机器学习框架及问题解决

机器学习框架

1. **function with unknown parameters**

$$y = f_\theta(x)$$

2. **define loss from training data**

$$L(\theta)$$

3. **optimization**

$$\theta^* = arg\ \min_\theta L$$

如何解决模型遇到的问题

- **Training loss Large**
  - **model bias**
  - **optimization**
    - 用简单的模型了解 loss 是什么水平
    - 增加模型复杂度
- **Training loss small**
  - **testing loss large**
    - **overfitting**
      - 增加训练数据量
      - data augmentation 翻转图片等
      - 简化模型 - 减轻弹性
    - **mismatch**
      - 优化数据结构，了解数据组成逻辑

模型复杂度如何权衡?

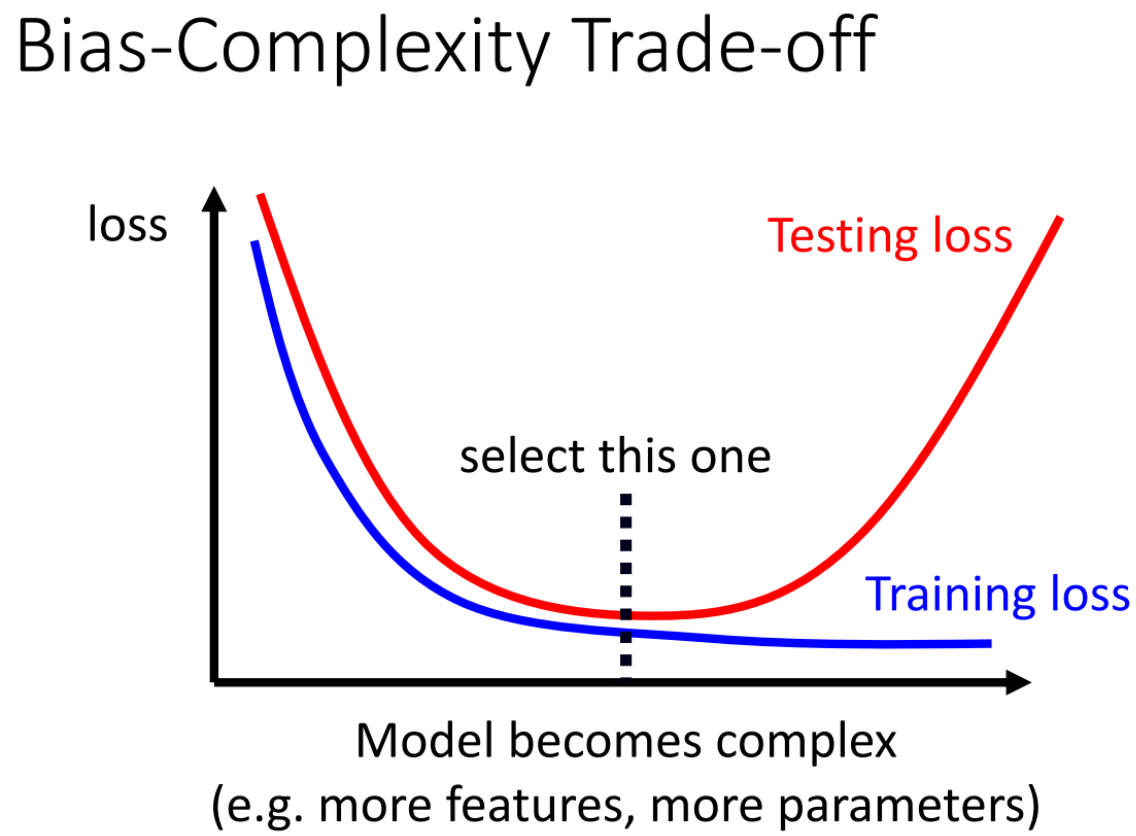

Split your training data into training set and validation set for model selection

克服 critical point 继续下降！-- 优化 optimization

> 局部最小值（local minima）与鞍点（saddle point）
> 梯度（gradient）为 0 的点，称为 critical point

很多 critical point 都是 saddle point，我们可以去克服它，继续下降！

方法一：Batch

将一堆数据分成好几个 batch，经过一个 batch 就算一次 gradient，更新一次参数。

> 1 epoch = see all the batches once
> shuffle：一个 epoch 后打乱数据顺序，再进行新一轮 train

Small Batch v.s. Large Batch:

