

# 神经网络基础

黄政宇

北京大学北京国际数学研究中心  
北京大学国际机器学习研究中心



# 本堂课大纲

- 全连接神经网络
  - 激活函数
  - 万能逼近定理
- 神经网络中的模块
- 神经网络的训练
  - 初始化
  - 反向传播
  - 凸优化



# 利用非线性模型的监督学习

## ➤ 监督学习

训练数据： $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$

线性模型： $f(x) = x^T w$   
 $f(x) = \Psi(x)^T w$

非线性模型： $f(x; \theta)$

优化均方误差函数：

$$J(\theta) = \frac{1}{n} \sum_{j=1}^n J^{(i)}(\theta) \quad J^{(i)}(\theta) = \frac{1}{2} (f(x_i; \theta) - y_i)^2$$



# 神经网络

## ➤ 全连接神经网络

$$y = f(x; \theta): R^{n_0} \rightarrow R^{n_L}$$

$$f(x; \theta) = f_L \circ f_{L-1} \circ \dots \circ f_1(x)$$

$$f_i(z) = h^{(i)}(W^{(i)}z + b^{(i)}): R^{n_{i-1}} \rightarrow R^{n_i}$$

矩阵： $W^{(i)} \in R^{n_i \times n_{i-1}}$

向量： $b^{(i)} \in R^{n_i}$

对每个元素作用的(非线性)激活函数： $h^{(i)}$



# 激活函数

## ➤ 激活函数

对每个元素作用的(非线性) 激活函数： $h$

$$h(z) = [\sigma(z_1), \sigma(z_2), \dots \dots \sigma(z_n)]^T$$

$$\text{RELU: } \sigma(z) = \max\{0, z\}$$

$$\text{Sigmoid: } \sigma(z) = \frac{1}{1+e^{-z}}$$

$$\text{Tanh: } \sigma(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$$

$$\text{Leaky RELU: } \sigma(z) = \max\{z, \gamma z\} (\gamma \in (0, 1))$$

$$\text{GELU: } \sigma(z) = \frac{z}{2} [1 + \text{erf}(\frac{z}{\sqrt{2}})]$$

$$\text{SoftPlus: } \sigma(z) = \frac{1}{\beta} \log(1 + e^{\beta z}), \beta > 0$$




# 激活函数

## ➤ 激活函数

对每个元素作用的(非线性) 激活函数： $h$

$$h(z) = [\sigma(z_1), \sigma(z_2), \dots \dots \sigma(z_n)]^T$$








# 激活函数

## ➤ 激活函数饱和(saturating)

- 饱和(saturating)
- 导数消失





# 激活函数

## ➤ 激活函数

对每个元素作用的(非线性) 激活函数： $h$

$$h(z) = [\sigma(z_1), \sigma(z_2), \dots \dots \sigma(z_n)]^T$$

$$\text{RELU: } \sigma(z) = \max\{0, z\}$$

$$\text{Sigmoid: } \sigma(z) = \frac{1}{1+e^{-z}}$$

$$\text{Tanh: } \sigma(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$$

$$\text{Leaky RELU: } \sigma(z) = \max\{z, \gamma z\} (\gamma \in (0, 1))$$

$$\text{GELU: } \sigma(z) = \frac{z}{2} [1 + \text{erf}(\frac{z}{\sqrt{2}})]$$

$$\text{SoftPlus: } \sigma(z) = \frac{1}{\beta} \log(1 + e^{\beta z}), \beta > 0$$



# 神经网络

## ➤ 全连接神经网络(multi-layer perceptron)

在最后一层 $f_L$ ，激活函数的选择由函数最终输出的约束条件所决定

-多类分类问题：
$$h^{(L)}(x) = \frac{e^{x_j}}{\sum_{j=1}^{R^{n_L}} e^{x_j}}$$

-正输出问题：
$$h^{(L)}(x) = e^x$$

-回归问题：没有激活函数
$$h^{(L)}(x) = x$$

## ➤ 回顾：回归问题

$$f(x; \theta) = W^{(L)} \phi_{\theta'}(x) + b^{(L)}$$

$\phi_{\theta'}(x)$ : 特征

同时学习权重和特征



# 万能逼近定理

## 通用逼近器

$\mathcal{X}$  是一个紧致集。函数族  $F$  被称为是通用逼近器，如果  $F$  在有均匀度量的函数空间  $C(\mathcal{X})$  中稠密。这等价于说对于任意的  $f \in C(\mathcal{X})$  和任意的  $\epsilon > 0$ ，存在  $\hat{f} \in F$  使得

$$\sup_x |f(x) - \hat{f}(x)| < \epsilon$$

## Weierstrass逼近定理

假设  $f(x)$  是定义在实数区间  $\mathcal{X} = [a, b]$  上的实值连续函数。对于任意的  $\epsilon > 0$ ，存在一个多项式  $p(x)$ ，使得对于所有  $[a, b]$  区间内的  $x$ ，都有  $|f(x) - p(x)| < \epsilon$ 。



