E \rightarrow \{0, 1\}$, on retombe sur la théorie conventionnelle.

Def II.2 : Ensemble vide

A (ensemble flou) est vide si $f_A = 0$.

Def II. 3 égalité

2 ensemble A et B sont égaux si
 $f_A = f_B$ ou $\forall x, f_A(x) = f_B(x)$.

Def III: 4 complémentaire

A ensemble flou, $\bar{A}$ son complémentaire

défini par $f_{\bar{A}}(x) = 1 - f_A(x)$.

Def II-5 : inclusion

A, B flous : A est inclus dans B ($A \subset B$)

ou $f_A(x) \leq f_B(x) \quad \forall x$

théorème classique

si $x \in A$ alors $x \in B$

$x \in A \Rightarrow f_A(x) = 1 \Rightarrow f_B(x) \geq f_A(x) = 1 \Rightarrow f_B(x) = 1$
 $\Rightarrow x \in B$.

Def II. 6 Union

A, B flows $C = A \cup B$ est un ensemble
flow. Donc $f_C(x) = \max(f_A(x), f_B(x))$
 $\forall x \in E$.

the. classique

- si $x \in A, x \notin B, f_A(x) = 1, f_B(x) = 0, f_C(x) = 1$
- si $x \in B, x \notin A, f_A(x) = 0, f_B(x) = 1, f_C(x) = 1$
- si $x \in A, x \in B, f_A(x) = 1, f_B(x) = 1, f_C(x) = 1$
- si $x \notin A, x \notin B, f_A(x) = 0, f_B(x) = 0, f_C(x) = 0$

Proposition II. 1

$$A \cup (B \cap C) = (A \cup B) \cap C$$

$$A \subset A \cup B$$

$$B \subset A \cup B$$

$$\begin{aligned}
 f_{A \cup (B \cap C)}(x) &= \max \{ f_A(x), f_{B \cap C}(x) \} \\
 &= \max \{ f_A(x), \max \{ f_B(x), f_C(x) \} \} \\
 &= \max \{ f_A(x), f_B(x), f_C(x) \} \\
 &= \max \{ \max \{ f_A(x), f_B(x) \}, f_C(x) \} \\
 &= f_{(A \cup B) \cup C}(x)
 \end{aligned}$$

$$\begin{aligned}
 f_{A \cup B}(x) &= \max \{ f_A(x), f_B(x) \} \geq f_A(x) \\
 \Rightarrow A &\subset A \cup B.
 \end{aligned}$$

Def. II.7 intersection
 A, B flows, $C = A \cap B$ défini par

$$f_C(x) = \min \{ f_A(x), f_B(x) \}$$

P. II. 2

- $A \cap (B \cap C) = (A \cap B) \cap C$
 - $A \cap B \subset A$
 - $A \cap B \subset B$
- Exo.

P. II. 3

- $\overline{(A \cup B)} = \overline{A} \cap \overline{B}$
- $\overline{A \cap B} = \overline{A} \cup \overline{B}$

~~$C \cap (A \cup B) = (C \cap A) \cup (C \cap B)$~~

~~$C \cup$~~

- $C \cap (A \cup B) = (C \cap A) \cup (C \cap B)$
 - $C \cup (A \cap B) = (C \cup A) \cap (C \cup B)$
- Exo

II. 2) Relation Jones

$D \subset \mathbb{R}^d$, $k \geq 1$ (cashe conventionel pour commencer)

Une partition de D en k

clusters / classes est donnée par
des fonctions indicatrices

$N_1, \dots, N_k$

$$N_i(x) = \begin{cases} 1 & \text{si } x \in \text{classe } i, i \in \{1, \dots, k\} \\ 0 & \text{sinon.} \end{cases}$$

Une relation ("sure" / "nette") r dans D

est définie comme une fonction

$$r: D \times D \longrightarrow \{0, 1\}$$

On dit que x et y ($\in D$)
partagent une relation si

$$r(x, y) = 1.$$

formalisation matricielle

$$D = \{x_1, \dots, x_n \mid x_i \in (\mathbb{R}^d)^n$$

$$N_i(x_j) = N_{ij} \quad \begin{cases} i \in \{1, \dots, k\} \\ j \in \{1, \dots, n\} \end{cases}$$

$$R(x_i, x_j) = R_{ij} \quad \begin{cases} i \in \{1, \dots, n\} \\ j \in \{1, \dots, n\} \end{cases}$$

M_k = ensemble de toutes les matrices de partition U .

