

MAP 553

Apprentissage statistique

Christophe Giraud

Université Paris Sud et Ecole Polytechnique

PC9

Convexification

Notations

Aujourd'hui :

- les étiquettes y_i appartiennent à $\{-1, +1\}$
- les classifieurs h sont à valeurs dans $\{-1, +1\}$:

$$h : \mathcal{X} \rightarrow \{-1, +1\}$$

Minimiseur du risque empirique

A partir d'observations $(x_i, y_i)_{i=1, \dots, n}$ et pour un ensemble \mathcal{H} de classifieurs,

$$\hat{h}_{\mathcal{H}} = \operatorname{argmin}_{h \in \mathcal{H}} \hat{R}_n(h), \quad \text{où} \quad \hat{R}_n(h) = \frac{1}{n} \sum_{i=1}^n \mathbf{1}_{\mathbb{R}^+}(-y_i h(x_i))$$

En pratique

- 1 \mathcal{H} non convexe,
- 2 $\hat{R}_n(h)$ non convexe.

Temps de calcul prohibitif !

Minimiseur du risque empirique

A partir d'observations $(x_i, y_i)_{i=1, \dots, n}$ et pour un ensemble \mathcal{H} de classifieurs,

$$\hat{h}_{\mathcal{H}} = \operatorname{argmin}_{h \in \mathcal{H}} \hat{R}_n(h), \quad \text{où} \quad \hat{R}_n(h) = \frac{1}{n} \sum_{i=1}^n \mathbf{1}_{\mathbb{R}^+}(-y_i h(x_i))$$

En pratique

- 1 \mathcal{H} non convexe,
- 2 $\hat{R}_n(h)$ non convexe.

Temps de calcul prohibitif !

Deux sources de difficultés

- 1 \mathcal{H} non convexe,
- 2 $\hat{R}_n(h)$ non convexe.

Convexification du problème

Pour


- \mathcal{F} un ensemble convexe de fonction $f : \mathcal{X} \rightarrow \mathbb{R}$
- et $\varphi : \mathbb{R} \rightarrow \mathbb{R}^+$ convexe croissante

on définit :

$$\hat{h}_{\varphi, \mathcal{F}} = \text{signe}(\hat{f}_{\varphi, \mathcal{F}}) \quad \text{avec} \quad \hat{f}_{\varphi, \mathcal{F}} = \operatorname{argmin}_{f \in \mathcal{F}} \frac{1}{n} \sum_{i=1}^n \varphi(-y_i f(x_i))$$

Quelques φ populaires

- Perte hinge : $\varphi(x) = (1 + x)_+$
- Perte exponentielle : $\varphi(x) = e^x$
- Perte Logit : $\varphi(x) = \log_2(1 + e^x)$



Quelques \mathcal{F} populaires

- **Convexification d'un ensemble de classifieurs de bases** $\{h_1, \dots, h_M\}$:

$$\mathcal{F} = \left\{ f = \sum_{j=1}^M \theta_j h_j : \theta \in \Theta \right\}$$

avec Θ un ensemble convexe de \mathbb{R}^M .

- **Boule d'un RKHS \mathcal{W}** : pour $R > 0$

$$\mathcal{F} = \{f \in \mathcal{W} : |f|_{\mathcal{W}} \leq R\}.$$

SVM

Les SVM correspondent au choix

- $\varphi(x) = (1 + x)_+$
- $\mathcal{F} = \{f \in \mathcal{W} : |f|_{\mathcal{W}} \leq R\}$, avec \mathcal{W} un RKHS et $R > 0$.