# 万能逼近定理

## 万能逼近定理 ( Cybenko 1989, Hoira 1990 )

设  $\sigma: R \rightarrow R$  是一个非常数、有界且连续的函数。令  $I_d$  表示  $d$ -维单位超立方体  $[0,1]^d$ 。实数值连续函数在  $I_d$  上的空间记为  $C(I_d)$ 。那么，给定任何  $\epsilon > 0$  和任何连续函数  $f \in C(I_d)$ 。存在宽度为  $D$  的两层神经网络，

$$F(x) = W^{(2)} \sigma(W^{(1)}x + b^{(1)}) + b^{(2)}$$

作为函数  $f$  的近似满足

$$\forall x \in I_d, |F(x) - f(x)| < \epsilon。$$



# 万能逼近定理

## ➤ 维数灾难 ( Curse of dimensionality )

对于 $L$ -Lipschitz连续函数，两层的神经网络

$$F(x) = W^{(2)} \sigma(W^{(1)} x + b^{(1)}) + b^{(2)}$$

对 $f \in C(I_d)$ 近似，达到 $\epsilon$ 的 $L_\infty$ 误差估计，宽度需要为

$$D \sim \left(\frac{L}{\epsilon}\right)^d$$

对于线性函数，线性回归能很好近似

对于 $C^\infty$ 光滑的函数，核岭回归能达到指数收敛

对于什么函数类，神经网络近似能克服维数灾难？



# 万能逼近定理

## 逼近定理 ( Jones , 1992, Barron 1993 )

考虑cos激活函数。给定全空间的实值函数  $f$ ，它的Fourier变换

$$\hat{f}(w) = \frac{1}{(2\pi)^d} \int_{R^d} f(x) e^{-iw^T x} dx$$

满足

$$C_f = \int_{R^d} |f(w)| dw < \infty$$

给定任意概率密度函数  $\rho$ ，那么存在宽度为  $D$  的两层神经网络  $F(x)$ ，作为函数  $f$  的近似满足

$$\|F(x) - f(x)\|_{L_2(\rho)}^2 \leq \frac{C_f^2}{D}$$



# 万能逼近定理

## 万能逼近定理 ( Jones , 1992, Barron 1993 )

考虑sigmoid激活函数。给定紧集 $\Omega$ 上的函数 $f$ ，考虑它的全空间 $L_1$ 延拓 $f_e$ ，以及相应的Fourier变换

$$\hat{f}_e(w) = \frac{1}{(2\pi)^d} \int_{\mathbb{R}^d} f_e(x) e^{-iw^T x} dx$$

满足

$$C_f = \inf_{f_e} \int_{\mathbb{R}^d} (1 + \|w\|) |f_e(w)| dw < \infty$$

其中 $\|w\| = \sup_{x \in \Omega} |w^T x|$ 。给定任意概率密度函数 $\rho$ ，那么存在宽度为 $D$ 的两层神经网络 $F(x)$ ，作为函数 $f$ 的近似满足

$$\|F(x) - f(x)\|_{L_2(\rho)}^2 \leq \frac{C_f^2}{D}$$



# 本堂课大纲

- 全连接神经网络
  - 激活函数
  - 万能逼近定理
- 神经网络中的模块
- 神经网络的训练
  - 初始化
  - 反向传播
  - 凸优化



# 神经网络中的模块



- 矩阵乘法模块：

$$MM(z) = Wz + b$$

- 残差连接模块：

$$Res(z) = z + \sigma(MM(\sigma(MM(z))))$$

ODE解释





# 神经网络中的模块

➤ 归一化(Layer normalization)层：

$$LN-S(z) = \begin{bmatrix} \frac{z_1 - \hat{\mu}}{\hat{\sigma}} \\ \frac{z_2 - \hat{\mu}}{\hat{\sigma}} \\ \vdots \\ \frac{z_m - \hat{\mu}}{\hat{\sigma}} \end{bmatrix} \quad \hat{\mu} = \frac{\sum_{i=1}^m z_i}{m} \quad \hat{\sigma} = \sqrt{\frac{\sum_{i=1}^m (z_i - \hat{\mu})^2}{m}}$$

$$LN(z) = \beta + \gamma LN-S(z)$$

- 尺度不变性(scaling-invariant):


$$LN(MM_{\alpha W, \alpha b}(z)) = LN(MM_{W, b}(z))$$

- 前归一化层、后归一化层 (在激活函数之后)



