

2-4 梯度下降法及其衍生算法

王中雷

厦门大学王亚南经济研究院和经济学院, 2025

内容摘要

1. 梯度下降法

2. 衍生算法

3. 学习率衰减策略

回顾

步骤1. 批量梯度下降法

- 随机初始化 $\boldsymbol{\theta}^{(0)}$
- 基于当前模型参数 $\boldsymbol{\theta}^{(t)}$, 计算

$$\nabla \mathcal{J}(\boldsymbol{\theta}^{(t)}) = \frac{\partial \mathcal{J}}{\partial \boldsymbol{\theta}}(\boldsymbol{\theta}^{(t)}) = n^{-1} \sum_{i=1}^n \frac{\partial \mathcal{L}_i}{\partial \boldsymbol{\theta}}(\boldsymbol{\theta}^{(t)})$$

▷ $\mathcal{L}_i$: 针对于第 i 个训练样本的损失函数

- 参数更新

$$\boldsymbol{\theta}^{(t+1)} = \boldsymbol{\theta}^{(t)} - \alpha \nabla \mathcal{J}(\boldsymbol{\theta}^{(t)})$$

- 回到步骤 2 直至收敛

回顾

1. 缺点

- 计算效率低下，尤其当样本量 n 很大的时候

2. 为什么不能只用部分训练样本更新参数呢？

小批量梯度下降法

1. 想法：每一步参数更新中，只使用一小部分训练样本
2. 将训练样本指标集划分成若干互斥的集合： $\{1, \dots, n\} = S_1 \cup \dots \cup S_k$
 - $|S_1| = \dots = |S_{k-1}| = m$
 - $|S_k| \leq m$
 - $k = \lceil n/m \rceil$
 - m 通常是 2 的指数次幂。例如， $m = 512$

小批量梯度下降法

1. 对于第 t 步更新, 模型参数的更新规则为

$$\boldsymbol{\theta}^{(t+1)} = \boldsymbol{\theta}^{(t)} - \alpha \nabla \mathcal{J}_t(\boldsymbol{\theta}^{(t)})$$

$$\nabla \mathcal{J}_t(\boldsymbol{\theta}^{(t)}) = |S_{t \% k + 1}|^{-1} \sum_{i \in S_{t \% k + 1}} \frac{\partial \mathcal{L}_i}{\partial \boldsymbol{\theta}}(\boldsymbol{\theta}^{(t)})$$

- 只用 $S_{t \% k + 1}$ 中的样本点计算梯度

2. 当全部样本被遍历完, 我们称训练完成一个周期 (epoch)

讨论

1. 两种特殊情况

- $m = 1$: 随机梯度下降法
- $m = n$: 批量梯度下降法

2. 当 $m < n$ 时, 小批量梯度下降法损失了计算精度


3. 然而, 小批量梯度下降法却能够节省内存以及提高计算效率

4. 广泛用于深度学习模型的训练

5. 接下来, 我们讨论几种更加有效的计算梯度的算法

问题背景


1. 梯度展示的是代价函数值增加最快的方向
2. 当代价函数的梯度“不稳定”时，梯度下降法的效率将降低



问题背景

1. 我们希望用更加“稳定”的方向替代梯度
2. 为了达到这个目标，我们考虑下面几种算法
 - 动量法 (Momentum)
 - RMSprop
 - Adam

动量法 (Momentum)



1. 我们希望达到如下效果

- 减小上-下方向的效应
- 增大左-右方向的效应

动量法 (Momentum)

1. 对过往梯度取均值?

- 将耗费大量内存用于存储过去的梯度
- 对于（带有海量参数的）深度学习模型而言，这么做几乎不可能

2. 考虑EWMA (Exponential Weighted Moving Average)

- 原始序列: $\{s_i : i = 1, 2, \dots\}$
- EWMA 序列: $\{v_i : i = 1, 2, \dots\}$
$$v_i = \beta_1 v_{i-1} + (1 - \beta_1) s_i \quad (i = 1, 2, \dots)$$
 - ▷ $v_0 = 0$
 - ▷ β_1 控制我们多么重视“动量” v_{i-1} 的值

