



東莞理工學院  
DONGGUAN UNIVERSITY OF TECHNOLOGY

# 人工智能概论

## 第五章：神经网络

丁烨，计算机科学与技术学院

[dingye@dgut.edu.cn](mailto:dingye@dgut.edu.cn)



# 目录

- ❖ 神经元模型
- ❖ 感知机与多层网络
- ❖ 误差逆传播算法
- ❖ 全局最小与局部极小


# 神经元模型

## 基本概念

- ❖ 人工神经网络 (Artificial Neural Network, ANN)
- ❖ 一种模仿生物神经网络的结构和功能的机器学习算法
- ❖ 神经网络由大量的人工神经元 (Neuron) 联结进行计算
- ❖ 人工神经网络能在外界信息的基础上改变内部结构，是一种自适应系统
- ❖ 通俗地讲就是具备学习功能
- ❖ 和其他机器学习方法一样，神经网络已经被用于解决各种各样的问题，例如机器视觉和语音识别
- ❖ 这些问题都是很难被传统基于规则的算法所解决的

# 神经元模型


## 基本概念



# 神经元模型

## 基本概念


- ❖ 神经元 (Neuron)
- ❖ 在生物神经网络中，每个神经元与其他神经元相连，当它被**激活**（“兴奋”）时，就会向相连的神经元发送化学物质，从而改变这些神经元内的电位
- ❖ 当神经元的电位超过了一个**“阈值 (Threshold)”**，它就会被激活



# 神经元模型

## 基本概念


- ❖ 1943年，McCulloch 和 Pitts 将上述情形抽象下图的数学模型
- ❖ 这就是一直沿用至今的“M-P 神经元模型”



# 神经元模型

## 基本概念


- ❖ 在这个模型中，神经元接收到来自其他神经元传递过来的输入信号
- ❖ 这些输入信号通过带**权重**的连接进行传递
- ❖ 神经元接收到的总输入值将与神经元的**阈值**进行比较
- ❖ 然后通过“**激活函数 (Activation Function)**”处理
- ❖ 并产生神经元的输出



# 神经元模型


## 基本概念

- ❖ 理想中的激活函数是上图所示的阶跃函数
- ❖ 但阶跃函数具有不连续、不光滑等不太好的性质
- ❖ 因此实际常用 **Sigmoid** 函数作为激活函数



$$\text{sgn}(x) = \begin{cases} 1, & x \geq 0; \\ 0, & x < 0. \end{cases}$$

(a) 阶跃函数



$$\text{sigmoid}(x) = \frac{1}{1 + e^{-x}}$$

(b) Sigmoid 函数



# 神经元模型

## 基本概念

- ❖ 把许多个这样的神经元按一定的层次结构连接起来，就得到了神经网络
- ❖ 事实上，从计算机科学的角度看，我们可以先不考虑神经网络是否真的模拟了生物神经网络
- ❖ 只需将一个神经网络视为**包含了许多参数的数学模型**，这个模型是若干个函数相互嵌套代入形成，例如：

$$y_i = f \left( \sum_i w_i x_i - \theta_j \right)$$


# 目录

- ❖ 神经元模型
- ❖ 感知机与多层网络
- ❖ 误差逆传播算法
- ❖ 全局最小与局部极小

# 感知机与多层网络

## 感知机


- ❖ 感知机 (Perceptron)
- ❖ 由两层神经元组成
- ❖ 输入层接收外界输入信号后传递给输出层
- ❖ 输出层是 M-P 神经元
- ❖ 感知机能容易地实现逻辑与、或、非运算



