

Regularization

正则化

郑滕飞

2023.5.17

目录

正则化的动机

泛化误差与过拟合
正则化项的引入

统计学习与正则化

优化视角下的正则化
岭回归与 Lasso 回归
一个例子：极致梯度提升树

深度学习中的正则化

神经网络的正则化
隐式正则化技巧

多项式逼近问题

问题：给定 $(x_i, y_i), i = 0, \dots, n - 1$, 且 x_i 互不相同, 求逼近它们的一个至多 $n - 1$ 次多项式 $p(x)$ 。

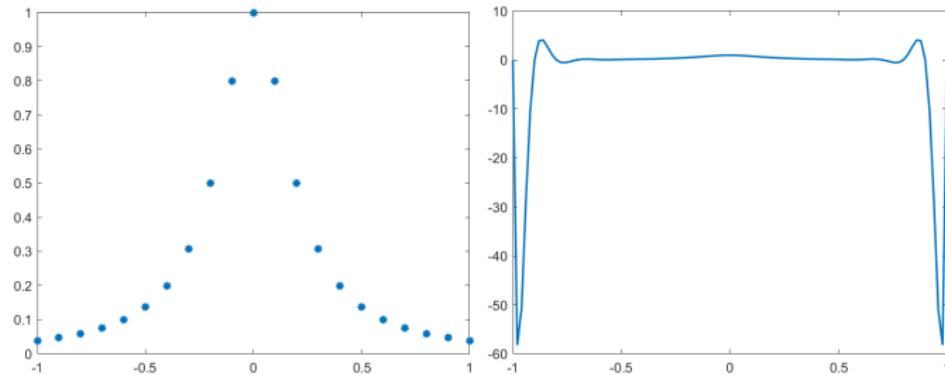
- ▶ 利用 Vandermonde 行列式容易看出存在唯一精确解
- ▶ 可证明 $x \in [a, b]$ 时多项式 $p(x)$ 插值 $f(x)$ 误差界

$$\frac{\prod_{i=0}^{n-1} (x - x_i)}{n!} \max_{t \in [a, b]} |f^{(n)}(t)|$$

- ▶ 若可以自由采样, 选取合适结点 (Chebyshev point) 可以显著降低误差

龙格现象

一般结点 (如等距结点) 插值多项式，在边界处容易出现很高的误差。



泛化误差

对拟合问题，可以考虑简单的均方误差作为**泛化误差**（与模型泛化能力相关）：

$$MSE(\hat{f}(x)) = E[(\hat{f}(x) - f(x))^2] = E[\hat{f}(x) - f(x)]^2 + Var(\hat{f}(x))$$

- ▶ 包含**偏差项**与**方差项**两项
- ▶ 也对应近似误差与估计误差（测试集结果未知）
- ▶ 近似误差降低，但估计误差反而升高的情况即为**过拟合**

偏差-方差权衡

- ▶ No Free Lunch Theorem
- ▶ 实际情况中基本不可能同时降低偏差与方差
- ▶ 无偏估计一般易于直接求解，于是考虑在偏差允许的范围内降低方差

正则化项的引入

回到多项式逼近问题，严格的逼近也就相当于

$$\min_{p \in \mathbb{R}_n[x]} \sum_i (p(x_i) - y_i)^2$$

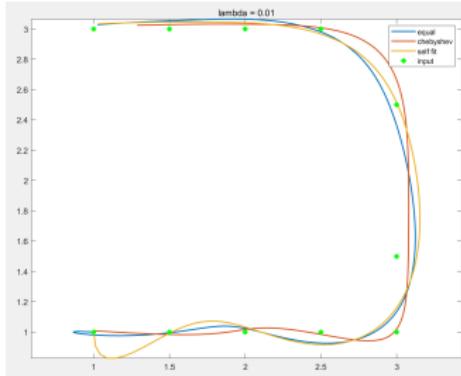
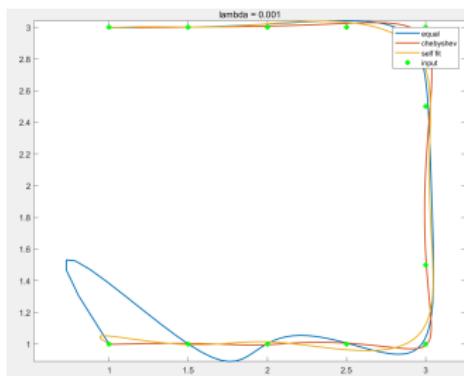
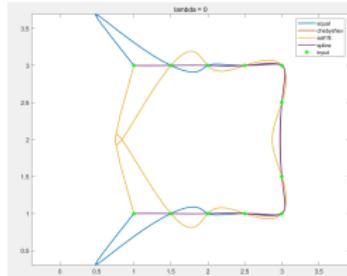
为控制 p 的“陡峭程度”，改进为

$$\min_{p \in \mathbb{R}_n[x]} \sum_i (p(x_i) - y_i)^2 + \lambda \int_a^b (p'')^2(x) dx$$

