

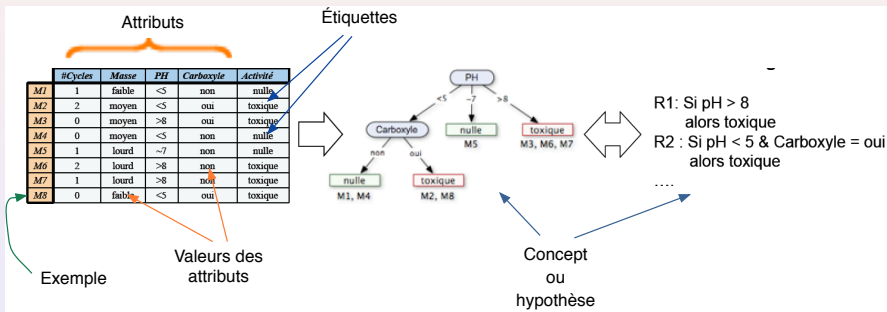
# En introduction à l'**Apprentissage Artificiel**

**Antoine Cornuéjols**

**MMIP, AgroParisTech, Paris**

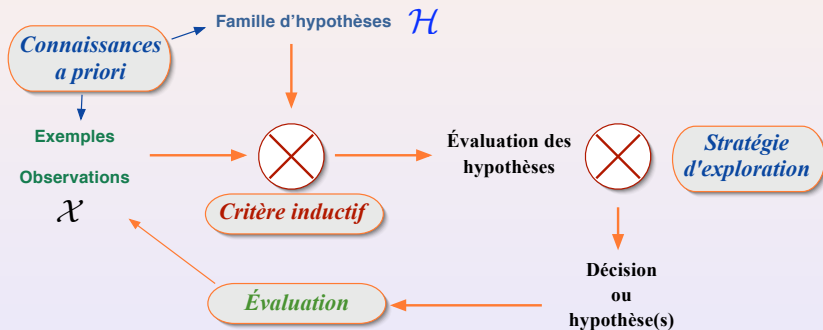
7 février 2008

# Un exemple



# L'apprentissage

## Ingrédients



# Plan

- 1 Les fondements
- 2 En pratique
- 3 Conclusions et perspectives

# Plan

- 1 Les fondements
  - Critère de performance
  - Critère inductif
  - Dilemme fondamental
  - Régularisation
  - Exploration de  $\mathcal{H}$
- 2 En pratique
- 3 Conclusions et perspectives

# Que signifie : avoir un bon modèle du monde ?

Idéalement

# Que signifie : avoir un bon modèle du monde ?

Idéalement

Identifier une **dépendance cible** :

- $\mathbf{P}_{\mathcal{X}\mathcal{Y}}$
- *Fonction cible*  $f : \mathcal{X} \rightarrow \mathcal{Y}$

# Que signifie : avoir un bon modèle du monde ?

Idéalement

Identifier une **dépendance cible** :

- $\mathbf{P}_{\mathcal{X}\mathcal{Y}}$
- *Fonction cible*  $f : \mathcal{X} \rightarrow \mathcal{Y}$

**Prédire** correctement

$$\mathcal{X} \rightarrow \mathcal{Y}$$

$$x \mapsto \text{decision bayésienne}(x)$$

$$\text{ou } x \mapsto \text{decision}(x) = f(x)$$



# Que signifie : avoir un bon modèle du monde ?

Idéalement

Identifier une **dépendance cible** :

- $\mathbf{P}_{\mathcal{X}\mathcal{Y}}$
- *Fonction cible*  $f : \mathcal{X} \rightarrow \mathcal{Y}$

## Prédire correctement

$$\mathcal{X} \rightarrow \mathcal{Y}$$

$$x \mapsto \text{decision bayésienne}(x)$$

$$\text{ou } x \mapsto \text{decision}(x) = f(x)$$

## Expliquer le monde

$$h(\cdot) = f(\cdot)$$

# Que signifie : avoir un bon modèle du monde ?

Idéalement

Identifier une **dépendance cible** :

- $\mathbf{P}_{\mathcal{X}\mathcal{Y}}$
- *Fonction cible*  $f : \mathcal{X} \rightarrow \mathcal{Y}$

## Prédire correctement

$$\mathcal{X} \rightarrow \mathcal{Y}$$

$$x \mapsto \text{decision bayésienne}(x)$$

$$\text{ou } x \mapsto \text{decision}(x) = f(x)$$

## Expliquer le monde

$$h(\cdot) = f(\cdot)$$

# Que signifie : avoir un bon modèle du monde ?

Plus réalistement



Figure: Modèle de génération des exemples.