# 感知机与多层网络


## 感知机

$$y = f\left(\sum_i w_i x_i - \theta\right)$$



$$\text{sgn}(x) = \begin{cases} 1, & x \geq 0; \\ 0, & x < 0. \end{cases}$$


(a) 阶跃函数



# 感知机与多层网络

## 感知机

- ❖ 逻辑与
- ❖ 令  $w_1 = w_2 = 1, \theta = 2$
- ❖ 则  $y = f(1 \cdot x_1 + 1 \cdot x_2 - 2)$
- ❖ 那么, 仅在  $x_1 = x_2 = 1$  时
- ❖  $y = 1$




$$\text{sgn}(x) = \begin{cases} 1, & x \geq 0; \\ 0, & x < 0. \end{cases}$$

(a) 阶跃函数

# 感知机与多层网络

## 感知机

- ❖ 逻辑或
- ❖ 令  $w_1 = w_2 = 1, \theta = 0.5$
- ❖ 则  $y = f(1 \cdot x_1 + 1 \cdot x_2 - 0.5)$
- ❖ 那么, 当  $x_1 = 1$  或  $x_2 = 1$  时
- ❖  $y = 1$




$$\text{sgn}(x) = \begin{cases} 1, & x \geq 0; \\ 0, & x < 0. \end{cases}$$

(a) 阶跃函数

# 感知机与多层网络

## 感知机

- ❖ 逻辑非
- ❖ 令  $w_1 = -0.6$ ,  $w_2 = 0$ ,  $\theta = -0.5$
- ❖ 则  $y = f(-0.6 \cdot x_1 + 0 \cdot x_2 + 0.5)$
- ❖ 那么:
- ❖ 当  $x_1 = 1$  时,  $y = 0$
- ❖ 当  $x_1 = 0$  时,  $y = 1$



$$\text{sgn}(x) = \begin{cases} 1, & x \geq 0; \\ 0, & x < 0. \end{cases}$$

(a) 阶跃函数

# 感知机与多层网络

## 感知机

- ❖ 给定训练数据集
- ❖ 神经元的权重  $w_i (i = 1, 2, \dots, n)$  和阈值  $\theta$  可以通过学习得到
- ❖ 假设我们先忽略  $\theta$ : “哑结点 (Dummy Node)”
- ❖ 感知机的学习规则就变得非常简单



# 感知机与多层网络

## 感知机

- ❖ 对训练样本  $(x, y)$ , 若当前感知机的输出为  $\hat{y}$
- ❖ 则感知机权重将调整为:

$$w_i \leftarrow w_i + \Delta w_i$$
$$\Delta w_i = \eta(y - \hat{y})x_i$$

- ❖ 其中  $\eta \in (0,1)$  称为**学习率 (Learning Rate)**
- ❖ 若感知机对训练样本预测正确, 即  $\hat{y} = y$ , 则感知机不发生变化
- ❖ 否则将根据错误的程度进行权重调整

# 感知机与多层网络

## 感知机

- ❖ 感知机只有输出层神经元进行激活函数处理
- ❖ 其学习能力非常有限
- ❖ 事实上，上述与、或、非问题都是线性可分的问题
- ❖ 即存在一个线性超平面能将它们分开
- ❖ 因此感知机的学习过程一定会收敛（Converge）
- ❖ 但是对于非线性可分的问题来说，感知机就很难训练了

# 感知机与多层网络

## 感知机





图 5.4 线性可分的“与”“或”“非”问题与非线性可分的“异或”问题


# 感知机与多层网络

## 多层网络

- ❖ 要解决非线性可分问题，需考虑使用多层神经元
- ❖ 例如下图的两层感知机就能解决异或问题



(a) 网络结构




(b) 分类区域

# 感知机与多层网络

## 多层网络


- ❖ 输出层与输入层之间的神经元被称为：
- ❖ 隐含层 (Hidden Layer)
- ❖ 隐含层和输出层神经元都是拥有激活函数的功能神经元




# 感知机与多层网络

## 多层网络

- ❖ 常见的神经网络是形如右图所示的层级结构
- ❖ 每层神经元与下一层神经元全互连
- ❖ 神经元之间不存在同层连接
- ❖ 也不存在跨层连接
- ❖ 这样的神经网络结构通常称为：
  - ❖ “多层前馈神经网络”
  - ❖ Multi-layer Feedforward Neural Network



(a) 单隐层前馈网络



(b) 双隐层前馈网络

# 感知机与多层网络

## 多层网络

- ❖ 多层前馈神经网络有强大的表示能力
- ❖ 只需一个包含足够多神经元的隐含层
- ❖ 多层前馈神经网络就能以任意精度逼近任意复杂度的连续函数
- ❖ 然而，如何设置隐含层神经元的个数仍是个未决问题
- ❖ 实际应用中通常靠“试错法”调整