- Small Batch 在 training 上表现更好：更容易克服 saddle point，更容易到达“较平坦”的 local minima，从而 testing 结果也更好
- Small Batch 经过一个 epoch 更慢

方法二：Momentum

沿梯度下降时，考虑之前走过的路径（获得“冲力”）

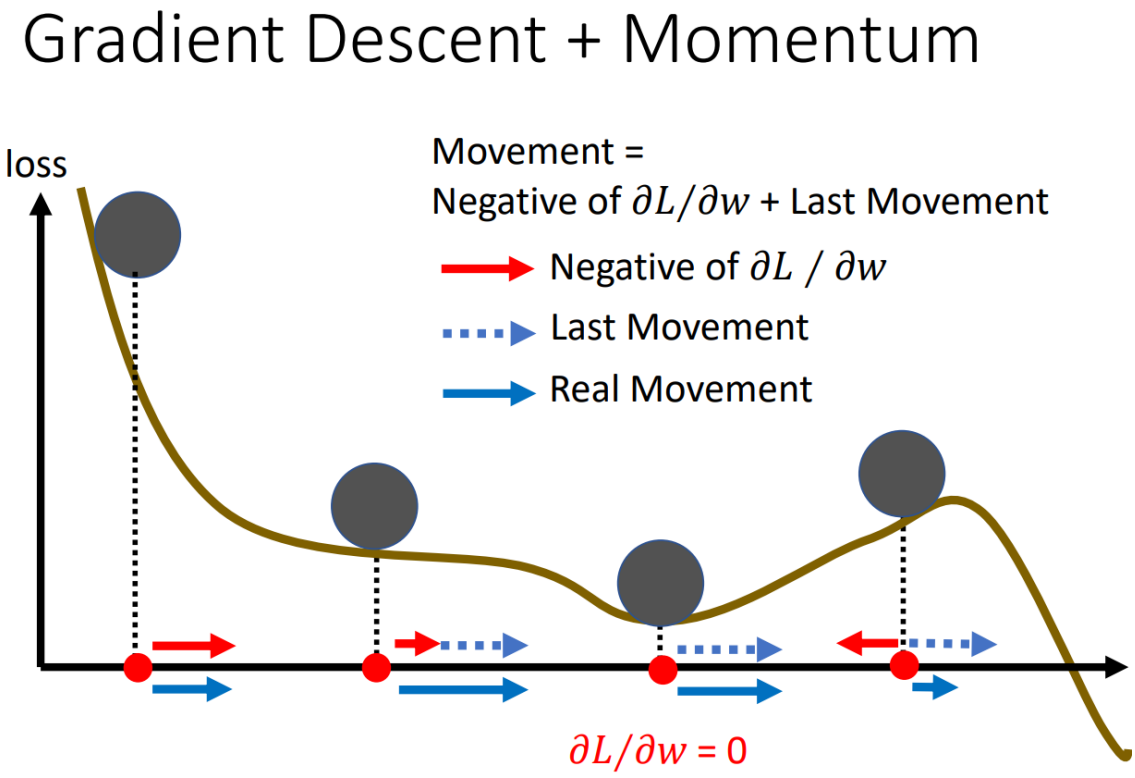

自动调整学习速率（Learning Rate）

为了更好的达到 critical point，在陡峭的地方走慢点，在平缓的地方走快点。为每个参数客制化学习速率。

Training stuck ≠ Small Gradient

Adam: RMSProp + Momentum

RMSProp: 对每个参数，针对不同的阶段，使用不同的学习速率参数。且可以指定对于现数据和之前数据的权重比。

从:

$$\theta_i^{t+1} \leftarrow \theta_i^t - \eta g_i^t$$

到:

$$\theta_i^{t+1} \leftarrow \theta_i^t - \frac{\eta}{\sigma_i^t} g_i^t$$

$$\sigma_i^t = \sqrt{\alpha(\sigma_i^{t-1})^2 + (1-\alpha)(g_i^t)^2}$$

α 是 hyper parameter

Adam:

$$\theta_i^{t+1} \leftarrow \theta_i^t - \frac{\eta}{\sigma_i^t} m_i^t$$

m_i^t: Momentum: weighted sum of the previous gradients.

