

## Méthodes à base de voisinage

1

- Idée
  - trouver des points d'apprentissage **similaires** au point de test
  - faire "voter" ces "voisins"
- Deux stratégies
  - **nombre de voisins** fixe  $\rightarrow$   $k$ -plus proches voisins ( $k$ -PPV)
  - **voisinage** fixe  $\rightarrow$  fenêtres de Parzen

## Méthodes à base de voisinage

2

- Terminologie/notation
  - **données d'entraînement**:  $D_n = ((\mathbf{x}_1, y_1), \dots, (\mathbf{x}_n, y_n))$
  - **observation**:  $\mathbf{x}_i \in \mathbb{R}^d$
  - **étiquette/classe**:  $y_i \in \{-1, 1\}$
  - **fonction discriminante**:  $g: \mathbb{R}^d \mapsto \mathbb{R}$ , souvent  $g: \mathbb{R}^d \mapsto [-1, 1]$
  - **fonction de classification/classifieur**:  $f: \mathbb{R}^d \mapsto \{-1, 1\}$
  - fonction discriminante  $\rightarrow$  classifieur:

$$f(\mathbf{x}) = \begin{cases} 1, & \text{si } g(\mathbf{x}) \geq 0 \\ -1, & \text{si } g(\mathbf{x}) < 0 \end{cases}$$

## Méthodes à base de voisinage

3

- Vote des voisins formellement:

$$g(\mathbf{x}) = \frac{1}{n} \sum_{\mathbf{x}_i \in V(\mathbf{x})} y_i$$

- **$k$ -PPV**:  
 $V(\mathbf{x})$  est l'ensemble des  $k$  points plus proches à  $\mathbf{x}$  dans  $D_n$
- **Parzen** (avec paramètre  $h$ ):  
 $V(\mathbf{x}) = \{\mathbf{x}_i : d(\mathbf{x}_i, \mathbf{x}) < h\}$

## Méthodes à base de voisinage

4

- **Erreur d'entraînement** (risque empirique)

$$\widehat{R}(f, D_n) = \widehat{R}(f) = \frac{1}{n} \sum_{i=1}^n I_{\{f(\mathbf{x}_i) \neq y_i\}}$$

- **fonction indicatrice**:  $I_{\{A\}} = \begin{cases} 1, & \text{si } A \text{ est vrai} \\ 0, & \text{sinon} \end{cases}$
- Comment choisir  $k$  ou  $h$ ?
  - minimiser  $\widehat{R}(f)$ ?
  - $k = 1, h \rightarrow 0$

## Méthodes à base de voisinage

5

- But: **généralisation!**

- **$k$  ou  $h$  petit**: les “électeurs” sont proches (donc **fiables**) mais pas nombreux (donc le vote est **bruité**)
- **$k$  ou  $h$  grand**: les “électeurs” sont nombreux (donc les fluctuations statistiques sont **lissées**) mais loin (donc **moins fiables**)

- Comment mesurer la généralisation?

- sur un **ensemble de test**:  $D'_m = ((x'_1, y'_1), \dots, (x'_m, y'_m))$

- **Erreur de test**

$$\widehat{R}(f, D'_m) = \widehat{R}'(f) = \frac{1}{m} \sum_{i=1}^m I_{\{f(x'_i) \neq y'_i\}}$$

## Fenêtres de Parzen

7

- Vote des voisins formellement:

$$g(\mathbf{x}) = \frac{1}{n} \sum_{d(\mathbf{x}_i, \mathbf{x}) < h} y_i = \frac{1}{n} \sum_{i=1}^n I_{\{d(\mathbf{x}_i, \mathbf{x}) < h\}} y_i = \frac{1}{n} \sum_{i=1}^n I_{\left\{\frac{d(\mathbf{x}_i, \mathbf{x})}{h} < 1\right\}} y_i$$

- remplacer  $I_{\{\cdot\}}$  par une fonction “lisse”:

$$g(\mathbf{x}) = \frac{1}{n} \sum_{i=1}^n \phi\left(\frac{d(\mathbf{x}_i, \mathbf{x})}{h}\right) y_i$$