$$\left\{ \begin{array}{l} \dim(U) = k \times n \\ U[i, j] = p_{ij} \in [0, 1] \\ \sum_{i=1}^k p_{i, j} = 1 \quad (\text{chq donnée } e \text{ a une unique classe}). \\ \sum_{j=1}^n p_{i, j} \geq 0 \quad \forall i \quad (\text{pas de classe violée}). \end{array} \right.$$

Pour $U \in M_k$, on associe une matrice de relation $R = \{r_{ij}, e\}$ avec $\dim(R) = n \times n$ définie par:

$$r_{ij}, e = \begin{cases} 1 & \text{si } p_{i, j} = p_{i, e} = 1, \text{ pour un certain } i \\ 0 & \text{sinon.} \end{cases}$$

12.03.24

Concours App-STAT

(4)

~~Ex~~

Exemple

3 données
2 classe

($n = 3$)
($k = 2$)

$$U = \begin{pmatrix} x_1 & x_2 & x_3 \\ 0 & 0 & 1 \\ 1 & 1 & 0 \end{pmatrix}$$

$x_1 \in \text{classe } 2$

$x_2 \in \text{classe } 2$

$x_3 \in \text{classe } 1$

2ème classe 2ème donnée

→ Matrice de relation R associée

$$R = \begin{matrix} & x_1 & x_2 & x_3 \\ \begin{matrix} x_1 \\ x_2 \\ x_3 \end{matrix} & \begin{pmatrix} 1 & 1 & 0 \\ 1 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix} \end{matrix}$$

NB: se poser la qti si on est
tout ensemble.

* Cache flow

Def II-8 Matrice flow

$U \in \Pi_{k,k}$ (ensemble des partitions
flow à k classe)

1. $\dim(U) = k \times n$ ($n = \text{nbr de données}$
à classes)

$U[i, j] = p_{ij} \in [0, 1]$ (probab. si
la donnée j
appartient à la
classe i)

$$\sum_{i=1}^k p_{i,j} = 1$$

$$\sum_{j=1}^n p_{i,j} > 0$$

On peut définir une matrice de
relations flou associée à U .
Def II.1 - Matrice de relation flou

$U \in M_{k,n}$, la matrice R_U
associée est définie, pour

$$\begin{cases} 1 \leq j \leq n \\ 1 \leq l \leq k \end{cases}$$


$$R_U[j, l] = R_{jl} = \max_{1 \leq i \leq k} (\min(p_{ij}, p_{il}))$$

Exemple 3 données ($n=3$)
& classes ($k=2$)

$$U = \begin{pmatrix} x_1 & x_2 & x_3 \\ 0,3 & 0,2 & 0,9 \\ \textcircled{0,7} & 0,8 & 0,1 \end{pmatrix} \quad \begin{matrix} x_1 \text{ Ensemble} \\ \text{plutôt} \end{matrix}$$

$P_{2,1}$
 4 degré d'appartenance de x_1 à la classe 2.

x_1 ressemble plutôt à la classe 2



$$x = P_{1,1} = \max \{ \min \{ P_{1,1}, P_{1,2} \}, \min \{ P_{2,1}, P_{2,2} \} \} \quad \text{cor}$$

$$R_j = \begin{matrix} & x_1 & x_2 & x_3 \\ x_1 & \boxed{0,7} & 0,7 & 0,3 \\ x_2 & 0,7 & 0,8 & 0,2 \\ x_3 & 0,3 & 0,2 & 0,9 \end{matrix}$$

x_1 et x_2 ———— plutôt ensemble
 x_1 et x_3 ———— pas ensemble
 x_2 et x_3 ———— plutôt pas ensemble.

III - Classification

III-1. KppV

$S = \{x_1, \dots, x_m\}$ dont on connaît
les labels (pas flou)

$$p_{i,j} \in \{0, 1\}$$

$$\forall r_{j,l} \in \{0, 1\}$$

$S' = \{x'_1, \dots, x'_m\}$ dont les labels sont
inconnus.
 $1 \leq i \leq \text{nbr de classe} = c$

On calcule $N_{i,j}^2$, $1 \leq j \leq m$

$$p'_{i,l} = \frac{\sum_{j=1}^k N_{i,j} \times \frac{1}{\|x'_e - x'_j\|^2 / (\lambda - 1)}}{\sum_{j=1}^k \frac{1}{\|x'_e - x'_j\|^2 / (\lambda - 1)}}$$

$$1 \leq i \leq c$$

λ est un paramètre ($1 < \lambda < \infty$)
qui détermine le degré de
flou de la classification

12.03.24

Cours App - stat (5)

