

# Apprentissage numérique (AN)

## Séance 1

François-Xavier Dupé, Valentin Emiya

prénom.nom@lif.univ-mrs.fr

<http://www.lif.univ-mrs.fr/~vemiya/teaching/AN/>

M2 IF/GSI/BDA - Aix-Marseille Université  
2011-2012

# Module AN : objectifs

- Pratique et théorie en apprentissage numérique
  - BDA : projets applicatifs
  - GSI : projets théorie/application
  - IF : étude d'articles
- Cohésion / 3 filières & compétences différentes
  - grande richesse : favoriser les échanges
  - (in)compréhension : travailler la communication

# Module AN : organisation

- 5 séances du 8/11 au 6/12 = 1 intro + 4 suivi
- BDA :
  - projets « reconnaissance faciale (visages) »
  - 2 groupes de 5 personnes
- GSI :
  - Projets techniques d'apprentissage
  - 3 groupes de 2-3 personnes
- M2 IF : étude 1 articles / personne

# Module AN : suivi et évaluation

## Suivi en séance :

- BDA : 3 présentations type prestataire-client
- GSI et IF : 1 présentation/séance avancement + suivi personnalisé

## Evaluation : en plus du suivi en séance,

- tous : 1 rapport à rendre ~ 10 janvier
- IF : 1 soutenance en janvier

# Plan de la séance 1

- Présentation du module et des sujets
- Apprentissage supervisé :
  - Principe, formalisation, concepts théoriques de base
  - Aperçu de quelques techniques : kNN, SVM
  - Validation d'un apprentissage
  - Principe ERM, compromis biais-variance
- Thématique de l'année : « sélection de modèle »

# Un exemple introductif

- Problème : Quelle est le chiffre  $a$  qui prolonge la séquence :
  - $1235 \dots a$

# Un exemple introductif

- Quelques solutions valides :
  - $a=6$ . Argument : c'est la suite des entiers sauf 4.
  - $a=7$ . Argument 1 : c'est la suite des nombres premiers.
  - $a=7$ . Argument 2 : suite binaire 1(1), 10(2), 11(3), 101(5), 111(7), 1011(11), 1111(15), 10111(23), 11111(31)...
  - $a=8$ . Argument : c'est la suite de Fibonacci.
  - $a=2\pi$ . Argument : la liste ordonnée des racines du polynôme :  
$$x^5 - (11 + a)x^4 + (41 + 11a)x^3 - (61 - 41a)x^2 + (30 + 61a)x - 30a$$
  
qui est le développement de  $(x - 1)(x - 2)(x - 3)(x - 5)(x - a)$   
 $\Rightarrow$   $a$  peut être n'importe quel nombre réel supérieur ou égal à 5)
- Généralisation : il est facile de montrer que n'importe quel nombre est la suite d'une séquence de nombre...  
 $\rightarrow$  Quel modèle choisir ?

# De vrais exemples (1)

## Classification supervisée

**But** : écarter automatiquement les annonces publicitaires et autres messages non sollicités.



**Données** : des messages ( $x_i$ ) dont on sait s'ils sont des SPAMs ou non ( $y_i$  binaire).

**Objectif** : construire un *classifieur*, capable d'attribuer une de ces deux classes à un nouveau document.

**But** : reconnaissance de chiffres manuscrits.

**Données** : des chiffres écrits sur une rétine de 16x16 pixels, associés à une classe parmi  $\{0, 1, \dots, 9\}$

**Objectif** : attribuer la bonne classe (problème de *reconnaissance des formes, pattern recognition*).



# De vrais exemples (2)

## Régression supervisée

**But** : Prédire la température, la pression atmosphérique, le taux d'ozone ou la vitesse du vent.

**Données** : Numériques (ex. : capteurs de température) ou symboliques (temps de la veille).


**But** : Dans le problème de détection des SPAMs, associer à un nouveau document la **probabilité** que ce soit un SPAM.