Learning Rate Scheduling

Learning Rate 随着时间（训练时间）自己改变。有以下两种主流方法：

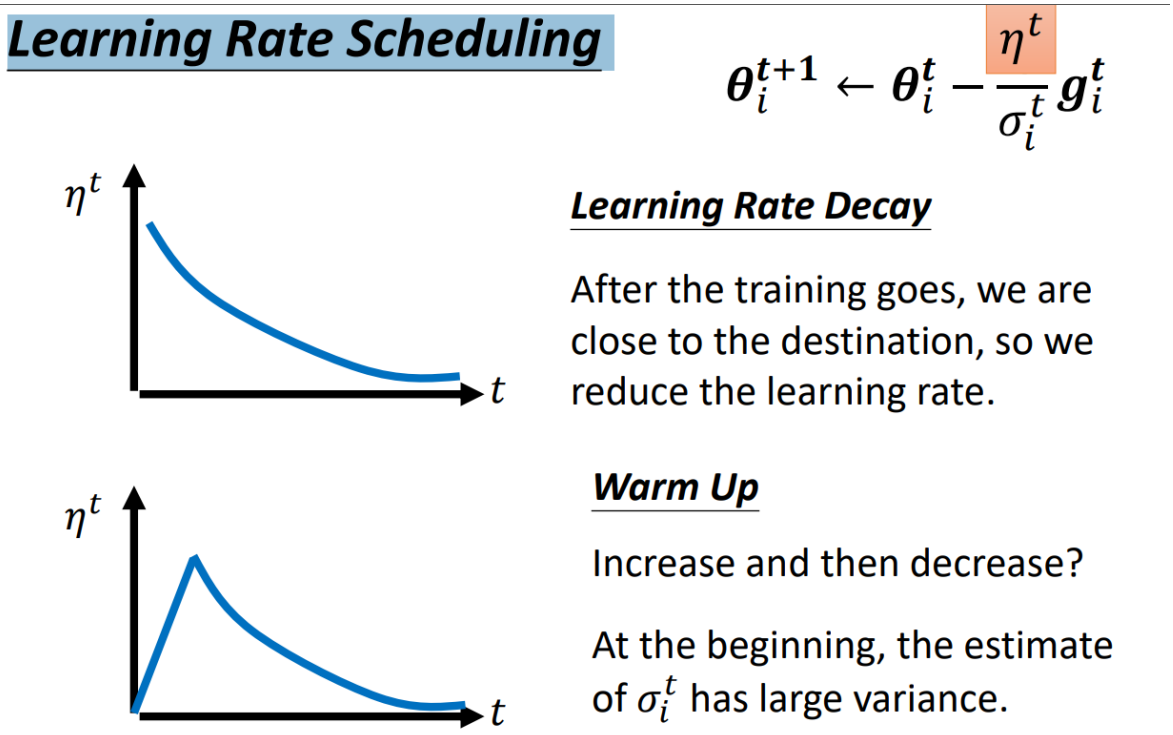

用分类模型引出 - Loss Function 也对训练有影响

分类模型:

- 用 one-hot vector 表示不同类别

```
y_1 = [1, 0, 0]
y_1 = [0, 1, 0]
y_1 = [0, 0, 1]
```

- 用 soft-max 将 数值向量归一化为一个概率分布向量，且各个概率之和为1
- Loss Function 用 cross-entropy（交叉熵）而不用 MSE