# Que signifie : avoir un bon modèle du monde ?

Plus réalistement



Figure: Modèle de génération des exemples.

**Prédictions correctes** (la plupart du temps)

$$L(h) = P_{xy}\{h(x) \neq y\}$$

# Que signifie : avoir un bon modèle du monde ?

Plus réalistement



Figure: Modèle de génération des exemples.

## Prédictions correctes (la plupart du temps)

$$L(h) = P_{xy}\{h(x) \neq y\}$$

## Expliquer le monde

$$h(\cdot) \approx f(\cdot)$$

# Que signifie : avoir un bon modèle du monde ?

Le risque réel

*Fonction de perte :*

$$\begin{aligned} \ell(h) : \mathcal{X} \times \mathcal{Y} &\rightarrow \mathbb{R}^+ \\ (\mathbf{x}, y) &\mapsto \ell(h(\mathbf{x}), y) \end{aligned}$$

# Que signifie : avoir un bon modèle du monde ?

Le risque réel

*Fonction de perte :*

$$\begin{aligned} \ell(h) : \mathcal{X} \times \mathcal{Y} &\rightarrow \mathbb{R}^+ \\ (\mathbf{x}, y) &\mapsto \ell(h(\mathbf{x}), y) \end{aligned}$$

**Risque réel : espérance de perte**

$$R(h) = \mathbb{E}[\ell(h(\mathbf{x}), y)] = \int_{\mathbf{x} \in \mathcal{X}, y \in \mathcal{Y}} \ell(h(\mathbf{x}), y) \mathbf{P}_{\mathcal{X}\mathcal{Y}} d(\mathbf{x}, y)$$


# Décision bayésienne

## Règle de Bayes

$$P(C_k|\mathbf{x}) = \frac{p(\mathbf{x}|C_i) P(C_i)}{p(\mathbf{x})}$$

## Décision bayésienne

$$C_k = \underset{C_k \in \mathcal{H}}{\text{ArgMax}} P(C_k|\mathbf{x})$$






# Décision bayésienne

## Règle de Bayes

$$P(C_k|\mathbf{x}) = \frac{p(\mathbf{x}|C_i) P(C_i)}{p(\mathbf{x})}$$

## Décision bayésienne

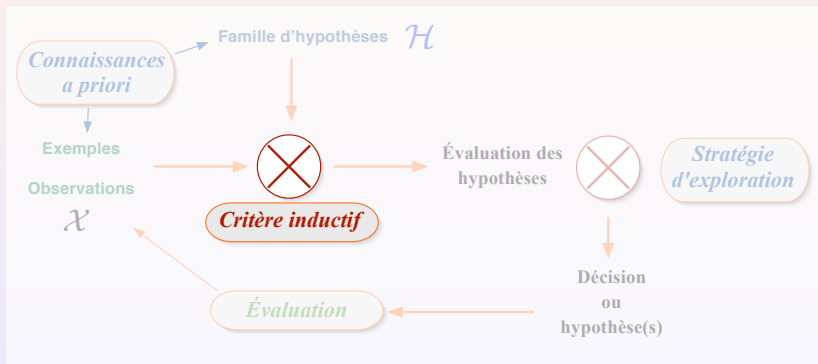
$$C_k = \underset{C_k \in \mathcal{H}}{\text{ArgMax}} P(C_k|\mathbf{x})$$



Il faut connaître  $P(C_k)$  et les lois de probabilité  $p(\mathbf{x}|C_i)$  !