**But** : Prédire le pronostic vital d'un patient à partir de différents paramètres cliniques.

# De vrais exemples (3)

## Traitement d'image : l'*inpainting*

**But** : reconstruire une partie manquante dans une image.



**Apprentissage** : position  $x_i$  et intensité  $y_i$  des pixels connus  $i \in I$ .

**Objectif** : estimer l'intensité  $y_i$  à partir de la position  $x_i$  des pixels inconnus  $i \in \bar{I}$ .

# De vrais exemples (4)

## Reconnaissance de visages

**But** : reconnaître une personne dans une image.

**Apprentissage** : images  $x_i$  et personnes  $y_i$ ,  $1 \leq i \leq n$ , dans une base de  $n$  images annotées :

$$y_1 = \dots = y_4 = p_1$$



$$y_5 = \dots = y_8 = p_2$$



$$y_9 = \dots = y_{12} = p_3$$



©BioID Face Database

**Objectif** : identifier une personne à partir d'une nouvelle image  $x$ .

$x =$



$y?$

# Références Bibliographiques

- Apprentissage Artificiel, *Antoine Cornuéjols et Laurent Miclet*.
- The elements of statistical Learning, *Hastie, Tibshirani et Friedman*.
- Data Mining : Practical Machine Learning Tools and Techniques with Java Implementations, *Witten et Frank*, auteurs de *Weka*  
<http://www.cs.waikato.ac.nz/ml/weka>.

# Présentation des sujets : IF

- B. Efron, T. Hastie, I. Johnstone, R. Tibshirani,  
*Least Angle Regression*,  
The Annals of Statistics, Inst. of Math. Stat., No 32, 2004.
- P. Stoica, Y. Selen,  
*Model-order selection: a review of information criterion rules*,  
IEEE Signal Processing Magazine, No 21, 2004.
- K. A. Clarke,  
*The Effect of Priors on Approximate Bayes Factors from MCMC Output*,  
Tech. Rep., 2000.
- A. Gálvez, A. Iglesias,  
*Efficient particle swarm optimization approach for data fitting with free knot B-splines*  
Computer-Aided Design, No 43, 2011.

# Présentation des sujets : BDA

Reconnaissance faciale



Scénario industriel...



©BioID Face Database

Présentations :

- 15/11 : compréhension du sujet, état de l'art
- 22/11 : présentation de la mise en œuvre choisie
- 29/11 : récapitulatif, verrous, endroits délicats

# Présentation des sujets : GSI

- Validation croisée pour la sélection de modèles :
  - Théorie
  - Implémentations rapides
- Tests d'hypothèses et classification :
  - Théorie
  - Utilisation en classification : choix des modèles
- Utilisation des kNN dans le cas de grandes bases de données
  - Etudes des différentes techniques et des cas d'utilisation

# Plan

- Présentation du module et des sujets
- Apprentissage supervisé :
  - Principe, formalisation, concepts théoriques de base
  - Aperçu de quelques techniques : kNN, SVM
  - Validation d'un apprentissage
  - Principe ERM, compromis biais-variance
- Thématique de l'année : « sélection de modèle »

# 2 types d'apprentissage

- **Apprentissage supervisé** : les exemples d'apprentissage  $x$  possèdent l'information à apprendre  $y$ . On cherche une loi de dépendance sous-jacente  $y=f(x)$ .
  - Si  $f$  est une *fonction continue*
    - Régression
    - Estimation de densité
  - Si  $f$  est une *fonction discrète*
    - Classification
  - Si  $f$  est une *fonction binaire* (booléenne)
    - Apprentissage de concept

# 2 types d'apprentissage

- **Apprentissage supervisé** : les exemples d'apprentissage  $x$  sont disponibles avec l'information à apprendre  $y$ . On cherche une loi de dépendance sous-jacente  $y=f(x)$ .
- **Apprentissage non-supervisé** : les exemples d'apprentissage  $x$  sont disponibles sans information supplémentaire, « apprentissage sans professeur ». On cherche des régularités ou structures sous-jacentes :
  - **Clustering** : découvrir les catégories et les règles de catégorisation
  - **Estimation de la densité de probabilité  $p(X)$**
  - **Séparation aveugle de sources**