SVM : version lagrangienne

le classifieur $\hat{h}_{\varphi, \mathcal{F}}$ est donné par $\hat{h}_{\varphi, \mathcal{F}}(x) = \text{signe}(\hat{f}_{\varphi, \mathcal{F}}(x))$ avec

$$\hat{f}_{\varphi, \mathcal{F}} = \operatorname{argmin}_{f \in \mathcal{W}} \left\{ \frac{1}{n} \sum_{i=1}^n (1 - y_i f(x_i))_+ + \lambda |f|_{\mathcal{W}}^2 \right\}$$

Rappels d'optimisation convexe

Considérons $f, -g_1, \dots, -g_n$ convexes de classe \mathcal{C}^1 et

$$\hat{x} = \underset{g_i(x) \geq 0}{\operatorname{argmin}} f(x).$$

Conditions nécessaires de Kuhn-Tucker

Soit

$$L(x, \lambda) = f(x) - \sum_{i=1}^n \lambda_i g_i(x).$$


Il existe $\hat{\lambda}$ tel que

- 1 $\nabla_x L(\hat{x}, \hat{\lambda}) = 0$
- 2 $\min(\hat{\lambda}_i, g_i(\hat{x})) = 0$ pour $i = 1, \dots, n$

Dualité forte


$$\hat{\lambda} = \underset{\lambda \geq 0}{\operatorname{argsup}} \underset{x}{\operatorname{inf}} L(x, \lambda)$$

Data :




Linear kernel : les points "+" sont les vecteurs supports

SVM classification plot



Gaussian kernel : les points "+" sont les vecteurs supports

SVM classification plot



$$\begin{aligned}(\hat{\alpha}, \hat{\gamma}) &\in \operatorname{argmax}_{(\alpha, \gamma) \geq 0} \min_{\beta, \xi} \left\{ \frac{1}{\lambda} \langle K\beta, \beta \rangle - \langle K\beta, y.\alpha \rangle + \langle \alpha, 1 \rangle + \langle \xi, \frac{1}{n} - \alpha - \gamma \rangle \right\} \\ &\in \operatorname{argmax}_{(\alpha, \gamma) \geq 0} \min_{\xi} \left\{ -\frac{1}{4\lambda} \langle K(y.\alpha), y.\alpha \rangle + \langle \alpha, 1 \rangle + \langle \xi, \frac{1}{n} - \alpha - \gamma \rangle \right\} \\ &\in \operatorname{argmax}_{(\alpha, \gamma) \geq 0 \ \& \ \alpha + \gamma = \frac{1}{n}} \left\{ -\frac{1}{4\lambda} \langle K(y.\alpha), y.\alpha \rangle + \langle \alpha, 1 \rangle \right\} \\ &\in \operatorname{argmax}_{0 \leq \alpha \leq \frac{1}{n} \ \& \ \gamma = \frac{1}{n} - \alpha} \left\{ -\frac{1}{4\lambda} \langle K(y.\alpha), y.\alpha \rangle + \langle \alpha, 1 \rangle \right\}\end{aligned}$$

AdaBoost

AdaBoost fournit une solution **approximative** au problème

$$\hat{f}_{\varphi, \mathcal{F}} = \operatorname{argmin}_{f \in \mathcal{F}} \left\{ \frac{1}{n} \sum_{i=1}^n \varphi(-y_i f(x_i)) \right\}$$

avec

- $\varphi(x) = \exp(x)$
- $\mathcal{F} = \left\{ f = \sum_{j=1}^M \theta_j h_j : \theta \in \mathbb{R}^M \right\}$

<< forward learning >>

Initialisation : $\hat{f}_0 = 0$

Itérer : For $m = 1, \dots, M$ do :

$$\hat{f}_m = \hat{f}_{m-1} + \beta_m h_{j_m} \quad \text{où}$$

$$(\beta_m, h_{j_m}) = \operatorname{argmin}_{\substack{h \in \{h_1, \dots, h_M\} \\ \beta \in \mathbb{R}}} \frac{1}{n} \sum_{i=1}^n \varphi \left(-y_i (\hat{f}_{m-1}(x_i) + \beta h(x_i)) \right).$$