# L'apprentissage

## Ingrédients



# Les critères inductifs

Mais, on ne connaît pas  $\mathbf{P}_{\mathcal{X}\mathcal{Y}}$

*Échantillon d'apprentissage* supposé représentatif

$$\mathcal{S}_m = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_m, y_m)\} \in (\mathcal{X} \times \mathcal{Y})^m$$

# Les critères inductifs

Mais, on ne connaît pas  $\mathbf{P}_{\mathcal{X}\mathcal{Y}}$

*Échantillon d'apprentissage* supposé représentatif

$$\mathcal{S}_m = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_m, y_m)\} \in (\mathcal{X} \times \mathcal{Y})^m$$

## Minimisation du Risque Empirique

$$R_m(h) = \frac{1}{m} \sum_{i=1}^m \ell(h(\mathbf{x}_i), y_i)$$

# Les critères inductifs

## Minimisation du Risque Empirique

### MRE

Choisir l'hypothèse  $\hat{h}$  telle que :  $\hat{h} = \text{ArgMin}_{h \in \mathcal{H}} [R_{\text{Emp}}(h)]$

$$R_{\text{Emp}}(h) = \frac{1}{m} \sum_{(x_i, u_i) \in S} \ell(h(x_i), u_i)$$

# Les critères inductifs

## Autres critères

### Compression maximale d'information

Choisir l'hypothèse  $\hat{h}$  telle que :  $\hat{h} = \text{ArgMin}_{h \in \mathcal{H}} [L(\mathcal{S}_m)]$

$$L(\mathcal{S}_m) = L(h) + L(\mathcal{S}_m|h)$$

### MLE et MAP

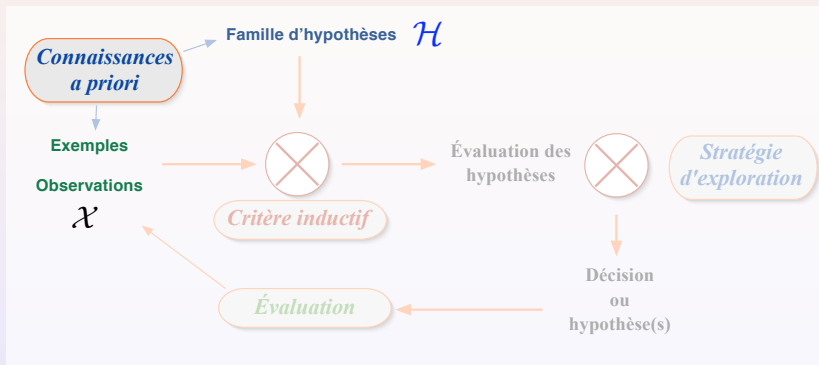
Choisir l'hypothèse  $\hat{h}$  telle que :

$$\hat{h} = \text{ArgMax}_{h \in \mathcal{H}} l(h) = \text{ArgMax}_{h \in \mathcal{H}} \ln [p(\mathcal{S}_m|h)] \quad (\text{MLE})$$

$$\hat{h} = \text{ArgMax}_{h \in \mathcal{H}} p(\mathcal{S}_m|h) p(h) \quad (\text{MAP})$$

# L'apprentissage

## Ingrédients



# Des hypothèses et des modèles

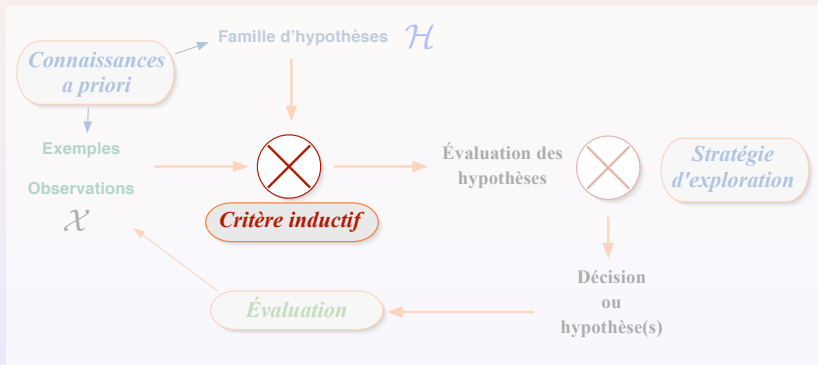
Nombreuses formes possibles :

- “simple” plus proche(s) voisin(s)
- SVM
- Modèles linéaires
- Modèles bayésiens
- Réseaux de neurones ; Modèles de Markov à états cachés (HMM)
- Arbres de décision
- Règles (ILP : Induction of Logic Programs)
- Grammaires




# L'apprentissage

## Ingrédients



# Les critères inductifs

doivent vérifier ...