$$e = -\sum_i \hat{y}_i \ln y_i'$$

Minimizing cross-entropy == maximizing likelihood

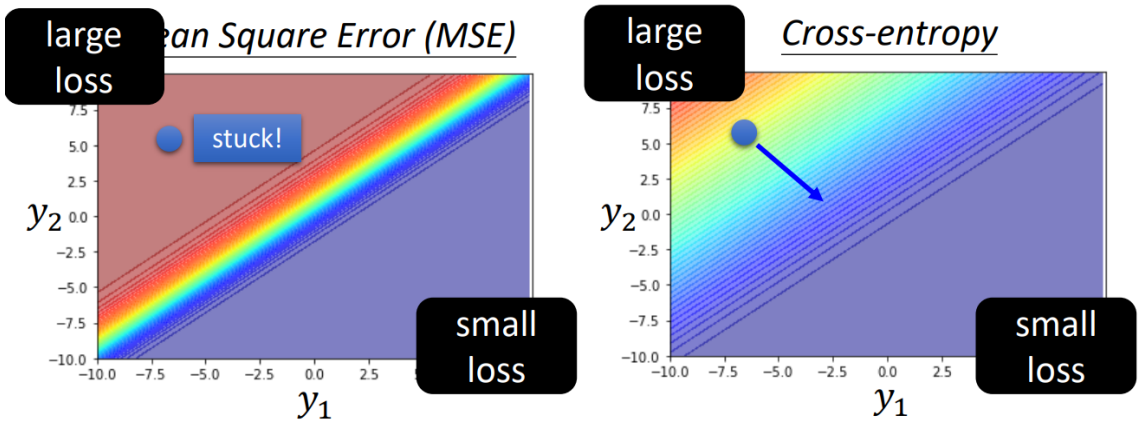

由上可得：改变 Loss Function 也会对 optimization 造成影响。

Normalization

因为 feature 的差异太大，可能造成 loss function 函数的 error surface 太过于崎岖，不利于 optimization
我们希望 feature 的范围相对差异较小：

Feature Normalization

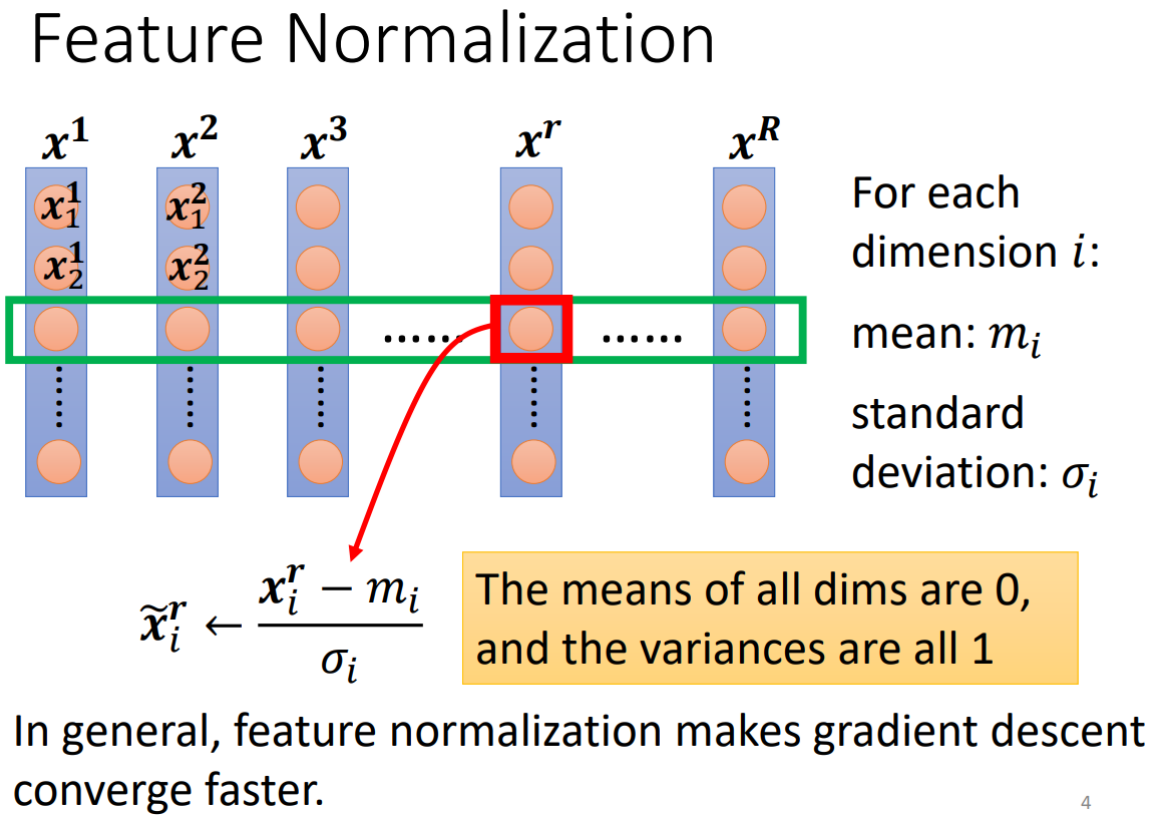

Batch normalization

在 deep learning 中，尽管最开始输入的 feature 们都经过了 normalization，但是他们经过 activation function 后数值又进行改变，对于新的一层来说，他们是全新的 feature，所以我们需要再进行 normalization

