

现代编程思想

案例：基于梯度下降的神经网络

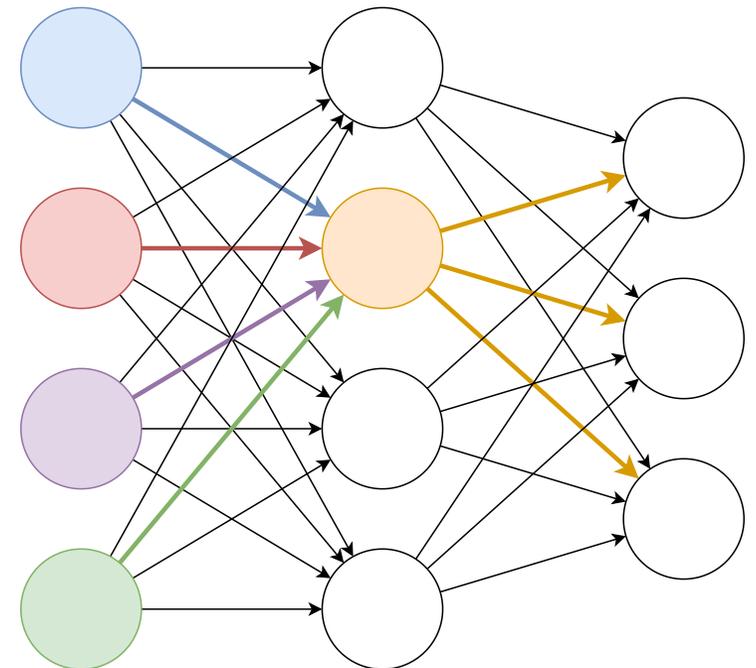
Hongbo Zhang

案例：鸢尾花

- 鸢尾花数据集是机器学习中的"Hello World"
 - 1936年发布
 - 包含对3种鸢尾花的测量，各有50个样本
 - 每个样本包含4项特征：花萼与花瓣的长度和宽度
- 目标
 - 通过特征，判断属于哪一类鸢尾花
 - 构建并训练神经网络，正确率95%以上

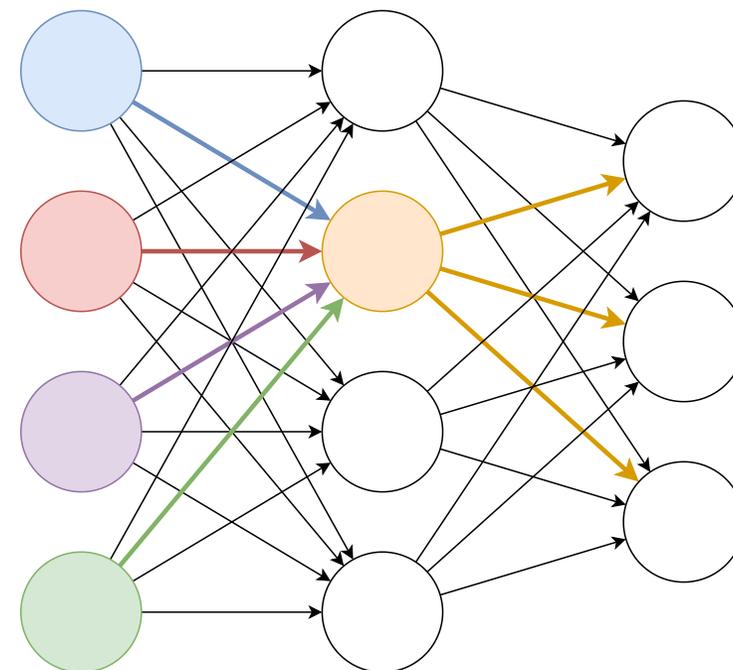
神经网络

- 神经网络是机器学习的一种
 - 模拟人的大脑神经结构
 - 单个神经元通常有
 - 多个输入
 - 一个输出
 - 神经元在达到一定阈值后激活
 - 通常分为多层结构



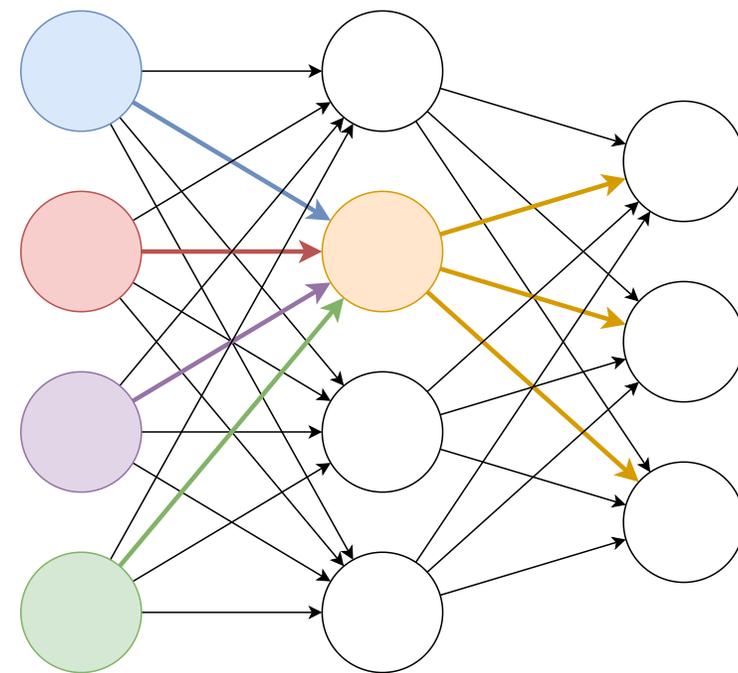
神经网络

- 一个典型的神经网络通常包含
 - 输入层：接受输入的参数
 - 输出层：输出计算结果
 - 隐含层：输入层与输出层之间的层级
- 神经网络的架构
 - 隐含层的层数、节点数、连接方式
 - 神经元的激活函数等