加入的部分即为**正则化项**。

光滑性效果

由两组多项式插值拟合平面参数曲线：



目录

正则化的动机

泛化误差与过拟合
正则化项的引入

统计学习与正则化

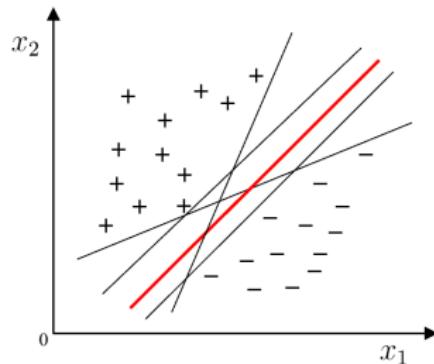
优化视角下的正则化
岭回归与 Lasso 回归
一个例子：极致梯度提升树

深度学习中的正则化

神经网络的正则化
隐式正则化技巧

SVM

支持向量机 (Support Vector Machine): 假设两类样本线性可分，寻找最优分割两类样本的超平面。



假设超平面 $w^T x + b = 0$, 可得到此例子的优化模型 (标签 $y_i = \pm 1$):

$$\min_{w,b} \frac{1}{2} \|w\|^2$$

$$s.t. y_i(w^T x_i + b) \geq 1$$

软间隔 SVM

- ▶ SVM 是稀疏的
- ▶ 只有离分割超平面最近的点才影响值
- ▶ 对噪声非常敏感

改进方式：软间隔 SVM

$$\min_{w,b} \frac{1}{2} \|w\|^2 + \frac{\sigma}{2} \sum_i \|c_i(x)\|^2$$

$$c_i(w, b) = \max\{1 - y_i(w^T x_i + b), 0\}$$

罚函数

定义：对问题 $\min_{x \in S} f(x)$, 满足 $\begin{cases} P(x) = f(x) & x \in S \\ P(x) > f(x) & x \notin S \end{cases}$ 的函数 P 称为**罚函数**。

硬约束化为软约束得到 $c(x)$, 则 $f(x) + \frac{\sigma}{2} \|c(x)\|^2$ 是一种罚函数, 且可证明: f 可微时, 只要 σ 充分大, 最优解即能任意接近真实最优解。

- ▶ 对抗噪声
- ▶ 便于求解

岭回归

$$\hat{y} = \beta^T x$$

$$\beta = \arg \min_{\beta} \|y - X\beta\|^2$$

↓

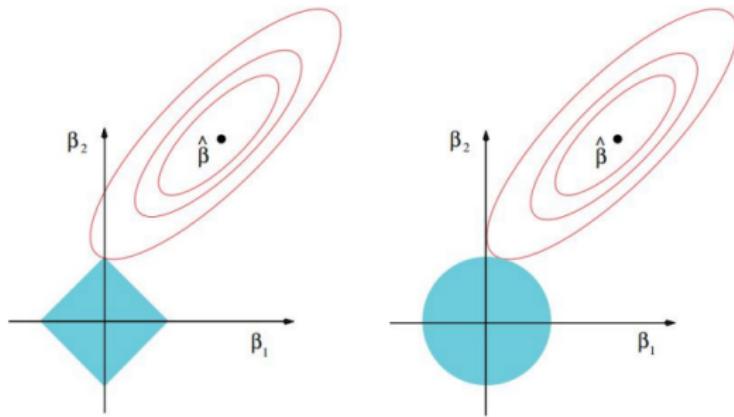
$$\beta = \arg \min_{\beta} \|y - X\beta\|^2 + \lambda \|\beta\|^2$$