计算

1. 令 $\mathbf{g}^{(t)}$ 表示第 t 步更新中, 某参数的梯度值

- 可以是 $d\mathbf{b}$ 或者 $d\mathbf{W}$ 在当前模型参数 $\boldsymbol{\theta}^{(t)}$ 下的计算结果
- 简便起见, 我们忽略掉与迭代次数 t 相关的上角标

2. 通过以下方式得到 EWMA “梯度” $\mathbf{v}_b^{(t)}$

$$\mathbf{v}_b^{(t)} = \beta_1 \mathbf{v}_b^{(t-1)} + (1 - \beta_1) \mathbf{g}^{(t)}$$

- $\beta_1 = 0.9$: 模型超参 (通常不调参)
- $\mathbf{v}_b^{(0)} = 0$: 初始动量

计算

1. 一个事实

$$\frac{1}{(1 - \beta_1)^{-1}} \sum_{i=1}^{\infty} \beta_1^i = 1$$

2. 更多细节

$$\begin{aligned} \mathbf{v}^{(t)} &= \beta_1 \mathbf{v}^{(t-1)} + (1 - \beta_1) \mathbf{g}^{(t)} \\ &= (1 - \beta_1) \beta_1^{t-1} \mathbf{g}^{(1)} + (1 - \beta_1) \beta_1^{t-2} \mathbf{g}^{(2)} + \cdots + (1 - \beta_1) \mathbf{g}^{(t)} \\ &= \frac{1}{(1 - \beta_1)^{-1}} \sum_{i=1}^t \beta_1^{t-i} \mathbf{g}^{(i)} \end{aligned}$$

- 当 t 较大时，以上结果可被视为求加权平均
- $(1 - \beta_1)^{-1}$ ：可被视作 EMWA 的“有效样本量”

基于动量的梯度下降法

步骤1. 随机初始化 $\theta^{(0)}$

步骤2. 基于当前模型参数 $\theta^{(t)}$, 计算 $d\mathbf{b}^{[1](t)}$

- 作为例子, 我们仅展示模型参数 $\mathbf{b}^{[1]}$ 的更新过程
- 相同的过程可用于更新其他模型参数


步骤3. 更新模型参数

$$\mathbf{b}^{[1](t+1)} = \mathbf{b}^{[1](t)} - \alpha \mathbf{v}_b^{[1](t+1)}$$

- $\mathbf{v}_b^{[1](t+1)} = \beta_1 \mathbf{v}_b^{[1](t)} + (1 - \beta_1) d\mathbf{b}^{[1](t)}$
- $\mathbf{v}_b^{[1](0)} = 0$
- $\beta_1 = 0.9$ (默认值, 通常不调参)

步骤4. 回到步骤 2 直至收敛

比较



比较

1. 动量的确降低了上-下方向的效应
2. 然而，算法收敛速度较慢
3. 一种可能的解决方法：不同方向用不同的学习率
 - 较小的学习率用于上-下方向
 - 较大的学习率用于左-右方向

基于RMSprop的梯度下降法

步骤1. 随机初始化 $\theta^{(0)}$

步骤2. 基于当前模型参数 $\theta^{(t)}$, 计算 $d\mathbf{b}^{[1](t)}$

- 作为例子, 我们考虑模型参数 $\mathbf{b}^{[1]}$ 的更新过程


步骤3. 更新参数

$$\mathbf{b}^{[1](t+1)} = \mathbf{b}^{[1](t)} - \frac{\alpha}{\sqrt{\epsilon + \mathbf{s}_b^{[1](t+1)}}} d\mathbf{b}^{[1](t)}$$

- $\epsilon = 10^{-8}$ (默认值, 通常不调参)
- $\mathbf{s}_b^{[1](t+1)} = \beta_2 \mathbf{s}_b^{[1](t)} + (1 - \beta_2) d\mathbf{b}^{[1](t)} \circ d\mathbf{b}^{[1](t)}$
- $\mathbf{s}_b^{[1](0)} = 0$
- $\beta_2 = 0.99$ (默认值, 通常不调参)