Exemple : 3 données, 2 classe $\lambda_{PPV}, \lambda=2$

$$Q = \begin{pmatrix} 0 & 0 & 1 \\ 1 & 1 & 0 \end{pmatrix} \quad \begin{aligned} x_1 &= (0, 0) \\ x_2 &= (1, 1) \\ x_3 &= (4, 4) \end{aligned}$$

2 nouvelles données $x'_1 = (0, 1)$
 $x'_2 = (4, 1)$

Les app de x'_1 : x_1 et x_2 $\left(\begin{aligned} \|x'_1 - x_1\| &= 1 \\ \|x'_1 - x_2\| &= 1 \end{aligned} \right)$
— x'_2 : x_2 et x_3 $\left(\begin{aligned} \|x'_2 - x_2\| &= 3 \\ \|x'_2 - x_3\| &= 3 \end{aligned} \right)$

$$\mu'_{1,1} = \frac{\overset{0}{\mu_{1,1}} \times \frac{1}{\|x'_1 - x_1\|^2} + \overset{0}{\mu_{1,2}} \times \frac{1}{\|x'_1 - x_2\|^2}}{\frac{1}{\|x'_1 - x_1\|^2} + \frac{1}{\|x'_1 - x_2\|^2}}$$

$$\mu'_{1,1} = 0$$

$$\mu'_{1,2} = \frac{\overset{0}{\mu_{1,2}} \times \frac{1}{\|x'_2 - x_2\|^2} + \overset{1}{\mu_{1,3}} \times \frac{1}{\|x'_2 - x_3\|^2}}{\frac{1}{\|x'_2 - x_2\|^2} + \frac{1}{\|x'_2 - x_3\|^2}} =$$

$$N'_{1,2} = \frac{1}{9} \times$$

$$N'_{1,2} = \frac{1/9}{1/9 + 1/9} = \frac{1}{2} = 0.5$$

$$U' = \begin{pmatrix} 0 & 0.5 \\ 1 & 0.5 \end{pmatrix}$$

Create U

label = Data[:, Ncol] # récupérer le label.

unique(c(0,0,1,1,1,2,2))

↳ c(0,1,2)

récupérer le nbr de label

Nlabel = length(unique(label))

Def une matrice contenant que des zero

U = matrix(0, ncol=Ndata, nrow=Nlabel)

Remplir la matrice

for (i in 1:Nlabel) {

U[i,] = as.numeric(label == unique_label[i])

}

over fuzzy k-m:

```
fuzzyknn = func(x, Data, k, lambda, U=0){  
  Nbcol = ncol(Data)  
  nbdata = nrow(Data)  
  Data = Data[order(Data[, Nbcol], )]  
  données = Data[, -Nbcol]  
  label = Data[, Nbcol]  
  unique_label = unique(label)  
  Nblabel = length(unique_label)  
  if (U==0) { U = createU(Data) }  
  D = ... # calcul des distance ||X-x||  
  ODK # indice des kppv.  
  opp # le vecteur dans lequel on  
        va mettre les degrés d'appar-  
        tenance de x à chq groupe  
  for (i in 1:Nblabel) { # applique la  
                           formule p  
    return (opp)  
  }
```


$$\text{si } D = (1, 0.8, 2, 0.6)$$

$$ODK = (4, 2, 1)$$

order $\Rightarrow$ donne des indices
du plus grand (nbr) au
plus petit (nbr)

$$\text{fuzzy pred} = (\text{---} \quad d = 4)$$

$$\text{hard pred} = (\text{---} \quad d = 1.05)$$

Afficher les

comparer avec plusieurs valeurs
de λ .

26.03.24

App. STAT

①

Apprentissage séquentiel

Introduction

En Stat, l'analyse séquentielle est une analyse où la taille de l'échantillon n'est pas connue à l'avance.
À la place, les données sont évaluées au fur et à mesure qu'elles sont récoltées.

Jusqu'à présent on avait un échantillon $S_n = \{ (x_i, y_i) \}_{i=1}^n$ et on construisait une règle de décision $\hat{g}_n$ à partir de S_n .

Si on récupère de nouvelles données, il faut tout refaire.

L'approche séquentielle est différente:

On veut pouvoir actualiser $\hat{g}_{n+1}$

à partir de $\hat{y}_n$ et (x_{n+1}, y_{n+1})
et intérêts.

* (1) gain computationnel : On peut avoir un faible coût d'actualisation. Il peut être ~~très intéressant~~ intéressant de traiter des jeux de données de manière séquentielle même si on les a depuis le début.

* (2) gain d'espace de stockage : une fois $\hat{y}_n$ calculé, on ne va pas essayer de se passer de S_n .