- ▶ 更广义的回归: $f^{-1}(y) = \beta^T x$
- ▶ 硬间隔版本: $\|\beta\|^2 \leq t$
- ▶ 权重衰减作用

Lasso 回归

$$\beta = \arg \min_{\beta} \|y - X\beta\|^2 + \lambda \|\beta\|_1$$

- ▶ 岭回归精确解 $\beta = (X^T X + \lambda I)^{-1} X^T y$
- ▶ Lasso 回归难以直接写出精确解，且解关于 y 非线性
- ▶ 优点： λ 充分大时会将一些系数精确设定为 0，得到稀疏解



XGBoost

利用多个基模型组合成加法模型，假设共 M 个，则前 t 个输出为

$$y_i^{(t)} = \sum_{k=1}^t f_k(x_i) = y_i^{(t-1)} + f_t(x_i)$$

于是在前 $t - 1$ 个固定时优化第 t 个应优化 (loss 表示误差函数，这里取均方误差 $\|\cdot\|^2$ ， p 表示惩罚项)

$$\sum_i \text{loss}(y_i, y_i^{(t-1)} + f_t(x_i)) + p(f_t)$$

将 loss 泰勒展开，保留 $y_i^{(t-1)}$ 处一阶导数 g_i 、二阶导数 h_i 得到优化目标近似为

$$\sum_i g_i f_t(x_i) + \sum_i \frac{1}{2} h_i^2 f_t(x_i) + p(f_t)$$

回归树

回归树模型：每步进行树状划分直到到底层结点，本质是给出一个映射 q ，将每个输入 x_i 映射到叶子 $q(x_i)$ ，并预测以这个叶子的权重 $w_{q(x_i)}$ 。

正则化项：叶子数 T 引起的正则化项 γT 与权重引起的正则化项 $\frac{1}{2}\lambda\|w\|^2$ 求和。

若树的映射已经确定，记 $G_j = \sum_{p(x_i)=j} g_i$, $H_j = \sum_{p(x_i=j)} h_i$ ，可得优化目标变为

$$\sum_{j=1}^T \left(G_j w_j + \frac{1}{2}(H_j + \lambda) w_j \right) + \gamma T \Rightarrow w_j = -\frac{G_j}{H_j + \lambda}$$

结点划分

假设旧叶子结点对应 g, h 之和为 G, H , 划分为左右后分别对应的和为 G_L, H_L, G_R, H_R , 则优化目标的改进为

$$\frac{G_L^2}{2(H_L + \lambda)} + \frac{G_R^2}{2(H_R + \lambda)} - \frac{G^2}{2(H + \lambda)} - \gamma$$

由此，重复寻找最优划分直到无法改进目标函数，并预先给定基学习器的数目，就可以完成整个回归树为基的 XGBoost 构造。

反之，若不进行正则化，目标为 $\frac{G_L^2}{2H_L} + \frac{G_R^2}{2H_R} - \frac{G^2}{2H}$ ，划分为单个才能终止，会产生严重的过拟合。

目录

正则化的动机

泛化误差与过拟合
正则化项的引入

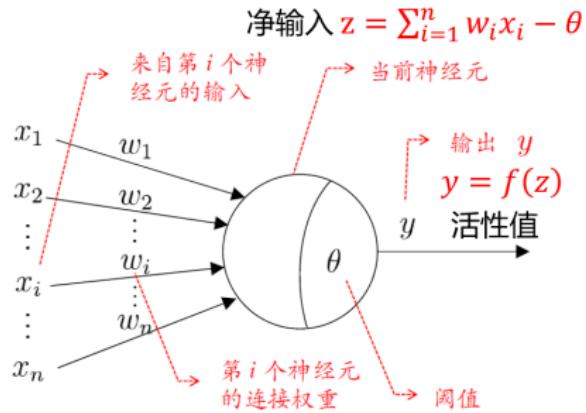
统计学习与正则化

优化视角下的正则化
岭回归与 Lasso 回归
一个例子：极致梯度提升树

深度学习中的正则化

神经网络的正则化
隐式正则化技巧

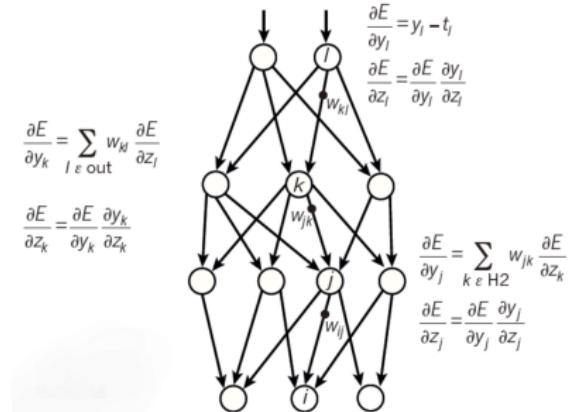
神经网络



- ▶ 多层线性回归中加以非线性处理
- ▶ 输入通过处理得到输出，可以多层叠加，进行不同连接
- ▶ 常用激活函数：ReLU($\max\{0, z\}$)、 \tanh 等

