

感知机

张腾

2025 年 3 月 24 日

1 感知机

给定 $\mathcal{D} = \{(x_i, y_i)\}_{i \in [m]} \subseteq \mathbb{R}^n \times \{1, -1\}$, 感知机 (perceptron) 学一个形如 $f(x) = \text{sign}(w^\top x)$ 的超平面模型对数据进行分类。

设初始 $w_1 = \mathbf{0}$, 第 t 轮的样本为 (x_i, y_i) , 其中 (i_1, \dots, i_m) 是 $(1, \dots, m)$ 的某个随机排列, 若 $y_i w_t^\top x_i \leq 0$, 即预测错误, 则更新 $w_{t+1} = w_t + \eta y_i x_i$, 其中 $\eta > 0$ 为学习率 (learning rate)。注意

$$y_i w_{t+1}^\top x_i = y_i w_t^\top x_i + \eta y_i x_i^\top x_i > y_i w_t^\top x_i$$

即更新后 w_{t+1} 在样本 (x_i, y_i) 上的预测比原来有所改善, 即使更新完还不对, 多错几次最终总能对。

考虑如下优化问题

$$\min_w L(w) = \frac{1}{m} \sum_{i \in [m]} \max\{0, -y_i w^\top x_i\}$$

目标函数次梯度为

$$\frac{\partial L(w)}{\partial w} = -\frac{1}{m} \sum_{i \in [m]} y_i x_i \mathbb{I}(y_i w^\top x_i \leq 0)$$

用随机梯度下降 (SGD) 进行求解, 设第 t 轮随机采样的样本为 (x_i, y_i) , 则更新为

$$w_{t+1} = w_t + \eta y_i x_i \mathbb{I}(y_i w_t^\top x_i \leq 0) = \begin{cases} w_t + \eta y_i x_i, & \text{if } y_i w_t^\top x_i \leq 0 \\ w_t, & \text{o.w.} \end{cases}$$

其中 $\eta > 0$ 是 SGD 的步长 (step size), 不难看出感知机就是在用 SGD 优化损失函数 $L(w)$ 。

2 Novikoff's 定理

定理 1 (Novikoff's 定理). 设 $\mathcal{D} = \{(x_i, y_i)\}_{i \in [m]} \subseteq \mathbb{R}^n \times \{1, -1\}$, 假设

1. 对 $\forall i \in [m]$ 存在 $r > 0$ 使得 $\|x_i\| \leq r$
2. 存在 $\rho > 0$ 和单位向量 $v \in \mathbb{R}^n$ 使得对于任意 $i \in [m]$ 有 $y_i v^\top x_i \geq \rho$

那么感知机的更新次数不超过 r^2/ρ^2 。

证明. 设集合 \mathcal{I} 是感知机进行更新的轮次集合, 易知有

$$|\mathcal{I}|\rho \leq \sum_{t \in \mathcal{I}} y_{i_t} \mathbf{v}^\top \mathbf{x}_{i_t} \leq \|\mathbf{v}\| \left\| \sum_{t \in \mathcal{I}} y_{i_t} \mathbf{x}_{i_t} \right\| = \left\| \sum_{t \in \mathcal{I}} \frac{\mathbf{w}_{t+1} - \mathbf{w}_t}{\eta} \right\| = \left\| \frac{\mathbf{w}_{M+1}}{\eta} \right\|$$

其中 $M = \max\{t \mid t \in \mathcal{I}\}$, 进一步有

$$\begin{aligned} |\mathcal{I}|\rho &\leq \left\| \frac{\mathbf{w}_{M+1}}{\eta} \right\| = \sqrt{\left\| \frac{\mathbf{w}_{M+1}}{\eta} \right\|^2} = \sqrt{\sum_{t \in \mathcal{I}} \frac{\|\mathbf{w}_{t+1}\|^2 - \|\mathbf{w}_t\|^2}{\eta^2}} = \sqrt{\sum_{t \in \mathcal{I}} \frac{\|\mathbf{w}_t + \eta y_{i_t} \mathbf{x}_{i_t}\|^2 - \|\mathbf{w}_t\|^2}{\eta^2}} \\ &= \sqrt{\sum_{t \in \mathcal{I}} \frac{2\eta y_{i_t} \mathbf{w}_t^\top \mathbf{x}_{i_t} + \eta^2 \|\mathbf{x}_{i_t}\|^2}{\eta^2}} \leq \sqrt{\sum_{t \in \mathcal{I}} \|\mathbf{x}_{i_t}\|^2} \leq \sqrt{|\mathcal{I}|r^2} \end{aligned}$$