# 感知机与多层网络

## 多层网络

- ❖ 神经网络的学习过程，就是根据训练数据来调整神经元之间的：
- ❖ “连接权重（Connection Weight）”
- ❖ 以及每个功能神经元的阈值
- ❖ 换言之，神经网络“学”到的东西，蕴涵在连接权重与阈值中



# 目录

- ❖ 神经元模型
- ❖ 感知机与多层网络
- ❖ 误差逆传播算法
- ❖ 全局最小与局部极小

# 误差逆传播算法

## 基本概念

- ❖ 对训练样本  $(x, y)$ , 若当前感知机的输出为  $\hat{y}$
- ❖ 则感知机权重将调整为:

$$w_i \leftarrow w_i + \Delta w_i$$
$$\Delta w_i = \eta(y - \hat{y})x_i$$

- ❖ 多层神经网络的学习能力比单层感知机强得多
- ❖ 训练时, 上述公式不足以表达神经元之间的连接权重

# 误差逆传播算法

## 基本概念

- ❖ 误差逆传播（Backpropagation, BP）
- ❖ 对多层人工神经网络进行梯度下降（Gradient Decent）的算法
- ❖ 也就是用链式法则以网络每层的权重为变数计算损失函数的梯度
- ❖ 以更新权重来最小化损失函数

# 误差逆传播算法



## 梯度下降法

- ❖ 梯度 (Gradient)
- ❖ 在向量微积分中，梯度是一种关于多元导数的概括
- ❖ 一元函数的导数是标量值函数
- ❖ 多元函数的梯度是向量值函数
- ❖ 多元可微函数  $f$  在点  $P$  上的梯度
- ❖ 是以  $f$  在  $P$  上的偏导数为分量的向量

# 误差逆传播算法

## 梯度下降法

- ❖ 标量场的值用灰度表示，越暗表示越大的数值
- ❖ 而其相应的梯度用蓝色箭头表示



# 误差逆传播算法


## 梯度下降法

- ❖ 假设有一个房间，房间内所有点的温度由一个标量场给出
- ❖ 在房间的每一点，该点的梯度将显示变热最快的方向
- ❖ 梯度的大小将表示在该方向上变热的速率
  
- ❖ 考虑一座高度在  $(x, y)$  点是  $H(x, y)$  的山
- ❖  $H$  这一点的梯度是在该点坡度（或者说斜度）最陡的方向
- ❖ 梯度的大小告诉我们坡度到底有多陡

# 误差逆传播算法

## 梯度下降法

- ❖ 梯度下降 (Gradient Decent)
- ❖ 一个一阶最优化算法
- ❖ 不断的对函数上当前点对应**梯度的反方向**的规定步长距离点进行迭代搜索
- ❖ 直到找到函数的一个**局部极小值**



# 误差逆传播算法

## 误差逆传播算法

- ❖ 第一阶段：激励传播
- ❖ 每次迭代中的传播环节包含两步：
  - ❖ 前向传播阶段：
    - ❖ 将训练样本输入神经网络并获得预测结果
  - ❖ 反向传播阶段：
    - ❖ 通过“损失函数（Loss Function）”计算预测结果与真相的误差



# 误差逆传播算法

## 误差逆传播算法

- ❖ 第二阶段：权重更新
- ❖ 对于每个神经元上的权重，按照以下步骤进行更新：
- ❖ 将激活函数的值与误差相乘，从而获得**权重的梯度**
- ❖ 将这个梯度乘上一个比例并取反后加到权重上
  