# Formaliser : quoi ? comment ?

- Comment modéliser les données ?  
→ *distribution statistique de  $(x,y)$*
- Que veut-on apprendre ?  
→ *une fonction  $f$  telle que  $y=f(x)$*
- Comment évaluer la performance de l'apprentissage obtenu ?  
→ *notion de risque  $R(f)$  (=erreur)*

# Formalisation : les données

## Notations :

- **entrées** : vecteurs de  $n$  attributs

$$\mathbf{x} = (x_1, \dots, x_n) \in \mathbf{X} = \mathbf{X}_1 \times \dots \times \mathbf{X}_n$$

- **sorties**  $y \in \mathbf{Y}$

## *Exemple*

Entrée à  $n = 2$  attributs :

âge  $\mathbf{X}_1 = [0; 120]$ , fumeur  $\mathbf{X}_2 = \{\text{oui, non}\}$

Sortie :  $\mathbf{Y} = \{\text{patient\_a\_risque, patient\_sans\_risque}\}$ .

Dépendance entrée/sortie : le risque cardiaque est-il lié à l'âge et au fait de fumer ?

# Formalisation : les données

- Notations :
  - **entrées** : vecteurs de  $n$  attributs  
 $\mathbf{x} = (x_1, \dots, x_n) \in \mathbf{X} = \mathbf{X}_1 \times \dots \times \mathbf{X}_n$
  - **sorties**  $y \in \mathbf{Y}$
- **Modèle statistique des données** :  
variables aléatoires  $(X, Y) \in \mathbf{X} \times \mathbf{Y}$   
distribuées selon  $P(X, Y)$  (inconnu en  $g^{\text{al}}$ )
- Base d'apprentissage, « **échantillon** » :  
ensemble de  $l$  **exemples**  $\{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_l, y_l)\}$   
avec  $(\mathbf{x}_i, y_i)$  **i.i.d.** selon  $P(X, Y)$
- Test, application : autres tirages i.i.d. selon  $P(X, Y)$   
 $\{(\mathbf{x}_{l+1}, y_{l+1}), (\mathbf{x}_{l+2}, y_{l+2}), \dots\}$

# Principe de l'apprentissage supervisé

- **À partir des données**

$$S = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_l, y_l)\}$$

trouver une fonction  $h : \mathbf{X} \rightarrow \mathbf{Y}$

qui prédit  $y$  à partir de  $\mathbf{x}$ .

- **Défi : généraliser** pour tout  $\mathbf{x} \in \mathbf{X}$

[Si  $\mathbf{x} \in \{\mathbf{x}_1, \dots, \mathbf{x}_l\}$ , facile : apprentissage par coeur.]

$h$  est aussi appelée aussi hypothèse, règle, classifieur, etc.

# Principe de l'apprentissage supervisé

- **À partir des données**

$$S = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_l, y_l)\}$$

trouver une fonction  $h : \mathbf{X} \rightarrow \mathbf{Y}$

qui prédit  $y$  à partir de  $\mathbf{x}$ .

*Exemple*

$$h_1(\mathbf{x}) = \begin{cases} \text{a\_risque} & \text{si } x_2 = \text{fumeur et } x_1 > 60 \\ \text{sans\_risque} & \text{sinon} \end{cases}$$

# Performance : notion de risque

- **Fonction de perte / loss function :**

$$\text{Classification: } L(y, h(\mathbf{x})) = \begin{cases} 1 & \text{si } y \neq h(\mathbf{x}) \\ 0 & \text{sinon.} \end{cases}$$

$$\text{Régression: } L(y, h(\mathbf{x})) = (y - h(\mathbf{x}))^2$$

- **Fonction Risque** ou erreur = espérance mathématique de la fonction de perte :

$$R(h) = \int L(y, h(\mathbf{x})) dP(\mathbf{x}, y)$$

Problème général de l'apprentissage supervisé :  
à partir de l'échantillon  $S = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_l, y_l)\}$   
trouver  $h : \mathbf{X} \rightarrow \mathbf{Y}$  qui minimise  $R(h)$