II - LPPV

II-1) De quoi a-t-on besoin?

* Retour au cas "classique"

$\Rightarrow$ Il faut stocker $d_1, \dots, d_k$

Si $\|X_{n+1} - x\| \geq d_k$, on change rien.

Si $\|X_{n+1} - x\| < d_k$, il faut intégrer X_{n+1} dans les k_{ppv} , actualiser $\{d_1, \dots, d_k\}$, et il faut recalculer

$$\sum_{i=1}^{p_k} \mathbb{1}_{\{X_i(n) = j\}} = n_j$$

$\Rightarrow$ On va garder $\{n_1, \dots, n_m\}$ et

$Y_1, \dots, Y_k$

II.2) k_{ppv} séquentiels

Etape 1: On a

$S_n = \{(X_i, Y_i)\}_{i=1}^n$, x, k fixes,
 m classes $(j_1, \dots, j_m)$.


26.03.24

App - STAT

(2)

On calcule les distances
 $d_1 \leq d_2 \leq \dots \leq d_m$ et on garde
 $\{d_1, \dots, d_k\}, \{y(1), \dots, y(k)\}$

On obtient



On fait calculer

$$\hat{g}_m(x) \in \arg \max_{j \in \{1, \dots, m\}} n_j$$

Etape 2: Nouvelle donnée
 (x_{n+1}, y_{n+1})

Si $\|x_{n+1} - x\| \geq d_k \Rightarrow$ on fait rien.

si $\|X_{nt+1} - x\| \in [d_i, d_j]$

$(0 < i < j \leq R, d_0 = \infty)$

On remplace d_j par $\|X_{nt+1} - x\|$,
 d_{j+1} par d_j ; d_{j+2} par d_j ,
 d_{j+2} par d_{j+1} ... et d_k est
éliminé.

② X_{nt+2} remplace $Y(i)$, $Y(j)$ remplace

$Y_{j+2}, \dots$, et $Y(k)$ est éliminée.

③ si $\begin{cases} X_{nt+2} = p \\ Y(k) = t \end{cases} \Rightarrow \begin{cases} n_s = n_s + 1 \\ n_t = n_t - 1 \end{cases}$

$J_{nt+1} \in \text{argmax } [J_{nt}]$

* Avantage: peu de chose à
calculer, peu de
chose à stocker.

* Inconvénient : K est fixé
coûte VR

- ① type "classif" sur un 1^{er} nbr de donnée (Etap 1)
- ② appliquer une fctⁿ qui actualise
↳ $f[distance, kLabels, n, x, NomData,]$

EXAMEN 24 / 04 / 24

Règles d'association

* Apprentissage non supervisé.

* → Influence causale

• Si quelqu'un achète du pain et du beurre est-ce qu'il va acheter du lait.

Sac	Contenants
1	Beurre, pain, lait
2	pain, viande
⋮	⋮
n	Poisson, pain

2 critères : "Support", "Confidence"

* **Support**: % d'observati^o qui contiennent les éléments de la règle.

100 sac, 30 avec ou moins lait, pain, beurre.

$\text{Support}(\text{lait, pain, Beurre}) = 0.3 (30\%)$

* **Confidence**: % d'observati^o contenant Y sachant qu'il y avait X.

26.03.24

App. STAT

3)

100 sac, ~~33~~ 33 contiennent
Pain et beurre et dans les 33,
30 contiennent du lait.

$$\text{Confidence: } \frac{30}{33} \approx 0.91$$

⇒ Règles intéressantes: gain support
gain confiance

Algo: "A priori" (1997)

Etape 1: On cherche des sous-ensembles de support assez élevés.

Etape 2: Dans ces sous-ensembles, on cherche les règles de grande confiance.

Exemple: Critère / support > 0.4
 confidence > 0.7

1	A, B, C
2	A, B, C
3	B, D, E

Etape 1 :

table 1 → utile pour éliminer les combinaisons de taille supérieure.

A	0.67
B	1
C	0.67
D	0.33
E	0.33

proportion
d'apparition.

support

table 2

{A, B}	0.67
{B, C}	0.67
{A, C}	0.67

Table 2

$\{A, B, C\}$	0.67
---------------	------

Etape 2

table 2

Confidence 70.7

$A \rightarrow B$	$\frac{2}{2} = 1$
$B \rightarrow A$	$\frac{2}{3} = 0.67$
$A \rightarrow C$	1
$C \rightarrow A$	1
$B \rightarrow C$	0.67
$C \rightarrow B$	1

2 qui
Contient
A et per
C et 2, 2
Contient 2

~~2 qui~~