- par exemple, gaussien standard  $N(0, 1)$ :

$$\phi(u) = \frac{1}{\sqrt{2\pi}} e^{-u^2/2}$$

## Méthodes à base de voisinage

6

- Courbes d'apprentissage

- erreurs d'entraînement et de test en terme du **paramètre de complexité/capacité**


- Fléau de la dimensionnalité

- les espaces de haute dimension sont **presque vides**: on a besoin de  $O(c^d)$  points pour la même densité
- les **voisins** plus proches **sont loin**
- les méthodes à base de voisinage “global” s'écroulent

## $k$ -plus-proche-voisin

8

- Partition de **Voronoi**



## k-plus-proche-voisin

9

- Complexité computationnelle

- méthode naïve:  $T(n, k, d) = O(nkd) = O(n^2d)$
- méthode de distances partielles:

$$d_r(\mathbf{a}, \mathbf{b}) = \left( \sum_{i=1}^r (a_i - b_i)^2 \right)^{1/2}, r \leq d$$

- méthodes d'arbre de recherche

## k-plus-proche-voisin

10

- Complexité computationnelle

- méthode de suppression/émondage (editing/pruning/condensing)

```

ÉMONDAGEDEPLUSPROCHEVOISIN( $D_n$ )
1  construire le diagramme de Voronoi complet de  $D_n$ 
2  pour  $j \leftarrow 1$  à  $n$  faire
3      pour tout les voisins de Voronoi  $x^j$  de  $x_j$  faire
4          si  $y_i \neq y^j$  alors
5              marquer  $x_i$ 
6  pour  $j \leftarrow 0$  à  $n$  faire
7      si  $x_j$  n'est pas marqué alors
8          supprimer  $x_i$ 
    
```

- $T(n, d) = O(d^3 n^{[d/2]} \ln n)$

## Métriques

11

- Propriétés d'une métrique

- positivité:  $d(\mathbf{a}, \mathbf{b}) \geq 0$
- réflexivité:  $d(\mathbf{a}, \mathbf{a}) = 0$
- symétrie:  $d(\mathbf{a}, \mathbf{b}) = d(\mathbf{b}, \mathbf{a})$
- inégalité de triangle:  $d(\mathbf{a}, \mathbf{b}) + d(\mathbf{b}, \mathbf{c}) \geq d(\mathbf{a}, \mathbf{c})$

## Métriques

12


- Exemples des métriques

|             |                       |  |
|-------------|-----------------------|--|
| euclidienne | $L_2$                 | $d(\mathbf{a}, \mathbf{b}) = \left( \sum_{i=1}^d (a_i - b_i)^2 \right)^{1/2}$          |
| Manhattan   | $L_1$                 | $d(\mathbf{a}, \mathbf{b}) = \sum_{i=1}^d  a_i - b_i $                                 |
|             | $L_\infty$            | $d(\mathbf{a}, \mathbf{b}) = \max_i  a_i - b_i $                                       |
| Minkowski   | $L_p$                 | $d(\mathbf{a}, \mathbf{b}) = \left( \sum_{i=1}^d  a_i - b_i ^p \right)^{1/p}$          |
| Tanimoto    | $L_{\text{Tanimoto}}$ | $d(S_1, S_2) = \frac{ S_1  +  S_2  - 2 S_1 \cap S_2 }{ S_1  +  S_2  -  S_1 \cap S_2 }$ |

## Métriques

13


- La métrique de Minkowski



## Métriques

14

- Les limitations de la métrique euclidienne



## La distance tangente


15

- Capturer l'invariance de certaines transformations:

$$TV_i = F_i(\mathbf{x}'; a_i) - \mathbf{x}'$$

## La distance tangente

16



## La distance tangente

17

$$d_{tan}(\mathbf{x}', \mathbf{x}) = \min_{\mathbf{a}} [\|\mathbf{x}' + \mathbf{T}\mathbf{a} - \mathbf{x}\|]$$