移项整理即可。 ♣

注. 这个界只跟归一化的间隔 r/ρ 有关, 与维度 n 无关, 同时也与学习率 η 无关, 因此一般教材上讲感知机时都是将 η 定为 1 的。

注. 这个界是紧的, 考虑这样一个例子, $\mathbf{x}_1, \dots, \mathbf{x}_m$ 分别为 \mathbb{R}^m 的 m 个单位向量, 前 m 轮感知机每次的预测值都 ≤ 0 , 故会连续更新 m 次, 之后得到

$$\mathbf{w}_{m+1} = \eta \sum_{i \in [m]} y_i \mathbf{x}_i$$

由 $\mathbf{x}_1, \dots, \mathbf{x}_m$ 之间的两两正交性知

$$\frac{y_j \mathbf{w}_{m+1}^\top \mathbf{x}_j}{\|\mathbf{w}_{m+1}\|} = \frac{y_j \eta \sum_{i \in [m]} y_i \mathbf{x}_i^\top \mathbf{x}_j}{\|\mathbf{w}_{m+1}\|} = \frac{\eta}{\eta \sqrt{m}} = \frac{1}{\sqrt{m}}$$

即 \mathbf{w}_{m+1} 可将所有样本正确分类且间隔为 $1/\sqrt{m}$, 下面说明 $\rho = 1/\sqrt{m}$, 结合 $r^2 = 1$ 可知界是紧的。若单位向量 $\mathbf{v} = [v_i]_{i \in [m]}$ 使得间隔 $\rho > 1/\sqrt{m}$, 则对于 $\forall i \in [m]$ 有 $y_i \mathbf{v}^\top \mathbf{x}_i = y_i v_i \geq \rho > 1/\sqrt{m}$, 于是 $\|\mathbf{v}\|^2 = \sum_{i \in [m]} v_i^2 > \sum_{i \in [m]} 1/m = 1$, 这与 \mathbf{v} 是单位向量矛盾。

注. Novikoff's 定理表明只要样本线性可分, 感知机都会在有限步内停止; 但当间隔 ρ 很小时, 收敛可能会很慢, 事实上存在一些极端情况, 感知机的更新次数达到 $\Omega(2^m)$ 。设 \mathbb{R}^m 中的 m 个样本为

$$\begin{aligned} \mathbf{x}_1 &= [1, 0, 0, 0, 0, \dots, 0], & y_1 &= 1 \\ \mathbf{x}_2 &= [1, -1, 0, 0, 0, \dots, 0], & y_2 &= -1 \\ \mathbf{x}_3 &= [-1, -1, 1, 0, 0, \dots, 0], & y_3 &= 1 \\ \mathbf{x}_4 &= [1, 1, 1, -1, 0, \dots, 0], & y_4 &= -1 \\ \mathbf{x}_5 &= [-1, -1, -1, -1, 1, \dots, 0], & y_5 &= 1 \\ &\vdots \\ \mathbf{x}_i &= [(-1)^i, \dots, (-1)^i, (-1)^{i+1}, 0, \dots, 0], & y_i &= (-1)^{i+1} \end{aligned}$$

易知

$$y_i \mathbf{x}_i = [\underbrace{-1, \dots, -1}_{i-1 \text{ 个}}, 1, 0, \dots, 0]$$

- 欲使 x_1 分类正确, 需要有 $w_1 > 0$, 加一次 $\eta y_1 x_1$ 即可
- 在 $w_1 > 0$ 的情况下, 欲使 x_2 分类正确, 需要有 $w_2 > 0$, 同样加一次 $\eta y_2 x_2$ 可使得 $w_2 > 0$, 但这会同时将 w_1 减小 η , 因此要想 w_1 不发生变化, 加一次 $\eta y_2 x_2$ 后需跟着再加一次 $\eta y_1 x_1$
- 在 $w_1, w_2 > 0$ 的情况下, 欲使 x_3 分类正确, 需要有 $w_3 > 0$, 同样加一次 $\eta y_3 x_3$ 可使得 $w_3 > 0$, 但这会同时将 w_1, w_2 减小 η , 因此加一次 $\eta y_3 x_3$ 后需跟着再加一次 $\eta y_1 x_1$ 、一次 $\eta y_2 x_2$, 而加一次 $\eta y_2 x_2$ 又得再加一次 $\eta y_1 x_1$

如此易知, 设欲使 $w_i > 0$ 且同时不改变其他 w_j ($j < i$) 所需的更新次数为 a_i , 由前面的分析

$$\begin{aligned}
 a_1 &= 1 = 2^0 \\
 a_2 &= 1 + a_1 = 2 = 2^1 \\
 a_3 &= 1 + a_2 + a_1 = 4 = 2^2 \\
 a_4 &= 1 + a_3 + a_2 + a_1 = 8 = 2^3 \\
 &\vdots \\
 a_i &= 1 + a_{i-1} + \dots + a_1
 \end{aligned}$$