误差逆传播

通过梯度下降的方式更新每个权重与阈值的值：



- ▶ 先前向计算出结果，再估计误差反向传播
- ▶ 当学习率设置得足够低时，一定能够逐渐逼近结果
- ▶ 足够大的网络可任意逼近任何连续函数（万能逼近定理）

对抗学习

由于深度学习过程中的参数远多于实际函数空间的维数，过拟合非常容易发生，几乎必然会学习到无效的特征，由此导致容易构造看起来相同但深度学习确定的标签相反的例子：

$$x \quad + .007 \times \text{sign}(\nabla_x J(\theta, x, y)) = x + \epsilon \text{sign}(\nabla_x J(\theta, x, y))$$

$y = \text{熊猫}$	线虫	长臂猿
w/ 57.7%	w/ 8.2%	w/ 99.3 %
confidence	confidence	confidence

自然，我们可以给权重添加显式的一范数或二范数正则化，不过，现实中也常采用隐式的正则化技巧。

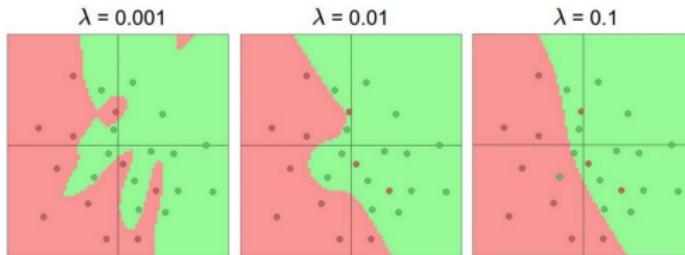
扰动数据集

给原本数据集添加一定噪声 $\epsilon \sim \mathcal{N}(0, \eta I)$, 记扰动后为 y_ϵ , 若不扰动, 模型为 \hat{y} , 扰动后训练的模型为 \hat{y}_ϵ , 并用泰勒展开近似
 $\hat{y}_\epsilon = \hat{y} + \nabla_w y^T \epsilon$ 。

直接代入后利用正态分布的性质展开得到均方误差

$$E[(\hat{y}_\epsilon - y)^2] = E[(\hat{y} - y)^2] + \eta E[\|\nabla_w y\|^2]$$

第二项即为正则化项。



早停策略

每次训练完计算验证集损失，上升时停止训练。

假设损失函数在最优点附近可以二次近似

$$J(w) = J(w^*) + \frac{1}{2}(w - w^*)^T H(w - w^*)$$

H 代表最优点 Hesse 阵，则梯度为 $H(w - w^*)$ 。若每次以学习率 t 进行梯度下降，若初始为 0，计算可知下降 τ 次后

$$w^{(\tau)} = (I - (I - tH)^\tau)w^*$$

对比直接进行 L2 正则化得到的 $w = (H - \alpha I)^{-1} H w^*$ ，可近似得到 $\tau \approx \frac{1}{t\alpha}$ ，也即给定学习率下早停次数与正则化系数反比。

Dropout

每次训练时，概率将一些神经元的输出设为 0。考虑基于指数分布的广义线性模型

$$P_{\beta}(y|x) = h(y) \exp(yx^T \beta - A(x^T \beta)), A(t) = \ln \int h(y) \exp(yt) dy$$

在此假设下可以分离出正则化项 $E_{\xi}[A((x_* \cdot \xi)^T \beta)] - A(x_i^T \beta)$ 其中 ξ 的每个分量独立以 σ 概率为 1, 否则为 0, $\cdot*$ 代表逐元素相乘。

- ▶ 防止特征的 co-adaptation
- ▶ 可以看成一种模型集成
- ▶ 在大网络效果良好的正则化技术

The End

Thank you for listening!

部分内容参考自：

- ▶ 连德富老师机器学习、深度学习讲义
- ▶ 崔文泉老师机器学习方法讲义