*Les entrées doivent **se traduire en « différences »** exploitables dans  $\mathcal{H}$*

# Un dilemme fondamental

## Le compromis biais-variance




FIG.: Les différents types d'erreurs.


# Capacité de $\mathcal{H}$

## Qualité de l'estimation

$$|R(h) - R_{\text{Emp}}(h)| \leq_P \text{fct}(\text{diversité}_{\mathcal{H}}, m)$$

- Dimension de Vapnik-Chervonenkis
- Complexité de Rademacher
- BIC
- AIC
- ...

# Critère inductif régularisé



Corriger le MRE en **contrôlant la capacité de  $\mathcal{H}$**   
(ou la complexité de  $h$ )

# Critère inductif régularisé

## Contrôler $d_{\mathcal{H}}$

- 1 “Sélection de modèle”
- 2 Puis choix de  $h \in \mathcal{H}$

$$\hat{h} = \text{ArgMin}_{h \in \mathcal{H}} [R_{Emp}(h) + \text{Capacité}(\mathcal{H})]$$

# Critère inductif régularisé

## Contrôler $d_{\mathcal{H}}$

- 1 "Sélection de modèle"
- 2 Puis choix de  $h \in \mathcal{H}$

$$\hat{h} = \text{ArgMin}_{h \in \mathcal{H}} [R_{Emp}(h) + \text{Capacité}(\mathcal{H})]$$

## Régularisation


- Contrôler directement la complexité de  $h$

$$\hat{h} = \text{ArgMin}_{h \in \mathcal{H}} [R_{Emp}(h) + \lambda \text{Reg}(h)]$$

# Optimisation du critère inductif régularisé

## Minimisation du $\phi$ -risque empirique

- “hinge loss”
- Fonction de perte exponentielle
- ...






# Optimisation du critère inductif régularisé

## Minimisation du $\phi$ -risque empirique

- “hinge loss”
- Fonction de perte exponentielle
- ...

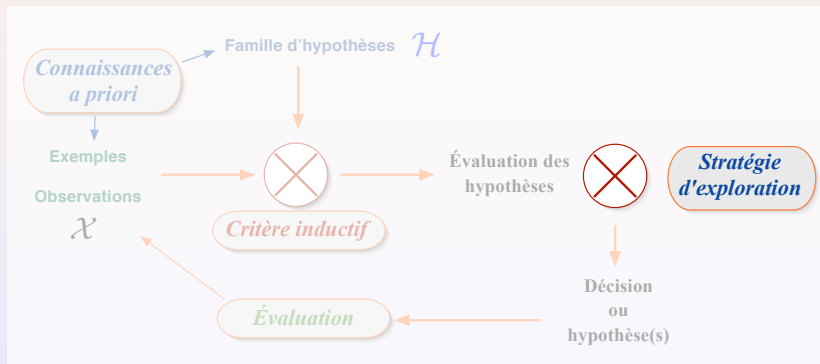


## Deux rôles :

- Régulariser
- Faciliter l'optimisation
  - Différentiabilité
  - Convexité

# L'apprentissage

## Ingrédients



# Exploration de $\mathcal{H}$

## Structures sur $\mathcal{H}$

# Exploration de $\mathcal{H}$

Structures sur  $\mathcal{H}$

Pas de  $\mathcal{H}$

Plus-proches-voisins

# Exploration de $\mathcal{H}$

## Structures sur $\mathcal{H}$

### Pas de $\mathcal{H}$

Plus-proches-voisins

### $\mathcal{H}$ muni d'une distance

*Réseaux de neurones ; régression logistique ; modèles bayésiens ; HMM ; ...*

- Optimisation directe (e.g. pseudo-inverse)
- Adaptation itérative = descente de gradient

# Exploration de $\mathcal{H}$

## Structures sur $\mathcal{H}$

### Pas de $\mathcal{H}$

Plus-proches-voisins

### $\mathcal{H}$ muni d'une distance

*Réseaux de neurones ; régression logistique ; modèles bayésiens ; HMM ; ...*

- Optimisation directe (e.g. pseudo-inverse)
- Adaptation itérative = descente de gradient

