

LU3I026 - Science des données

Apprentissage et modèles

Olivier Schwander <olivier.schwander@sorbonne-universite.fr>

Sorbonne Université

2025-2026

Types d'apprentissage

Apprentissage supervisé

- ▶ Données
- ▶ Étiquettes
- ▶ Exemple: des images, et le nom de l'objet dans l'image
- ▶ Difficulté: obtenir les étiquettes...

Apprentissage non-supervisé


- ▶ Juste les données
- ▶ Pas d'étiquettes

Autres


- ▶ Semi-supervisé
- ▶ Renforcement
- ▶ Auto-supervisé

Types d'apprentissage


Supervisé Non-supervisé Semi-supervisé Renforcement




Supervised Learning Algorithms



Unsupervised Learning Algorithms



Semi-supervised Learning Algorithms



Première chose à déterminer




- ▶ conditionne les choix d'algorithmes et de méthodes
- ▶ et les mesures de performances

Tâches d'apprentissage

Régression

Classification

Ordonnancement



Autres tâches

- ▶ Souvent des cas particuliers des tâches précédentes
- ▶ Image: segmentation (classif), localisation (régression)
- ▶ Texte: génération (classif), dialogue (ordonnancement)

Deuxième chose à déterminer

- ▶ Conditionne les choix précis de modèles
- ▶ Permet de fixer le protocole expérimental
- ▶ Ensuite, on peut réfléchir aux modèles

Premier modèle: linéaire

Dépendance linéaire entre l'entrée et la sortie

- ▶ Dans un espace vectoriel de dimension d , soit un point $x \in \mathbb{R}^d$
- ▶ $f_w(x) = \sum_{i=1}^d w_i x_i$
- ▶ f est le *modèle*
- ▶ w est le vecteur de *paramètres*

Apprentissage

- ▶ À partir des données
- ▶ Trouver le meilleur w

Abus de langage

- ▶ Linéaire: $y = ax$
- ▶ Affine: $y = ax + b$
- ▶ **Attention** en TP !

Régression linéaire

- ▶ Avec **UN** point: $\mathbf{x} = (x_1, \dots, x_d)$
- ▶ Une étiquette $y \in \mathbb{R}$
- ▶ Approcher l'étiquette y avec un modèle $f(x)$

Apprentissage supervisé

- ▶ À partir de N points $\{\mathbf{x}^{(1)}, \dots, \mathbf{x}^{(N)}\}$
- ▶ Et leur label y_1, \dots, y_N
- ▶ Chercher le meilleur compromis

Classification linéaire

- ▶ Avec **UN** point: $\mathbf{x} = (x_1, \dots, x_d)$
- ▶ Une étiquette $y \in \{-1, +1\}$
- ▶ Retrouver l'étiquette y avec un modèle $\text{signe}(f(x))$

avec $\text{signe}(x) = +1$ si $x \leq 0$ et -1 sinon

Apprentissage supervisé

- ▶ À partir de N points $\{\mathbf{x}^{(1)}, \dots, \mathbf{x}^{(N)}\}$
- ▶ Et leur label y_1, \dots, y_N
- ▶ Chercher le meilleur compromis

Géométriquement

- ▶ Tracer les points
- ▶ Tracer la frontière de décision
- ▶ À quoi correspond la somme ?

Plus proche voisin

Nearest neighbor

Idée

Associer un nouveau point à l'exemple connu le plus proche
[Au tableau]

k -plus proches voisins

Algorithme

- ▶ Pour un nouveau point
- ▶ Calculer toutes les distances entre ce point et les points connus
- ▶ Rechercher les k plus proches voisins
- ▶ Aggréger: vote (classification), moyenne (régression)

[Au tableau]

Analyse

Complexité algorithmique

- ▶ Temps, espace

Performances

- ▶ Influence du k
- ▶ Score et généralisation

[Au tableau]

Modèle linéaire

Classifieur binaire: deux sorties $+1$ ou -1

Hyperplan

- ▶ en dimension d
- ▶ équation $\sum_{i=1}^d w_i x_i = 0$
- ▶ (w_1, \dots, w_d) vecteur normal

Décision (ou inférence, ou prédiction)

- ▶ De quel coté est-on par rapport à la droite ?
- ▶ Produit scalaire entre le point à classer et le vecteur normal:
signe de $\sum_{i=1}^d w_i x_i$
- ▶ Si positif: $+1$
- ▶ Si négatif: -1

Comment apprendre ?