由数学归纳法易证 $a_i = 2^{i-1}$, 因此光是将 w 的全部分量变为正数所需的更新次数就至少为 $2^0 + 2^1 + \dots + 2^{m-1} = 2^m$, 而将全部样本分类正确的要求更苛刻, 因此所需的更新次数更多, 故为 $\Omega(2^m)$ 。

3 线性不可分

Novikoff's 定理的假设条件是数据线性可分, 对于线性不可分的数据有:

定理 2. 设 $\mathcal{D} = \{(x_i, y_i)\}_{i \in [m]} \subseteq \mathbb{R}^n \times \{1, -1\}$, 假设

1. 对 $\forall i \in [m]$ 存在 $r > 0$ 使得 $\|x_i\| \leq r$
2. 对于单位向量 $v \in \mathbb{R}^n$ 和 $\rho > 0$, 记 $\epsilon_i = \max\{0, \rho - y_i v^\top x_i\}$ 及 $\delta = \sqrt{\sum_{i \in [m]} \epsilon_i^2}$

则存在映射将所有样本映射到高维空间后线性可分, 且感知机的更新次数不超过 $(r+\delta)^2/\rho^2$ 。

证明. 对 $\forall x_i$, 原来的特征保留不变, 后面添加 m 位, 其中第 i 位为取值待定的 A , 其余为零

$$x_i = [x_{i,1}, \dots, x_{i,n}] \mapsto x'_i = [x_{i,1}, \dots, x_{i,n}, 0, \dots, 0, \underbrace{A}_{\text{第 } n+i \text{ 个分量}}, 0, \dots, 0]$$

v 也要映射到 \mathbb{R}^{n+m} 中:

$$v = [v_1, \dots, v_n] \mapsto v' = \left[\frac{v_1}{B}, \dots, \frac{v_n}{B}, \frac{y_1 \epsilon_1}{AB}, \dots, \frac{y_m \epsilon_m}{AB} \right]$$

其中 B 是待定参数, 根据 v' 为单位向量有

$$1 = \|v'\|^2 = \sum_{i \in [n]} \frac{v_i^2}{B^2} + \sum_{i \in [m]} \frac{\epsilon_i^2}{A^2 B^2} = \frac{1}{B^2} + \frac{\delta^2}{A^2 B^2} \implies B = \sqrt{1 + \frac{\delta^2}{A^2}}$$

如此映射后有

$$y_i \mathbf{v}'^\top \mathbf{x}'_i = y_i \left(\frac{\mathbf{v}^\top \mathbf{x}_i}{B} + \frac{y_i \epsilon_i}{B} \right) = \frac{y_i \mathbf{v}^\top \mathbf{x}_i + \epsilon_i}{B} \geq \frac{\rho}{B}$$

这意味着 $\mathbf{x}'_1, \dots, \mathbf{x}'_m$ 线性可分且间隔至少为 ρ/B ，注意此时有 $\|\mathbf{x}'\|^2 \leq r^2 + A^2$ ，于是更新次数不超过

$$\frac{r^2 + A^2}{\rho^2/B^2} = \frac{(r^2 + A^2)(1 + \delta^2/A^2)}{\rho^2} = \frac{r^2 + \delta^2 + A^2 + r^2\delta^2/A^2}{\rho^2}$$

上式在 $A^2 = r\delta$ 可使界最紧，为 $(r+\delta)^2/\rho^2$ 。

♣

4 大间隔

Novikoff's 定理要求存在超平面 $\mathbf{v}^\top \mathbf{x}$ 间隔为 ρ ，但感知机的更新条件是 $y_i \mathbf{w}^\top \mathbf{x}_i \leq 0$ ，因此最终模型只能做到 $y_i \mathbf{w}^\top \mathbf{x}_i > 0$ ，间隔是没有保证的，可能会很小。若将更新条件修改成 $y_i \mathbf{w}^\top \mathbf{x}_i / \|\mathbf{w}\| < k\rho$ ，其中 $k \in (0, 1)$ ，这样最终就能得到一个间隔至少为 $k\rho$ 的超平面。下面证明经此改动后，感知机的更新次数不超过 $4r^2/(1-k)^2\rho^2$ 。因此若想得到间隔至少为 $\rho/3$ 的超平面，更新次数上界就是 $9r^2/\rho^2$ ；若想得到间隔至少为 $\rho/2$ 的超平面，更新次数上界就是 $16r^2/\rho^2$ 。