### $\mathcal{H}$ muni d'une relation de généralité

*Inférence grammaticale ; Induction de règles ; Apprentissage relationnel*

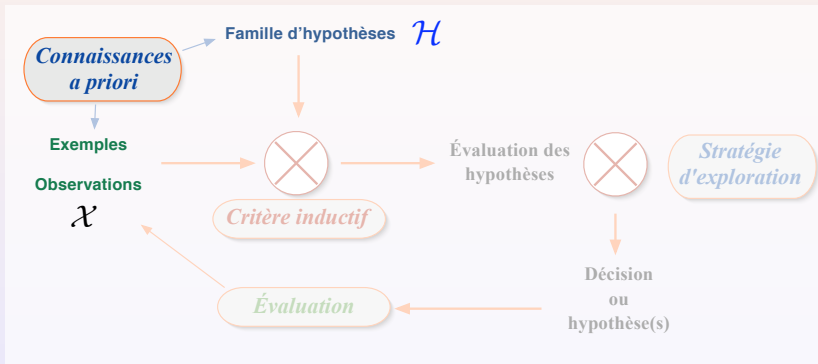
- Apprentissage symbolique
- Bruit

# Plan

- 1 Les fondements
- 2 En pratique
  - Choix de  $\mathcal{H}$
  - Les données
  - L'évaluation
- 3 Conclusions et perspectives

# L'apprentissage

## Ingrédients





# Choix de $\mathcal{H}$

## Types d'espaces d'hypothèses

# Choix de $\mathcal{H}$

Types d'espaces d'hypothèses

## Modèles génératifs

Demandent  $p(\mathbf{x}|\mathcal{C}_k)$  et  $p(\mathcal{C}_k)$

# Choix de $\mathcal{H}$

## Types d'espaces d'hypothèses

### Modèles génératifs

Demandent  $p(\mathbf{x}|\mathcal{C}_k)$  et  $p(\mathcal{C}_k)$

### Fonctions de décision

- Fonctions composées de fonctions de base
- Méthodes à Noyaux (*Kernel methods*)

# Choix de $\mathcal{H}$

## Types d'espaces d'hypothèses

### Modèles génératifs

Demandent  $p(\mathbf{x}|\mathcal{C}_k)$  et  $p(\mathcal{C}_k)$

### Fonctions de décision

- Fonctions composées de fonctions de base
- Méthodes à Noyaux (*Kernel methods*)

### Approches constructives

- Spécialisation dans l'espace  $\mathcal{X}$
- Modèles hiérarchiques ou "profonds" (*Deep models*)

# Choix de $\mathcal{H}$

## Modèles génératifs

1 **Estimer**  $p(\mathbf{x}|\mathcal{C}_k)$  (et  $p(\mathcal{C}_k)$ )  $\forall \mathcal{C}_k$

par le **Principe du Maximum de Vraisemblance** (MLE)

# Choix de $\mathcal{H}$

## Modèles génératifs

- 1 **Estimer**  $p(\mathbf{x}|\mathcal{C}_k)$  (et  $p(\mathcal{C}_k)$ )  $\forall \mathcal{C}_k$   
par le **Principe du Maximum de Vraisemblance** (MLE)
- 2 **Décider**, en utilisant le **théorème de Bayes** :

$$p(\mathcal{C}_k|\mathbf{x}) = \frac{p(\mathbf{x}|\mathcal{C}_k) p(\mathcal{C}_k)}{p(\mathbf{x})}$$

avec  $p(\mathbf{x}) = \sum_k p(\mathbf{x}|\mathcal{C}_k) p(\mathcal{C}_k)$

# Choix de $\mathcal{H}$

## Modèles génératifs

- 1 **Estimer**  $p(\mathbf{x}|\mathcal{C}_k)$  (et  $p(\mathcal{C}_k)$ )  $\forall \mathcal{C}_k$   
par le **Principe du Maximum de Vraisemblance** (MLE)
- 2 **Décider**, en utilisant le **théorème de Bayes** :

$$p(\mathcal{C}_k|\mathbf{x}) = \frac{p(\mathbf{x}|\mathcal{C}_k) p(\mathcal{C}_k)}{p(\mathbf{x})}$$

$$\text{avec } p(\mathbf{x}) = \sum_k p(\mathbf{x}|\mathcal{C}_k) p(\mathcal{C}_k)$$