# 神经网络中的模块



## 卷积模块





# 神经网络中的模块

## ➤ 卷积模块





# 神经网络中的模块

## ➤ 注意力机制(Attention)

编码器状态 ( encoder states )  $x_1, x_2, \dots, x_n \in R^c$

解码器状态 ( decoder states )  $h \in R^o$

投影 :

$$f = \langle x_1, h \rangle x_1 + \langle x_2, h \rangle x_2 + \dots + \langle x_n, h \rangle x_n$$

计算编码器状态 和解码状态的相关性:

$$\text{score}(h, x_i)$$

注意力权重 :

$$a_i = \frac{\exp(\text{score}(h, x_i))}{\sum_{i=1}^n \exp(\text{score}(h, x_i))}$$

输出 :  $f = a_1 x_1 + a_2 x_2 + \dots + a_n x_n$



# 神经网络中的模块

## ➤ 自注意力机制(Attention)

编码器状态 ( encoder states )  $x_1, x_2, \dots, x_n \in R^c$

查询 (query):  $q_i = W^q x_i$  ( $W^q \in R^{m \times c}$ )

键 (key):  $k_i = W^k x_i$  ( $W^k \in R^{m \times c}$ )

值 (value):  $v_i = W^v x_i$  ( $W^v \in R^{m \times c}$ )

相关性(alignment\score):

$$e_{ij} = \frac{q_i \cdot k_j}{\sqrt{d}} \quad a_{ij} = \frac{\exp(e_{ij})}{\sum_{j'=1}^n \exp(e_{ij'})}$$

输出 :


$$\text{Attention}(q, k, v)_i = \sum_{j=1}^n a_{ij} v_j$$



# 神经网络中的模块


## ➤ 自注意力机制(Attention)

自然语言处理




## Vision Transformer (ViT)

图像处理



## Transformer Encoder





# 本堂课大纲

- 全连接神经网络
  - 激活函数
  - 万能逼近定理
- 神经网络中的模块
- 神经网络的训练
  - 初始化
  - 反向传播
  - 凸优化




# 初始化

## ➤ 例子

```
dims = [4096] * 7
hs = []
x = np.random.randn(16, dims[0])

for n_in, n_out in zip(dims[:-1], dims[1:]):
    W = 0.05 * np.random.randn(n_in, n_out)
    x = np.tanh(x.dot(W))
    hs.append(x)
```






# 初始化

## ➤ 例子

```
dims = [4096] * 7  
hs = []  
x = np.random.randn(16, dims[0])  
for n_in, n_out in zip(dims[:-1], dims[1:]):  
    W = 0.01 * np.random.randn(n_in, n_out)  
    x = np.tanh(x.dot(W))  
    hs.append(x)
```





# 初始化

## ➤ Xavier初始化

考虑  $y = Wz$ ，假设  $W_{i,j} \sim \mathcal{N}(0, w^2)$

$$\text{Cov}[y_i] = n_{in} w^2 \times \text{Cov}[z_i] \Rightarrow w = \frac{1}{\sqrt{n_{in}}}$$

如果激活函数为ReLU，考虑  $y = \sigma(Wz)$ ，假设  $W_{i,j} \sim \mathcal{N}(0, w^2)$


$$\text{Cov}[y_i] = \frac{1}{2} n_{in} w^2 \times \text{Cov}[z_i] \Rightarrow w = \frac{1}{\sqrt{\frac{n_{in}}{2}}}$$



# 初始化

## ➤ 例子

```
dims = [4096] * 7
hs = []
x = np.random.randn(16, dims[0])
for n_in, n_out in zip(dims[:-1], dims[1:]):
    W = np.random.randn(n_in, n_out) / np.sqrt(n_in)
    x = np.tanh(x.dot(W))
    hs.append(x)
```