步骤4. 回到步骤 2 直至收敛

比较



比较

1. RMSprop 对应的参数更新轨迹更加“平滑”
2. 然而，收敛速度仍然不太理想

算法总结

1. 传统的梯度下降法

$$\mathbf{b}^{[1](t+1)} = \mathbf{b}^{[1](t)} - \alpha d\mathbf{b}^{[1](t)}$$

2. 动量法只更改梯度部分

$$\mathbf{b}^{[1](t+1)} = \mathbf{b}^{[1](t)} - \alpha \mathbf{v}_b^{[1](t+1)}$$

3. RMSprop 只更改学习率部分

$$\mathbf{b}^{[1](t+1)} = \mathbf{b}^{[1](t)} - \frac{\alpha}{\sqrt{\epsilon + \mathbf{s}_b^{[1](t+1)}}} d\mathbf{b}^{[1](t)}$$

4. 为什么不同结合两种方法，同时更改两部分？

Adam (Adaptive moment estimation)

步骤1. 随机初始化 $\theta^{(0)}$

步骤2. 基于当前模型参数 $\theta^{(t)}$, 计算 $db^{[1](t)}$

- 作为例子, 我们考虑模型参数 $b^{[1]}$ 的更新过程

步骤3. 更新参数

$$b^{[1](t+1)} = b^{[1](t)} - \frac{\alpha}{\epsilon + \sqrt{\hat{s}_b^{[1](t+1)}}} \hat{v}_b^{[1](t+1)}$$

- 关于 $\hat{s}_b^{[1](t+1)}$ 以及 $\hat{v}_b^{[1](t+1)}$ 的解释请参见下一页
- $\epsilon = 10^{-8}$ (默认值, 通常不调参)

步骤4. 回到步骤 2 直至收敛

Adam (Adaptive moment estimation)


1. 关于 $\hat{\mathbf{s}}_b^{[1](t+1)}$ 和 $\hat{\mathbf{v}}_b^{[1](t+1)}$ 的计算细节

$$\mathbf{s}_b^{[1](t+1)} = \beta_2 \mathbf{s}_b^{[1](t)} + (1 - \beta_2) \mathbf{d}\mathbf{b}^{[1](t)} \circ \mathbf{d}\mathbf{b}^{[1](t)} \quad \hat{\mathbf{s}}_b^{[1](t+1)} = \frac{\mathbf{s}_b^{[1](t+1)}}{1 - \beta_2^{t+1}}$$

$$\mathbf{v}_b^{[1](t+1)} = \beta_1 \mathbf{v}_b^{[1](t)} + (1 - \beta_1) \mathbf{d}\mathbf{b}^{[1](t)} \quad \hat{\mathbf{v}}_b^{[1](t+1)} = \frac{\mathbf{v}_b^{[1](t+1)}}{1 - \beta_1^{t+1}}$$

- $\mathbf{v}_b^{[1](0)} = \mathbf{s}_b^{[1](0)} = 0$
- $\beta_1 = 0.9$ (默认值, 通常不调参)
- $\beta_2 = 0.99$ (默认值, 通常不调参)

算法对比



算法对比

1. Adam 表现最好
2. Adam 或者其变体通常用于深度模型参数估计

学习率衰减策略

1. 直观

- 随着迭代的增加，估计值“应当”接近理论真值
- 我们不应当在每步更新中使用不变的学习率
 - ▷ [效率低] 较小的学习率通常具有较好的收敛性质，但我们通常需要多步迭代
 - ▷ [不稳定] 当迭代次数较大时，较大的学习率往往导致参数更新不太稳定
- 随着迭代次数的增加，我们应当以较为有效的方式降低学习率

学习率衰减策略

1. 记

- t : 迭代指标
- $epoch$: 周期指标

2. 有多种学习率衰减策略

$$\alpha_t = \frac{\alpha_0}{1 + \gamma \cdot epoch}$$

$$\alpha_t = \frac{\alpha_0}{\sqrt{epoch}}$$

$$\alpha_t = 0.95^{epoch} \cdot \alpha_0$$

$$\alpha_t = \frac{1}{\sqrt{t}} \cdot \alpha_0$$

$$\alpha_t = 0.95^t \cdot \alpha_0$$

- 例如, $\alpha_0 = 5 \times 10^{-3}$

王中雷 (厦门大学王亚南经济研究院和经济学院)

- $\gamma = 1$ (默认值, 通常不调参)