Exemple : Deux classes supposées gaussiennes de mêmes matrices de covariance

$$p(\mathbf{x}|\mathcal{C}_k) = \frac{1}{(2\pi)^{D/2}} \frac{1}{|\Sigma|^{1/2}} \exp\left\{-\frac{1}{2}(\mathbf{x} - \mu_k)^\top \Sigma^{-1}(\mathbf{x} - \mu_k)\right\}$$

# Choix de $\mathcal{H}$

## Modèles probabilistes discriminatifs

- **Estimer directement**  $p(\mathcal{C}_k|\mathbf{x})$  en utilisant un **modèle paramétré**

### Exemple : Deux classes et régression logistique

$$p(\mathcal{C}_1|\mathbf{x}) = \frac{1}{1 + \exp(\mathbf{w}^\top \mathbf{x})} = \sigma(\mathbf{w}^\top \mathbf{x})$$

- 1 Fonction de vraisemblance :  $p(\mathbf{y}|\mathbf{w}) = \prod_{i=1}^m \sigma(\mathbf{w}^\top \mathbf{x}_i)^{y_i} \{1 - \sigma(\mathbf{w}^\top \mathbf{x}_i)\}^{(1-y_i)}$
- 2 Fonction d'erreur :  
 $E(\mathbf{w}) = -\ln p(\mathbf{y}|\mathbf{w}) = -\sum_{i=1}^m \{y_i \ln \sigma(\mathbf{w}^\top \mathbf{x}_i) + (1 - y_i) \ln(1 - \sigma(\mathbf{w}^\top \mathbf{x}_i))\}$
- 3 Optimisation par **descente de gradient**



# Choix de $\mathcal{H}$

## Modèles probabilistes discriminatifs

- **Estimer directement**  $p(\mathcal{C}_k|\mathbf{x})$  en utilisant un **modèle paramétré**

### Exemple : Deux classes et régression logistique

$$p(\mathcal{C}_1|\mathbf{x}) = \frac{1}{1 + \exp(\mathbf{w}^\top \mathbf{x})} = \sigma(\mathbf{w}^\top \mathbf{x})$$

- 1 Fonction de vraisemblance :  $p(\mathbf{y}|\mathbf{w}) = \prod_{i=1}^m \sigma(\mathbf{w}^\top \mathbf{x}_i)^{y_i} \{1 - \sigma(\mathbf{w}^\top \mathbf{x}_i)\}^{(1-y_i)}$
- 2 Fonction d'erreur :  
 $E(\mathbf{w}) = -\ln p(\mathbf{y}|\mathbf{w}) = -\sum_{i=1}^m \{y_i \ln \sigma(\mathbf{w}^\top \mathbf{x}_i) + (1 - y_i) \ln(1 - \sigma(\mathbf{w}^\top \mathbf{x}_i))\}$
- 3 Optimisation par **descente de gradient**

Moins de paramètres à estimer.

# Choix de $\mathcal{H}$

## Fonctions de décision à base de dictionnaire


- $h(\mathbf{x}, \mathbf{w}) = \sum_{i=1}^n w_i g_i(\mathbf{x}) + w_0$
- où les  $g_i(\mathbf{x})$  sont des **fonctions de base**

# Choix de $\mathcal{H}$

## Fonctions de décision à base de dictionnaire

- $h(\mathbf{x}, \mathbf{w}) = \sum_{i=1}^n w_i g_i(\mathbf{x}) + w_0$
- où les  $g_i(\mathbf{x})$  sont des **fonctions de base**

### Exemple : Perceptron multi-couches



# Choix de $\mathcal{H}$

## Fonctions de décision par noyaux

- $h(\mathbf{x}) = \sum_i \text{“critiques”} \alpha_i y_i K(\mathbf{x}, \mathbf{x}_i) + \alpha_0$
- où les  $K_i(\cdot, \cdot)$  sont des **fonctions noyaux**