# 反向传播

## ➤ 链式法则

$$r(x, y, z) = z^2(x^2 + y)^2$$


$$u = x^2$$

$$v = u + y$$

$$w = zu$$

$$r = w^2$$

$$(x, y, z) = (1, 2, 4)$$





# 反向传播

## ➤ 链式法则


$$r(x, y, z) = z^2(x^2 + y)^2$$

$$u = x^2 \quad \frac{\partial u}{\partial x} = 2x$$

$$v = u + y \quad \frac{\partial v}{\partial u} = 1 \quad \frac{\partial v}{\partial y} = 1$$

$$w = zu \quad \frac{\partial w}{\partial u} = z \quad \frac{\partial w}{\partial z} = u$$

$$r = w^2 \quad \frac{\partial r}{\partial w} = 2w$$





# 反向传播

## ➤ 链式法则

$$f(x; \theta) = f_L \circ f_{L-1} \circ \dots \circ f_1(x)$$

我们神经网络中的操作(加减乘除激活函数等)，以及它们的导数或偏导数，都可以在  $O(1)$  时间内计算出来。如果  $f(x; \theta)$  的复杂度为  $O(N)$ ，那么计算  $\nabla_{\theta} f(x; \theta)$  的复杂度也为  $O(N)$ 。



# 非凸优化

## ➤ 监督学习

极小化均方误差函数：

$$J(\theta) = \frac{1}{n} \sum_{j=1}^n J^{(i)}(\theta) \quad J^{(i)}(\theta) = \frac{1}{2} (f(x_i; \theta) - y_i)^2$$

## ➤ 最速度梯度下降法

$$\begin{aligned} \theta &:= \theta - \alpha \nabla_{\theta} J(\theta) \\ &:= \theta - \alpha \sum_{i=1}^n \nabla_{\theta} J^{(i)}(\theta) \end{aligned}$$



# 初始化

## ➤ 随机梯度下降法

均匀地（无放回）从 $\{1, 2, \dots, n\}$ 中选取 $B$ 个实例  
 $j_1, j_2, \dots, j_B$

$$\theta := \theta - \alpha \frac{n}{|B|} \sum_{k=1}^B \nabla_{\theta} J^{(j_k)}(\theta)$$


每次把 $\{1, 2, \dots, n\}$ 分为 $k$ 组 $B_1, B_2, \dots, B_k$

$$\theta := \theta - \alpha \sum_{i \in B_j} \nabla_{\theta} J^{(i)}(\theta) \quad j = 1, 2, \dots, k$$



# 非凸优化

## ➤ 最速度梯度下降法



- 损失函数具有高条件数，损失函数在一个方向上变化很快，而在另一个方向上变化很慢，会出现震荡。




- 鞍点和局部极小点



# 非凸优化

## ➤ 动量更新





# 非凸优化

## ➤ 动量更新

### Polyak重球法(heavy ball method)

$$\begin{aligned}y_{k+1} &= x_k + \beta(x_k - x_{k-1}) \\x_{k+1} &= y_k - \alpha \nabla f(x_k)\end{aligned}$$


### Nesterov 加速梯度下降(accelerated gradient descent)

$$\begin{aligned}y_{k+1} &= x_k + \beta(x_k - x_{k-1}) \\x_{k+1} &= y_k - \alpha \nabla f(y_k)\end{aligned}$$



# 非凸优化

## ➤ 步长选取



- SGD
- SGD+Momentum
- Nesterov



# 非凸优化

## ➤ 步长选取

### AdaGrad

$$dx_k = \nabla f(x_k)$$

$$\text{grad}_{k+1}^2 = \text{grad}_{k+1}^2 + dx_k \cdot dx_k$$

$$x_{k+1} = y_k - \frac{\alpha}{\sqrt{\text{grad}_{k+1}^2 + 10^{-7}}} dx_k$$

### RMSProp

$$dx_k = \nabla f(x_k)$$

$$\text{grad}_{k+1}^2 = \beta \text{grad}_{k+1}^2 + (1 - \beta) dx_k \cdot dx_k$$