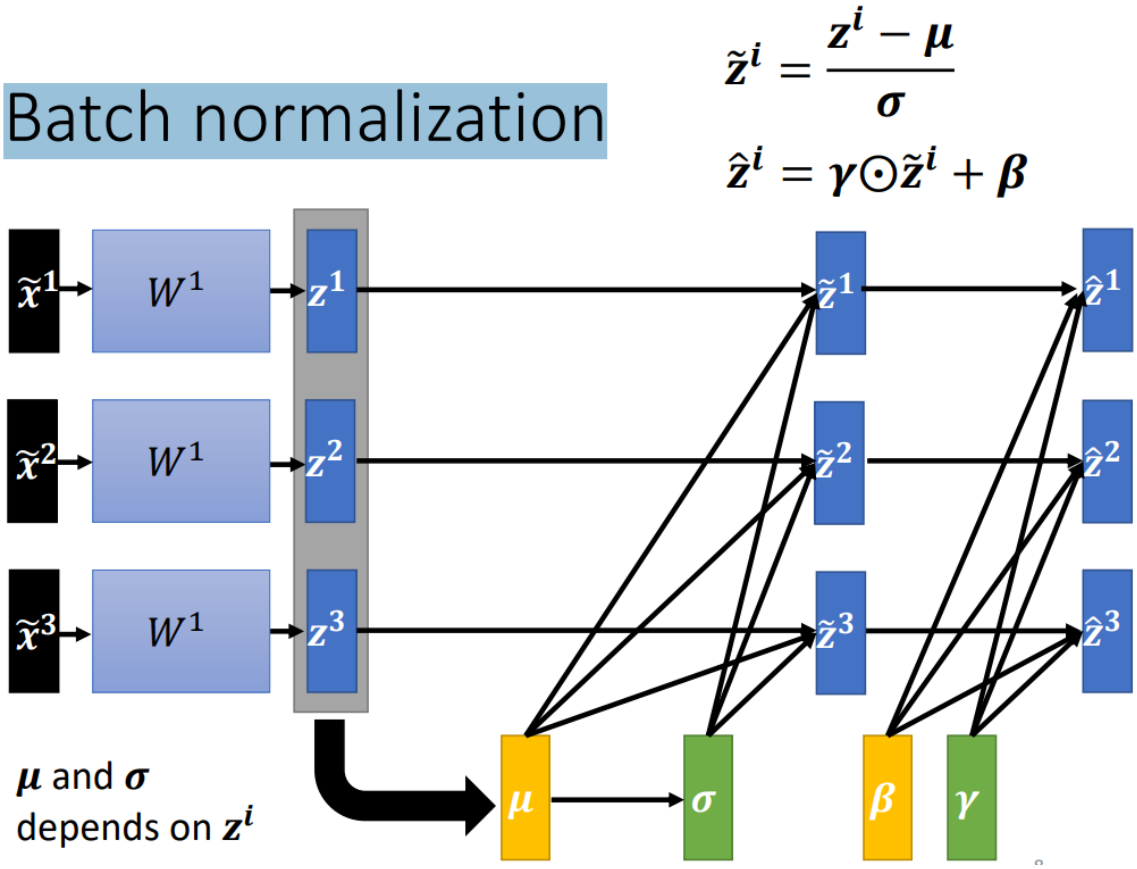

为了实现 batch normalization，我们需要让 feature 们并行进行（一个 batch 一起运算）

Testing 时怎么办?

We do not always have batch at testing stage.

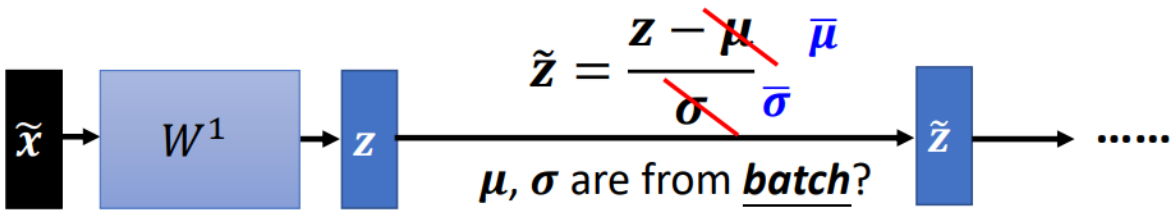

We do not always have ***batch*** at testing stage.

Computing the moving average of μ and σ of the batches during training.

$$\mu^1 \quad \mu^2 \quad \mu^3 \quad \cdots\cdots \quad \mu^t$$

$$\bar{\mu} \leftarrow p\bar{\mu} + (1-p)\mu^t$$

除了 batch normalization，还有各式各样的 normalization... ...