# Synthèse

Problème général de l'apprentissage supervisé :

- à partir de l'échantillon  $S = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_l, y_l)\}$  supposé i.i.d.
- trouver  $h : \mathbf{X} \rightarrow \mathbf{Y}$ ,  $h \in H$  (classe de fonctions)
- qui minimise  $R(h)$

# Quelques règles de classification

- Règle majoritaire :

$$\forall \mathbf{x} \in \mathbf{X}, f_{\text{maj}}(\mathbf{x}) = \operatorname{argmax}_y P(y) = y_{\text{maj}}$$

- Règle du maximum de vraisemblance (*maximum likelihood*) :

$$\forall \mathbf{x} \in \mathbf{X}, f_{\text{mv}}(\mathbf{x}) = \operatorname{argmax}_y P(\mathbf{x}|y)$$

- Règle de Bayes

$$\forall \mathbf{x} \in \mathbf{X}, f_{\text{B}}(\mathbf{x}) = \operatorname{argmax}_y P(y|\mathbf{x})$$

# La classification

- Nous cherchons une fonction  $f : \mathbf{X} \rightarrow \mathbf{Y}$  qui prend des **valeurs discrètes**.

- Fonction de perte : *perte 0-1*

$$L(y, f(x)) = \delta(y \neq f(x))$$

- Risque ou erreur de la fonction  $f$  : *erreur quadratique* :

$$R(h) = \int L(y, h(\mathbf{x})) dP(\mathbf{x}, y) = P(Y \neq h(X))$$

- Théorème : la fonction de classification de risque minimal est la règle de Bayes :

$$\forall \mathbf{x} \in \mathbf{X}, f_B(\mathbf{x}) = \operatorname{argmax}_y P(y|\mathbf{x})$$

# La régression

- Nous cherchons une fonction  $f : \mathbf{X} \rightarrow \mathbf{Y}$  qui prend des **valeurs continues**.

- Fonction de perte : *écart quadratique* :

$$L(y, f(x)) = (y - f(x))^2$$

- Risque ou erreur de la fonction  $f$  : *erreur quadratique* :

$$R(f) = \int_{\mathbf{X} \times \mathbf{Y}} (y - f(x))^2 dP(x, y)$$

- Théorème : la fonction de régression de risque minimal est l'espérance des valeurs observables en

$$\mathbf{x} : f^*(x) = \int_{\mathbf{Y}} y dP(y|x)$$

# Plan

- Présentation du module et des sujets
- Apprentissage supervisé :
  - Principe, formalisation, concepts théoriques de base
  - Aperçu de quelques techniques : kNN, SVM
  - Validation d'un apprentissage
  - Principe ERM, compromis biais-variance
- Thématique de l'année : « sélection de modèle »

# Plan

- Présentation du module et des sujets
- Apprentissage supervisé :
  - Principe, formalisation, concepts théoriques de base
  - Aperçu de quelques techniques : kNN, SVM
  - **Validation d'un apprentissage**
  - Principe ERM, compromis biais-variance
- Thématique de l'année : « sélection de modèle »


# Validation empirique d'un apprentissage

- Plusieurs méthodes permettent de valider (ou d'infirmer) la valeur d'un processus d'apprentissage.
- Une des approches consiste à n'utiliser qu'une partie des données pour apprendre et à se servir des autres données pour tester le résultat.
- Différentes mesures permettent alors de comparer des processus (erreur, F-score, etc.)