$$x_{k+1} = y_k - \frac{\alpha}{\sqrt{\text{grad}_{k+1}^2 + 10^{-7}}} dx_k$$



## ➤ 步长选取

### AdaGrad

$$dx_k = \nabla f(x_k)$$

$$s_{k+1}^2 = s_k^2 + dx_k \cdot dx_k$$

$$x_{k+1} = x_k - \frac{\alpha}{\sqrt{s_{k+1}^2 + 10^{-7}}} dx_k$$

### RMSProp

$$dx_k = \nabla f(x_k)$$


$$s_{k+1}^2 = \beta s_k^2 + (1 - \beta) dx_k \cdot dx_k$$

$$x_{k+1} = x_k - \frac{\alpha}{\sqrt{s_{k+1}^2 + 10^{-7}}} dx_k$$



# 非凸优化

## ➤ 步长选取



SGD



SGD+Momentum



RMSProp



# 非凸优化

## 自适应矩估计(Adaptive Moment Estimation,Adam)

$$dx_k = \nabla f(x_k)$$

$$v_{k+1} = \beta_1 v_k + (1 - \beta_1) dx_k$$

$$s_{k+1} = \beta_2 s_k + (1 - \beta_2) dx_k \cdot dx_k$$

偏差修正：

$$\hat{v}_{k+1} = \frac{v_{k+1}}{1 - \beta_1^{k+1}} \quad \hat{s}_{k+1} = \frac{s_{k+1}}{1 - \beta_2^{k+1}}$$



$$x_{k+1} = x_k - \frac{\alpha}{\sqrt{\hat{s}_{k+1} + 10^{-7}}} \hat{v}_{k+1}$$

参数  $\beta_1 = 0.9$  ,  $\beta_2 = 0.999$  和  $\alpha$



# 非凸优化


## 学习率选 $\alpha$ 的取





# 非凸优化

## 过拟合



<https://blog.csdn.net/u010960155>



# 非凸优化

➤ 过拟合：正则化

$$J(\theta) = J(\theta) + \lambda R(\theta)$$

$L_2$ 正则化(weight decay)：

$$R(\theta) = \sum \theta_i^2$$

$L_1$ 正则化：

$$R(\theta) = \sum |\theta_i|$$



弹性网络(Elastic net)：

$$R(\theta) = \beta \sum \theta_i^2 + \sum |\theta_i|$$



# 非凸优化

## ➤ 过拟合：丢弃法(Dropout)



- 在训练的时候(每一个批次(batch))，以概率 $1 - p$ 随机删去该层的一些输出，并把其余输出乘以 $1/p$
- 训练了多个模型



# 非凸优化


## 过拟合：丢弃法(Dropout)

```
p = 0.5 # probability of keeping a unit active. higher = less dropout

def train_step(X):
    # forward pass for example 3-layer neural network
    H1 = np.maximum(0, np.dot(W1, X) + b1)
    U1 = (np.random.rand(*H1.shape) < p) / p # first dropout mask. Notice /p!
    H1 *= U1 # drop!
    H2 = np.maximum(0, np.dot(W2, H1) + b2)
    U2 = (np.random.rand(*H2.shape) < p) / p # second dropout mask. Notice /p!
    H2 *= U2 # drop!
    out = np.dot(W3, H2) + b3

    # backward pass: compute gradients... (not shown)
    # perform parameter update... (not shown)

def predict(X):
    # ensembled forward pass
    H1 = np.maximum(0, np.dot(W1, X) + b1) # no scaling necessary
    H2 = np.maximum(0, np.dot(W2, H1) + b2)
    out = np.dot(W3, H2) + b3
```



测试时保持不变



# 参考文献

## ➤ 参考文献

斯坦福CS231课件：

[cs231n.stanford.edu/slides/2017/cs231n\\_2017\\_lecture7.pdf](https://cs231n.stanford.edu/slides/2017/cs231n_2017_lecture7.pdf)

Cybenko, George. "Approximation by superpositions of a sigmoidal function." *Mathematics of control, signals and systems* 2, no. 4 (1989): 303-314.

Hornik, Kurt. "Approximation capabilities of multilayer feedforward networks." *Neural networks* 4, no. 2 (1991): 251-257.

Jones, Lee K. "A simple lemma on greedy approximation in Hilbert space and convergence rates for projection pursuit regression and neural network training." *The annals of Statistics* (1992): 608-613.

Barron, Andrew R. "Universal approximation bounds for superpositions of a sigmoidal function." *IEEE Transactions on Information theory* 39, no. 3 (1993): 930-945.

维斯康星麦迪逊CS726课件：[Lecture 9–10: Accelerated Gradient Descent](#)



# 神经网络中的模块

➤ Batch normalization 模块

$$BN(z) = \frac{z - E[z]}{\sqrt{Var[z] + \epsilon}}$$

$$BN(z) = \beta + \gamma \odot BN-S(z)$$