- ❖ 注意：这个比例将会影响训练过程的速度和效果

# 误差逆传播算法

## 误差逆传播算法

- ❖ 第一阶段和第二阶段可以反复循环迭代
- ❖ 直到误差达到一定阈值范围之内（“收敛”）
- ❖ 则训练完毕，得到模型

# 误差逆传播算法

## 误差逆传播算法

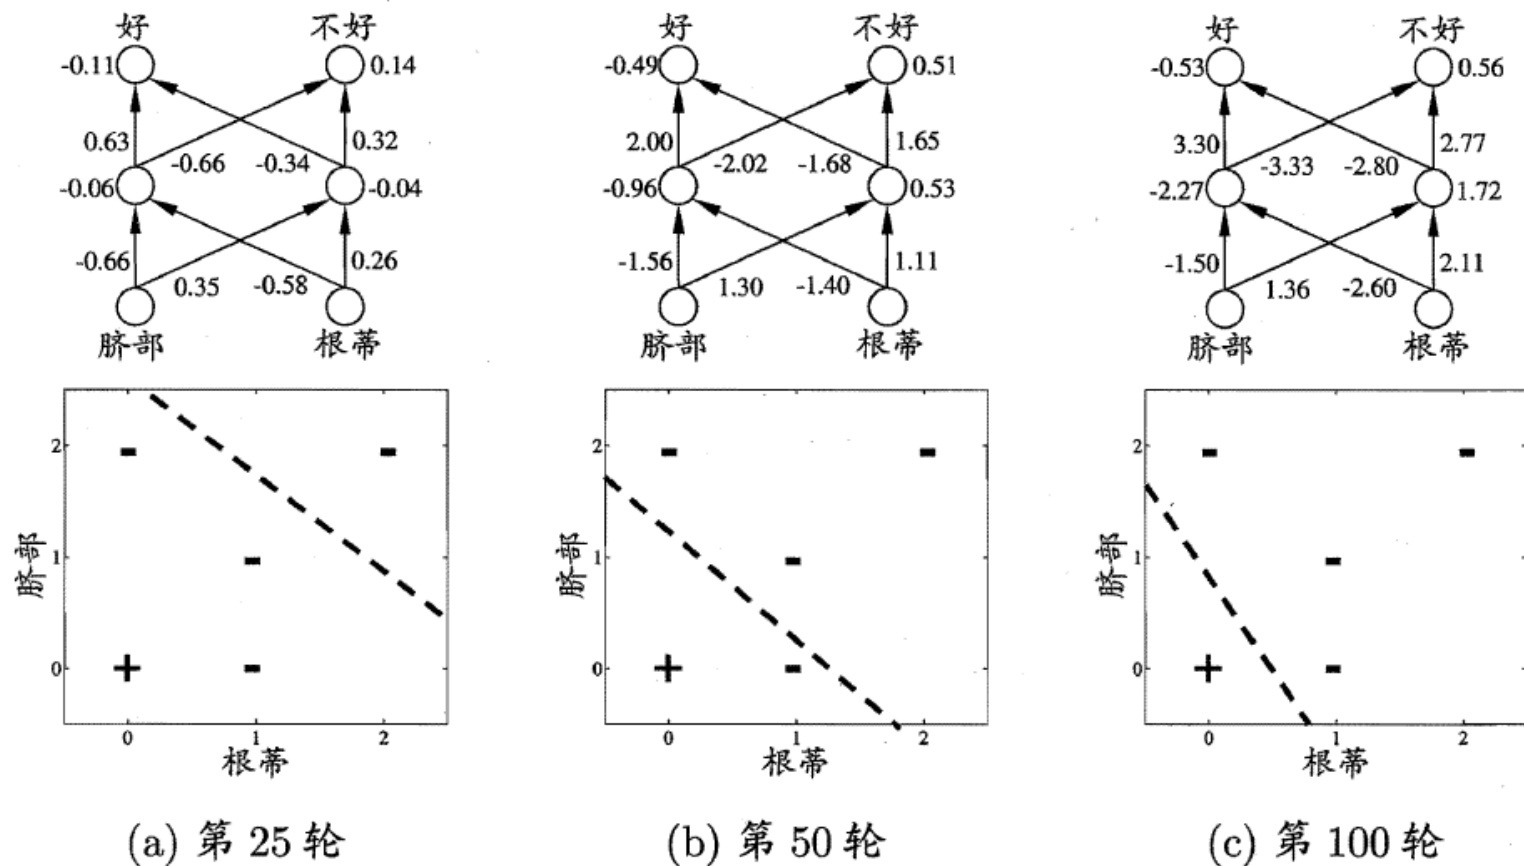


图 5.9 在2个属性、5个样本的西瓜数据上, BP网络参数更新和分类边界的变化情况

# 目录

- ❖ 神经元模型
- ❖ 感知机与多层网络
- ❖ 误差逆传播算法
- ❖ 全局最小与局部极小

# 全局最小与局部极小

## 基本概念

- ❖ 若用  $E$  表示神经网络在训练集上的误差
- ❖ 则它显然是关于连接权重  $w$  和阈值  $\theta$  的函数
- ❖ 此时，神经网络的训练过程可看作一个参数寻优过程
- ❖ 即在参数空间中，寻找一组最优参数使得  $E$  最小


# 全局最小与局部极小

## 基本概念

- ❖ 我们常会谈到两种误差的“最优”：
- ❖ 局部极小 (Local Minimum)
- ❖ 全局最小 (Global Minimum)
- ❖ 对于参数空间中的某个点：
- ❖ 局部极小解是指其邻域点的误差函数值均不小于该点的误差函数值
- ❖ 全局最小解是指所有点的误差函数值均不小于该点的误差函数值

# 全局最小与局部极小

## 基本概念



# 全局最小与局部极小

## 解决方案

- ❖ 神经网络常采用以下策略来试图“跳出”局部极小
- ❖ 从而进一步接近全局最小
- ❖ 模拟退火 (Simulated Annealing, SA)
- ❖ 随机梯度下降 (Stochastic Gradient Descent, SGD)
- ❖ 遗传算法 (Genetic Algorithm, GA)
  
- ❖ 注意：上述算法大多是启发式算法，理论上缺乏保障



# 全局最小与局部极小


## 解决方案

- ❖ 模拟退火 (Simulated Annealing, SA)
- ❖ 退火是指冶金学中将材料加热后再经特定速率冷却
- ❖ 材料中的原子起初会停留在内能局部极小值的位置
- ❖ 加热使能量变大, 原子会离开原来位置, 而随机在其他位置中移动