# Choix de $\mathcal{H}$

## Fonctions de décision par noyaux

- $h(\mathbf{x}) = \sum_i \text{“critiques”} \alpha_i y_i K(\mathbf{x}, \mathbf{x}_i) + \alpha_0$
- où les  $K_i(\cdot, \cdot)$  sont des **fonctions noyaux**

$$K_G(\mathbf{x}, \mathbf{x}_i) = \exp\left(-\frac{\|\mathbf{x}, \mathbf{x}_i\|^2}{2\sigma^2}\right)$$

$$K_L(\mathbf{x}, \mathbf{x}_i) = \mathbf{x}^\top \mathbf{x}_i$$

$$K_{Poly1}(\mathbf{x}, \mathbf{x}_i) = (\mathbf{x}^\top \mathbf{x}_i)^d$$

$$K_{Poly2}(\mathbf{x}, \mathbf{x}_i) = (\mathbf{x}^\top \mathbf{x}_i + c)^d$$

$$K_{sig}(\mathbf{x}, \mathbf{x}_i) = \tanh(\kappa \mathbf{x}^\top \mathbf{x}_i + \theta)$$

# Choix de $\mathcal{H}$

## Fonctions de décision par noyaux

- $h(\mathbf{x}) = \sum_i \text{"critiques"} \alpha_i y_i K(\mathbf{x}, \mathbf{x}_i) + \alpha_0$
- où les  $K_i(\cdot, \cdot)$  sont des **fonctions noyaux**

$$K_G(\mathbf{x}, \mathbf{x}_i) = \exp\left(-\frac{\|\mathbf{x}, \mathbf{x}_i\|^2}{2\sigma^2}\right)$$


$$K_L(\mathbf{x}, \mathbf{x}_i) = \mathbf{x}^\top \mathbf{x}_i$$

$$K_{Poly1}(\mathbf{x}, \mathbf{x}_i) = (\mathbf{x}^\top \mathbf{x}_i)^d$$

$$K_{Poly2}(\mathbf{x}, \mathbf{x}_i) = (\mathbf{x}^\top \mathbf{x}_i + c)^d$$

$$K_{sig}(\mathbf{x}, \mathbf{x}_i) = \tanh(\kappa \mathbf{x}^\top \mathbf{x}_i + \theta)$$

### Exemple : Séparateurs à Vastes Marges (SVM)




# Choix de $\mathcal{H}$


## Fonctions de décision par noyaux : Les SVM

$$h^*(\mathbf{x}) = (\mathbf{w}^* \cdot \mathbf{x}) + w_0^* = \sum_{i=1}^m \alpha_i^* u_i \cdot \langle \phi(\mathbf{x}_i), \phi(\mathbf{x}) \rangle + w_0^*$$

SVM : espace des redescripteurs  $\Phi(\mathcal{X})$



SVM : espace initial  $\mathcal{X}$





# Choix de $\mathcal{H}$

## Fonctions de décision par spécialisation

$$h_{\mathcal{X}} = h_{x_1} \times h_{x_2} \times \dots \times h_{x_n}$$

$$\mathcal{X} = h_{x_1} \cup h_{x_2} \cup \dots \cup h_{x_n}$$

### Exemple : Arbres de décisions






# Choix de $\mathcal{H}$

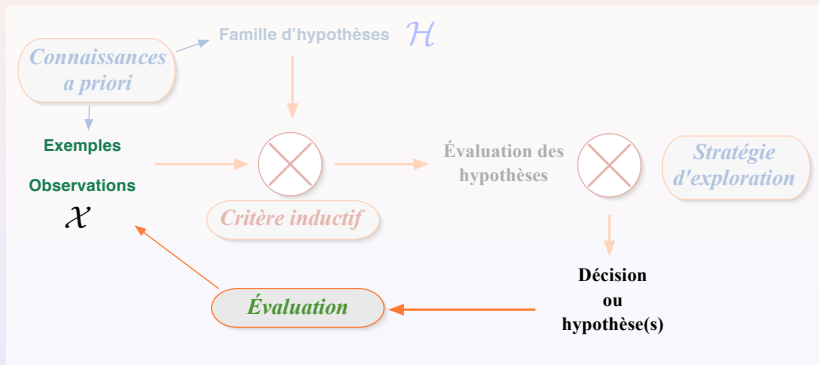
## Fonctions de décision par vote

### Exemple : Boosting



# L'apprentissage

## Ingrédients



# Les données

Caractéristiques à prendre en considération

## Représentativité

- $P_{\mathcal{X}}$  biaisé : *classe sous échantillonnée*
- $P_{\mathcal{Y}|\mathcal{X}}$  biaisé : *bruit ; dérive de concept*