Apprentissage ?

Paramètres du modèle

- ▶ Caractérise les frontière de décision
- ▶ Permet de prendre la décision
- ▶ Ici les w_i

Apprentissage

- ▶ Choisir ces paramètres
- ▶ À partir des données
- ▶ Objectif: chercher les meilleurs paramètres

Moins de linéarité

Hyperplan linéaire

- ▶ Passe par l'origine
- ▶ C'est le $= 0$ dans l'équation

Modèle affine

- ▶ $\sum_{i=1}^d w_i x_i = b$
- ▶ b : **biais**

Comment choisir ce biais ?

- ▶ L'apprendre comme les w : paramètre
- ▶ Le fixer à l'avance: **hyper-paramètre**

Linéarité: suffisant ou pas ?

[Au tableau]

Hyperplan aléatoire

Paramètres

- ▶ Vecteur normal w
- ▶ Éventuellement biais b

“Apprentissage”

- ▶ Tirer aléatoirement un vecteur w (avec $\|w\|$ suffisamment grand)
- ▶ Pas vraiment de l'apprentissage: ne dépend pas des données

Performances

- ▶ Est-ce que ça marche bien ?
- ▶ Comment le savoir ?

Perceptron de Rosenblatt

~~Table~~ Vocabulaire

- ▶ Neurone formel
- ▶ Poids synaptique
- ▶ Activation

Version maths/stats/info

- ▶ Hyperplan, vecteur normal, etc
- ▶ Activation: signe (fonction de Heaviside, notée h)

Apprentissage

- ▶ Cette fois, un algorithme !
- ▶ Principe: mise à jour successives des paramètres en fonction des erreurs

Règle de Rosenblatt

Algorithme

- ▶ Tirer aléatoirement w
- ▶ **Tant qu'il y a des erreurs:**
 - ▶ **Pour** chaque exemple x et son étiquette y :
 - ▶ **Si** $y\langle w, x \rangle < 0$:
 $w \leftarrow w + yx$

Questions

- ▶ $y\langle w, x \rangle < 0$?
- ▶ *Tant qu'il y a des erreurs* ?
- ▶ Influence du w initial ?
- ▶ Impact de la mise à jour ?

Théorème de Novikoff

Convergence si et seulement si classes linéairement séparables

Règle de Widrow-Hoff


Algorithme

- ▶ Tirer aléatoirement w
- ▶ **Jusqu'à** convergence ou un nombre d'itérations maximum:
 - ▶ **Pour** chaque exemple x et son étiquette y :
$$\hat{y} = \langle w, x \rangle$$
$$w \leftarrow w + \alpha(y - \hat{y})x$$


Questions

- ▶ Points communs et différences ?
- ▶ α ?
- ▶ Nombre d'itération maximum ?
- ▶ D'où ça vient ? Voir prochain cours


Démonstration




Démonstration




Démonstration




Démonstration




Démonstration




Démonstration




Démonstration




Démonstration



Démonstration



Démonstration



Et le biais ?

Astuce

- ▶ Départ: hyperplan en dimension d : $\sum_{i=1}^d w_i x_i = b$
- ▶ $\sum_{i=1}^d w_i x_i - b = 0$
- ▶ $\sum_{i=1}^d w_i x_i + b(-1) = 0$
- ▶ Nouveau $x = (x_1, \dots, x_d, -1)$
- ▶ Nouveau $w = (w_1, \dots, w_d, b)$
- ▶ Arrivée: hyperplan en dimension $d + 1$: $\sum_{i=1}^{d+1} w_i x_i = 0$

Plus qu'une astuce

- ▶ Changement de la représentation des données
- ▶ Avant: modèle complexe, on ne sais pas quoi faire du biais
- ▶ Après: transformation des exemples, modèle simple et algorithmes déjà vus

Conclusion

Modèles et algorithme

- ▶ Modèle: forme de la frontière
- ▶ Apprentissage: trouver les paramètres à partir des données
- ▶ Hyper-paramètres: choisi à la main

Plein de choix

- ▶ Comment les faire ?

Évaluation

- ▶ La semaine prochaine

Objectif: généraliser