- ❖ 退火冷却时速度较慢
- ❖ 使得原子有较多可能可以找到内能比原先更低的位置

# 全局最小与局部极小

## 解决方案

- ❖ 模拟退火的原理和金属退火的原理近似
- ❖ 将搜寻空间内每一点想像成原子
- ❖ 算法先以搜寻空间内一个任意点开始
- ❖ 每一步先选择一个“邻居”
- ❖ 然后再计算到达“邻居”的概率
- ❖ 此处将模拟退火算法应用于求解旅行商问题：求出连接 125 个点的最小路线长度



# 全局最小与局部极小

## 解决方案

- ❖ 随机梯度下降 (Stochastic Gradient Descent, SGD)
- ❖ 梯度下降算法的一个随机估计 (Stochastic Approximation)
- ❖ 在**小批量随机数据**上计算损失函数的梯度
- ❖ 由于加入了随机性, 即便陷入局部极小点, 也有一定概率跳出

# 全局最小与局部极小

## 解决方案

- ❖ 遗传算法 (Genetic Algorithm, GA)
- ❖ 在寻找全局最小的过程中加入随机“突变”
- ❖ 由于加入了随机性, 即便陷入局部极小点, 也有一定概率跳出

# 总结

- ❖ 神经网络是深度学习的重要基础
- ❖ 深度学习
- ❖ 2024-05-27
- ❖ 10:25 - 12:00

# 总结

- ❖ 「西瓜书」周志华《机器学习》，清华大学出版社
- ❖ <https://item.jd.com/12762673.html>
- ❖ 「南瓜书」谢文睿、秦州《机器学习公式详解》，人民邮电出版社
- ❖ <https://github.com/datawhalechina/pumpkin-book/>

# 总结

❖ Scikit-Learn

❖ <https://scikit-learn.org>

❖ TensorFlow

❖ <https://www.tensorflow.org>



TensorFlow



東莞理工學院  
DONGGUAN UNIVERSITY OF TECHNOLOGY

# Thank You!

丁焯，计算机科学与技术学院

[dingye@dgut.edu.cn](mailto:dingye@dgut.edu.cn)