AdaBoost

AdaBoost fournit une solution **approximative** au problème

$$\hat{f}_{\varphi, \mathcal{F}} = \operatorname{argmin}_{f \in \mathcal{F}} \left\{ \frac{1}{n} \sum_{i=1}^n \varphi(-y_i f(x_i)) \right\}$$

avec

- $\varphi(x) = \exp(x)$
- $\mathcal{F} = \left\{ f = \sum_{j=1}^M \theta_j h_j : \theta \in \mathbb{R}^M \right\}$

« forward learning »

Initialisation : $\hat{f}_0 = 0$

Itérer : For $m = 1, \dots, M$ do :

$$\hat{f}_m = \hat{f}_{m-1} + \beta_m h_{j_m} \quad \text{où}$$

$$(\beta_m, h_{j_m}) = \operatorname{argmin}_{\substack{h \in \{h_1, \dots, h_M\} \\ \beta \in \mathbb{R}}} \frac{1}{n} \sum_{i=1}^n \varphi \left(-y_i (\hat{f}_{m-1}(x_i) + \beta h(x_i)) \right).$$

$$\frac{1}{n} \sum_{i=1}^n \varphi\left(-y_i(\hat{f}_{m-1}(x_i) + \beta h(x_i))\right) = (e^\beta - e^{-\beta}) \sum_{i=1}^n w_i^{(m)} \mathbf{1}_{h(x_i) \neq y_i} + e^{-\beta} \sum_{i=1}^n w_i^{(m)}$$

avec $w_i^{(m)} = n^{-1} \exp(-y_i \hat{f}_{m-1}(x_i))$

Solution

Si

$$\text{err}_m(h) = \frac{\sum_{i=1}^n w_i^{(m)} \mathbf{1}_{h(x_i) \neq y_i}}{\sum_{i=1}^n w_i^{(m)}} > 0 \quad \text{pour tout } h$$

on a

$$h_{j_m} = \underset{h \in \{h_1, \dots, h_M\}}{\text{argmin}} \text{err}_m(h) \quad \text{et} \quad \beta_m = \frac{1}{2} \log \left(\frac{1 - \text{err}_m(h_{j_m})}{\text{err}_m(h_{j_m})} \right).$$

$$\frac{1}{n} \sum_{i=1}^n \varphi\left(-y_i(\hat{f}_{m-1}(x_i) + \beta h(x_i))\right) = (e^\beta - e^{-\beta}) \sum_{i=1}^n w_i^{(m)} \mathbf{1}_{h(x_i) \neq y_i} + e^{-\beta} \sum_{i=1}^n w_i^{(m)}$$

avec $w_i^{(m)} = n^{-1} \exp(-y_i \hat{f}_{m-1}(x_i))$

Solution

Si

$$\text{err}_m(h) = \frac{\sum_{i=1}^n w_i^{(m)} \mathbf{1}_{h(x_i) \neq y_i}}{\sum_{i=1}^n w_i^{(m)}} > 0 \quad \text{pour tout } h$$

on a

$$h_{j_m} = \underset{h \in \{h_1, \dots, h_M\}}{\text{argmin}} \text{err}_m(h) \quad \text{et} \quad \beta_m = \frac{1}{2} \log \left(\frac{1 - \text{err}_m(h_{j_m})}{\text{err}_m(h_{j_m})} \right).$$

AdaBoost

Initialisation : $w_i^{(1)} = 1/n$, pour $i = 1, \dots, n$

Itérer : For $m = 1, \dots, M$

$$h_{j_m} = \underset{h \in \{h_1, \dots, h_M\}}{\operatorname{argmin}} \operatorname{err}_m(h)$$

$$2\beta_m = \log(1 - \operatorname{err}_m(h_{j_m})) - \log(\operatorname{err}_m(h_{j_m}))$$

$$w_i^{(m+1)} = w_i^{(m)} \exp(2\beta_m \mathbf{1}_{h_{j_m}(x_i) \neq y_i}), \quad i = 1, \dots, n$$

Résultat : $\hat{f}_M(x) = \sum_{m=1}^M \beta_m h_{j_m}(x)$.

Bonne fin d'année !