不妨固定学习率 η 为 1，此时同样有

$$\begin{aligned} |\mathcal{I}|\rho &\leq \sum_{t \in \mathcal{I}} y_i \mathbf{v}^\top \mathbf{x}_i \leq \|\mathbf{v}\| \left\| \sum_{t \in \mathcal{I}} y_i \mathbf{x}_i \right\| = \left\| \sum_{t \in \mathcal{I}} (\mathbf{w}_{t+1} - \mathbf{w}_t) \right\| = \|\mathbf{w}_{M+1}\| = \sqrt{\|\mathbf{w}_{M+1}\|^2} \\ &= \sqrt{\sum_{t \in \mathcal{I}} (\|\mathbf{w}_{t+1}\|^2 - \|\mathbf{w}_t\|^2)} = \sqrt{\sum_{t \in \mathcal{I}} (\|\mathbf{w}_t + y_i \mathbf{x}_i\|^2 - \|\mathbf{w}_t\|^2)} = \sqrt{\sum_{t \in \mathcal{I}} (2y_i \mathbf{w}_t^\top \mathbf{x}_i + \|\mathbf{x}_i\|^2)} \end{aligned}$$

Novikoff's 定理的证明中， $y_i \mathbf{w}_t^\top \mathbf{x}_i$ 直接放缩成零，从而得到 $|\mathcal{I}|\rho \leq \sqrt{|\mathcal{I}|r^2}$ 。现在 $y_i \mathbf{w}_t^\top \mathbf{x}_i$ 的上界变成了 $k\rho\|\mathbf{w}_t\|$ ，需要更细致的处理。

首先若 $\|\mathbf{w}_{M+1}\| < 2r^2/(1-k)\rho$ ，注意 $2/(1-k) > 2$ ，于是

$$|\mathcal{I}| \leq \frac{\|\mathbf{w}_{M+1}\|}{\rho} < \frac{2r^2}{(1-k)\rho^2} < \frac{4r^2}{(1-k)^2\rho^2}$$

故不妨设 $\|\mathbf{w}_{M+1}\| \geq 2r^2/(1-k)\rho$ ，下面求 $\|\mathbf{w}_{M+1}\|$ 的上界，注意

$$\|\mathbf{w}_{t+1}\|^2 = \|\mathbf{w}_t + y_i \mathbf{x}_i\|^2 = \|\mathbf{w}_t\|^2 + 2y_i \mathbf{w}_t^\top \mathbf{x}_i + \|\mathbf{x}_i\|^2 \leq \|\mathbf{w}_t\|^2 + 2k\rho\|\mathbf{w}_t\| + r^2 < (\|\mathbf{w}_t\| + k\rho)^2 + r^2$$

于是

$$\|\mathbf{w}_{t+1}\| - \|\mathbf{w}_t\| - k\rho \leq \frac{r^2}{\|\mathbf{w}_{t+1}\| + \|\mathbf{w}_t\| + k\rho}$$

若 $\|\mathbf{w}_t\|$ 和 $\|\mathbf{w}_{t+1}\|$ 中至少有一个 $\geq 2r^2/(1-k)\rho$ ，则

$$\|\mathbf{w}_{t+1}\| \leq \|\mathbf{w}_t\| + k\rho + \frac{r^2}{2r^2/(1-k)\rho + k\rho} \leq \|\mathbf{w}_t\| + k\rho + \frac{(1-k)\rho}{2} = \|\mathbf{w}_t\| + \frac{(1+k)\rho}{2}$$

$\|w\|$ 初始为 $\|w_1\| = 0$, 最终为 $\|w_{M+1}\| \geq 2r^2/(1-k)\rho$, 因此必存在某个轮次, 不妨设为第 t' 轮, 满足 $\|w_{t'}\| < 2r^2/(1-k)\rho$ 且对 $\forall t > t' : \|w_t\| \geq 2r^2/(1-k)\rho$, 于是有

$$\|w_{t'+1}\| \leq \|w_{t'}\| + \frac{(1+k)\rho}{2}, \dots, \|w_{M+1}\| \leq \|w_M\| + \frac{(1+k)\rho}{2}$$

上面的不等式个数不超过 $|\mathcal{I}|$ 个, 累加可得

$$\|w_{M+1}\| \leq \|w_{t'}\| + |\mathcal{I}| \frac{(1+k)\rho}{2} < \frac{2r^2}{(1-k)\rho} + |\mathcal{I}| \frac{(1+k)\rho}{2}$$

回代易知有

$$|\mathcal{I}|\rho \leq \|w_{M+1}\| < \frac{2r^2}{(1-k)\rho} + |\mathcal{I}| \frac{(1+k)\rho}{2} \implies |\mathcal{I}| < \frac{4r^2}{(1-k)^2\rho^2}$$