# Validation croisée (*cross-validation*)

- La validation croisée est une généralisation de la méthode précédente.
- Elle consiste à diviser les données en  $K$  *folders*, à en enlever un pour l'apprentissage puis à l'utiliser pour la phase de test. Le processus est ensuite réitéré.
- L'erreur moyenne tend alors vers l'erreur en généralisation.



# Plan

- Présentation du module et des sujets
- Apprentissage supervisé :
  - Principe, formalisation, concepts théoriques de base
  - Aperçu de quelques techniques : kNN, SVM
  - Validation d'un apprentissage
  - Principe ERM, compromis biais-variance
- Thématique de l'année : « sélection de modèle »

# L'apprentissage en pratique : intuition

*Intuition 1* : on veut utiliser une méthode telle que

- les arbres de décision,
- les réseaux de neurones,
- les kNN, les SVM, etc.

= choix d'une classe  $H$  d'hypothèses  $h \in H$

*Intuition 2* : pour trouver le « meilleur »  $h \in H$ ,

- on ne peut pas calculer le risque  $R(h)$
- on ne dispose que d'un échantillon  $S$ .

= parmi les  $h \in H$ , on prend celui qui décrit le mieux  $S$

# L'apprentissage en pratique : intuition

L'apprentissage consisterait donc à faire

$$\hat{h} \triangleq \arg \min_{h \in \mathcal{H}} R_S (h)$$

où  $R_S$  une mesure de performance sur les exemples connus  $S$  :  $\hat{h}$  est optimal sur  $S$ .

$R_S$  s'appelle le *risque empirique*

Le principe d'optimisation ci-dessus s'appelle  
*minimisation du risque empirique.*

# Risque empirique

- En classification,  $R_{\text{emp}}(\mathbf{h})$  (ou  $R_S(\mathbf{h})$ ) est la moyenne du nombre d'erreurs sur l'échantillon  $S$  :

$$R_{\text{emp}}(\mathbf{h}) = \|\{i : \mathbf{h}(x_i) \neq y_i\}\| / \|S\|$$

- En régression,  $R_{\text{emp}}(\mathbf{h})$  est la moyenne des carrés des écarts à la moyenne de  $\mathbf{h}$  sur  $S$  :

$$R_{\text{emp}}(\mathbf{h}) = 1/\|S\| \sum_{x_i \in S} (y_i - \mathbf{h}(x_i))^2$$

# Risque (réel) vs. risque empirique

- Risque (réel)

= **espérance** de la fonction de perte

$$R(h) = E[L(Y, h(X))] = \int L(y, h(x)) dP(x, y) \text{ (classif./régr.)}$$

- Risque empirique :

= **moyenne sur S** de la fonction de perte

$$R_{\text{emp}}(h) = \frac{1}{l} \sum_{(x,y) \in S} L(y, h(x)) \text{ (classif./régr.)}$$

- Donc  $R_{\text{emp}}(h)$  est une estimation de  $R(h)$

# Synthèse (provisoire)

- Intuitivement, le principe de minimisation du risque empirique (ERM) recommande de **rechercher une fonction  $h$  de  $H$  minimisant  $R_{emp}(h)$**
- En classification = minimiser le nombre d'erreurs de  $h$  sur l'échantillon.
- En régression = méthode des moindres carrés.

# ERM : deux questions importantes


Idéalement :  $f_{\min} \triangleq \arg \min_f R(f)$

Principe ERM :  $\hat{h} \triangleq \arg \min_{h \in \mathcal{H}} R_S(h)$

Quelles sont les enjeux et conséquences relatifs

- au choix de  $H$  ?
- au « remplacement » du risque réel  $R(h)$  par le risque empirique  $R_S(h)$  ?

# Conséquence du choix de $H$ : le biais



$$f_{\text{min}} \triangleq \arg \min_f R(f)$$

$$h_{\text{opt}} \triangleq \arg \min_{h \in \mathcal{H}} R(h)$$


$\mathcal{H}$  : espace des hypothèses possibles de l'apprenant.