## Dimension de l'espace

- Réduction de dimension

## Déséquilibre des classes

- Rééquilibrer

## Déséquilibre faux positifs / faux négatifs

- Techniques ad hoc

# Évaluation des résultats

## Précision en prédiction

Précision ; Rappel ; Validation croisée ; ... ; Courbe ROC ; test d'hypothèses

Souci principal : l'*overfitting*

# Évaluation des résultats

## Précision en prédiction

Précision ; Rappel ; Validation croisée ; ... ; Courbe ROC ; test d'hypothèses

Souci principal : l'*overfitting*

## Avec degré de confiance ou de probabilité

- Fct de coût adaptée (e.g. entropie croisée)
- Distance à la frontière de décision
- ...

# Évaluation des résultats

## Précision en prédiction

Précision ; Rappel ; Validation croisée ; ... ; Courbe ROC ; test d'hypothèses

Souci principal : l'*overfitting*

## Avec degré de confiance ou de probabilité

- Fct de coût adaptée (e.g. entropie croisée)
- Distance à la frontière de décision
- ...

## Interprétabilité de l'hypothèse

- Symbolique
- Simplicité

# Évaluation des résultats

## Contrôle de l'overfitting

### En théorie

- Fonctions de décision
  - Mesure de capacité ( $d_{VC}$ , ...)
- Modèles génératifs
  - **AIC** : Pénalisation =  $2 \times$  nb de paramètres libres  
(suppose que le modèle est correct, sinon modèle trop complexe)
  - **BIC** : Pénalisation =  $\log m \times$  nb de paramètres libres

# Évaluation des résultats

## Contrôle de l'overfitting

### En théorie

- Fonctions de décision
  - Mesure de capacité ( $d_{VC}$ , ...)
- Modèles génératifs
  - **AIC** : Pénalisation =  $2 \times$  nb de paramètres libres  
(suppose que le modèle est correct, sinon modèle trop complexe)
  - **BIC** : Pénalisation =  $\log m \times$  nb de paramètres libres

### En pratique

#### Validation croisée

- Nombre de **paramètres** (ou AIC ou BIC)
- Nombre de **concepts** (apprentissage relationnel ; arbre de décision)
- Nombre d'**itérations** (RNs, Boosting)



# Plan

- 1 Les fondements
- 2 En pratique
- 3 Conclusions et perspectives**
  - Le paradigme et ses frontières
  - Les directions

# Autres tâches d'apprentissage

- 1 Non supervisé
- 2 Semi-supervisé
- 3 Transduction
- 4 Apprentissage de tri (*ranking*)
- 5 Apprentissage de recommandations
- 6 Apprentissage de politique d'action (par renforcement)
- 7 Apprentissage à partir d'explications
- 8 ...

# Le paradigme ... et ses limites

- Lien entre passé et futur :  
distributions  $P_X$  et  $P_{Y|X}$  supposées stationnaires
- Données i.i.d.

# L'avenir

## Les tendances

### Dans le paradigme

- Très grosses Bases de Données
- Recherche de "Deep models" (modèles causaux hiérarchiques)
- Apprentissage et jeux (adversaire ; transfert)

# L'avenir

## Les tendances

### Dans le paradigme

- Très grosses Bases de Données
- Recherche de “Deep models” (modèles causaux hiérarchiques)
- Apprentissage et jeux (adversaire ; transfert)

### Renouvellement

- **Apprentissage-en-ligne et flux de données**
  - Pas de stockage possible : “one-pass learning”
  - Dérive de concept possible
  - Information dans la séquence d'exemples
- **Rationalité limitée**
  - *Intelligence ambiante*

# L'avenir ...

... commence ici !

MERCI !