$\mathcal{F}$  : espace des fonctions cible de la nature.

En général,  $f_{\text{min}} \notin \mathcal{H}$ , et  $R(h_{\text{opt}}) \geq R(f_{\text{min}})$ .

$R(h_{\text{opt}}) - R(f_{\text{min}})$  est l'**erreur d'approximation** ou biais.

# Minimisation de $R_S$ : la variance



$$f_{\min} \triangleq \arg \min_f R(f)$$

$$h_{\text{opt}} \triangleq \arg \min_{h \in \mathcal{H}} R(h)$$


$$\hat{h} \triangleq \arg \min_{h \in \mathcal{H}} R_S(h)$$

$R(h) \neq R_S(h)$  donc on peut avoir  $\hat{h} \neq h_{\text{opt}}$  et  $R(\hat{h}) \geq R(h_{\text{opt}})$

$R(\hat{h}) - R(h_{\text{opt}})$  est l'**erreur d'estimation** ou variance.

En particulier, problème du surapprentissage.

# Décomposition de la performance



$$f_{\min} \triangleq \arg \min_f R(f)$$

$$h_{\text{opt}} \triangleq \arg \min_{h \in \mathcal{H}} R(h)$$

$$\hat{h} \triangleq \arg \min_{h \in \mathcal{H}} R_S(h)$$

$$R(\hat{h}) = R(f_{\min}) + R(h_{\text{opt}}) - R(f_{\min}) + R(\hat{h}) - R(h_{\text{opt}})$$

$R(f_{\min})$  est l'**erreur minimale, intrinsèque**.

$R(h_{\text{opt}}) - R(f_{\min})$  est l'**erreur d'approximation**.

$R(\hat{h}) - R(h_{\text{opt}})$  est l'**erreur d'estimation**.

# ERM : deux questions importantes

Idéalement :  $f_{\min} \triangleq \arg \min_f R(f)$

Principe ERM :  $\hat{h} \triangleq \arg \min_{h \in \mathcal{H}} R_S(h)$


## Enjeux relatifs

- au choix de  $H$  : erreur d'approximation
- au « remplacement » du risque réel  $R(h)$  par le risque empirique  $R_S(h)$  : erreur d'estimation

$$R(\hat{h}) = R_{\min} + R_{\text{approx.}} + R_{\text{estim.}}$$

Comment minimiser ces erreurs ?

# Réduire l'erreur d'approximation/biais




$$f_{\min} \triangleq \arg \min_f R(f)$$

$$h_{\text{opt}} \triangleq \arg \min_{h \in \mathcal{H}} R(h)$$

Solutions :

- Choisir pour  $H$  une famille de fonctions adaptée au problème
- Augmenter la « richesse » de  $H$  : ordre, nombre de degrés de liberté, etc.

# Réduire l'erreur d'estimation/variance



$$f_{\min} \triangleq \arg \min_f R(f)$$

$$h_{\text{opt}} \triangleq \arg \min_{h \in \mathcal{H}} R(h)$$


$$\hat{h} \triangleq \arg \min_{h \in \mathcal{H}} R_S(h)$$

Solutions :

- Augmenter la taille de  $S$  (coûteux) : le principe ERM est *consistant* dans la classe  $\mathcal{H}$  si  $\hat{h}$  tend vers  $h_{opt}$  quand le nombre d'exemples tend vers l'infini.

•

# Réduire l'erreur d'estimation/variance



$$f_{\min} \triangleq \arg \min_f R(f)$$

$$h_{\text{opt}} \triangleq \arg \min_{h \in \mathcal{H}} R(h)$$

$$\hat{h} \triangleq \arg \min_{h \in \mathcal{H}} R_S(h)$$

Solutions :

- Augmenter la taille de  $S$  (coûteux) : le principe ERM est *consistant* dans la classe  $H$  si  $\hat{h}$  tend vers  $h_{\text{opt}}$  quand le nombre d'exemples tend vers l'infini.
- Réduire la « richesse » de  $H$  : ordre, nombre de degrés de liberté, etc.


# Le compromis biais-variance

$$R(\hat{h}) = R(f_{\min}) + R(h_{\text{opt}}) - R(f_{\min}) + R(\hat{h}) - R(h_{\text{opt}})$$

= compromis entre erreur d'approximation et erreur d'estimation pour minimiser l'erreur totale

Exemples :

- Ordre d'un polynôme
- Nombre de gaussiennes
- Etc.



# Plan

- Présentation du module et des sujets
- Apprentissage supervisé :
  - Principe, formalisation, concepts théoriques de base
  - Aperçu de quelques techniques : kNN, SVM
  - Validation d'un apprentissage
  - Principe ERM, compromis biais-variance
- Thématique de l'année : « sélection de modèle »

# Sélection de modèle : 2 questions

A partir d'un échantillon d'apprentissage  $S$ ,

- qualitativement, quel modèle  $H$  choisir ?
- quantitativement, pour une complexité croissante

$$\mathcal{H}_1 \subset \mathcal{H}_2 \subset \dots \subset \mathcal{H}_p$$

quel ensemble choisir pour obtenir un bon compromis biais-variance ?

Solutions : plusieurs méthodes de sélection de modèle sont possibles.


# Solution 1 : pénaliser le risque empirique

En utilisant une pénalité  $q$  dépendant de la complexité du modèle, on remplace

$$\hat{h} \triangleq \arg \min_{h \in \mathcal{H}_m} R_S(h)$$

par

$$\hat{h} \triangleq \arg \min_{h \in \mathcal{H}_m, 1 \leq m \leq p} R_S(h) + q(m)$$



# Solution 2 : test d'hypothèses

Idée générale :  $\hat{\mathcal{H}} \triangleq \arg \min_{\mathcal{H}} p(\mathcal{H} | S)$



# Solution 3 : estimer le risque réel à partir d'un échantillon de validation

DONNEES

Ensemble de validation

Ensemble de test

Ensemble d'apprentissage




"Richesse" de H

$$\mathcal{H}_1 \subset \mathcal{H}_2 \subset \dots \subset \mathcal{H}_p$$

En pratique, on utilise plutôt une validation croisée.


# Validation croisée

- Itération 1 :



$$\hat{h}_1 \triangleq \arg \min_{h \in \mathcal{H}} R_{S_1}(h)$$
$$\rightarrow R_{T_1}(\hat{h}_1)$$

- Itération 2 :



$$\hat{h}_2 \triangleq \arg \min_{h \in \mathcal{H}} R_{S_2}(h)$$
$$\rightarrow R_{T_2}(\hat{h}_2)$$

...

$\frac{1}{K} \sum_{k=1}^K R_{T_k}(\hat{h}_k)$  est une bonne estimation de  $R(\hat{h})$

# Validation croisée pour trouver un compromis biais-variance

- On dispose d'un échantillon  $S$
- Objectif : choisir entre  $\mathcal{H}_1, \mathcal{H}_2, \dots, \mathcal{H}_M$
- Pour chaque  $\mathcal{H}_m$ , on fait une validation croisée :

$$R^{(m)} = \frac{1}{K} \sum_{k=1}^K R_{T_k} \left( \hat{h}_k^{(m)} \right) \quad \left( \hat{h}_k^{(m)} \triangleq \arg \min_{h \in \mathcal{H}_m} R_{S_k}(h) \right)$$

- On sélectionne finalement  $\mathcal{H}_{\hat{m}}$  tel que

$$\hat{m} \triangleq \arg \min_m R^{(m)}$$

# Plan

- Présentation du module et des sujets
- Apprentissage supervisé :
  - Principe, formalisation, concepts théoriques de base
  - Aperçu de quelques techniques : kNN, SVM
  - Validation d'un apprentissage
  - Principe ERM, compromis biais-variance
- Thématique de l'année : « sélection de modèle »