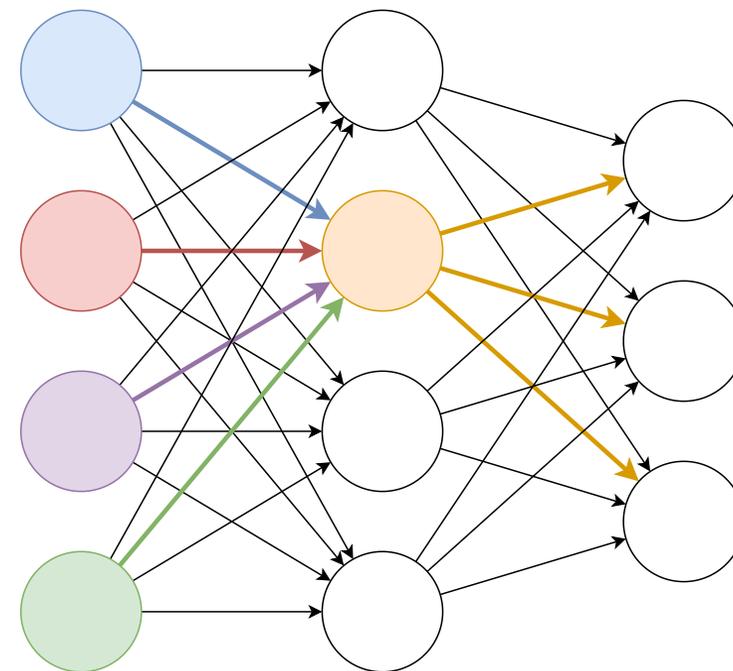
神经网络架构

- 输入：每个样本包含4个特征，四个输入
- 输出：属于每一种类的可能性，三个输出
- 样本数：150（总共）
- 网络架构：前馈神经网络
 - 输入层：四个节点
 - 输出层：三个节点
 - 隐含层：一层四个节点
 - 全连接：每一个神经元与前一层所有神经元相连



神经元

- $f = w_0x_0 + w_1x_1 + \dots + w_nx_n + c$
 - w_i, c : 参数
 - x_i : 输入
- 激活函数
 - 隐含层: 线性整流函数 ReLU
 - 当计算值小于零, 不激活神经元
 - $f(x) = \begin{cases} x & x \geq 0 \\ 0 & x < 0 \end{cases}$
 - 输出层: Softmax
 - 将输出整理为总和为1的概率分布
 - $f(x_m) = \frac{e^{x_m}}{\sum_{i=1}^N e^{x_i}}$



神经网络实现

- 运算的定义

```
1. trait Base {  
2.     constant(Double) -> Self  
3.     value(Self) -> Double  
4.     op_add(Self, Self) -> Self  
5.     op_neg(Self) -> Self  
6.     op_mul(Self, Self) -> Self  
7.     op_div(Self, Self) -> Self  
8.     exp(Self) -> Self // 用于计算softmax  
9. }
```

- 激活函数

```
1. fn relu[T : Base](t : T) -> T {
2.   if t.value() < 0.0 { T::constant(0.0) } else { t }
3. }
4.
5. fn softmax[T : Base](inputs : Array[T]) -> Array[T] {
6.   let n = inputs.length()
7.   let outputs : Array[T] = Array::make(n, T::constant(0.0))
8.   let mut sum = T::constant(0.0)
9.   for i = 0; i < n; i = i + 1 {
10.    sum = sum + inputs[i].exp()
11.  }
12.  for i = 0; i < n; i = i + 1 {
13.    outputs[i] = inputs[i].exp() / sum
14.  }
15.  outputs
16. }
```

神经网络实现

- 输入->隐含层

```
1. fn input2hidden[T : Base](inputs: Array[Double], param: Array[Array[T]]) -> Array[T] {
2.   let outputs : Array[T] = Array::make(param.length(), T::constant(0.0))
3.   for output = 0; output < param.length(); output = output + 1 { // 4 outputs
4.     for input = 0; input < inputs.length(); input = input + 1 { // 4 inputs
5.       outputs[output] = outputs[output] + T::constant(inputs[input]) * param[output][input]
6.     }
7.     outputs[output] = outputs[output] + param[output][inputs.length()] |> reLU // constant
8.   }
9.   outputs
10. }
```

神经网络实现

- 隐含层->输出

```
1. fn hidden2output[T : Base](inputs: Array[T], param: Array[Array[T]]) -> Array[T] {
2.   let outputs : Array[T] = Array::make(param.length(), T::constant(0.0))
3.   for output = 0; output < param.length(); output = output + 1 { // 3 outputs
4.     for input = 0; input < inputs.length(); input = input + 1 { // 4 inputs
5.       outputs[output] = outputs[output] + inputs[input] * param[output][input]
6.     }
7.     outputs[output] = outputs[output] + param[output][inputs.length()] // constant
8.   }
9.   outputs |> softmax
10. }
```

神经网络训练

- 损失函数
 - 评估当前结果与预期结果之间的“差距”
 - 我们选择交叉熵
- 梯度下降
 - 梯度决定参数的调整方向
- 学习率
 - 学习率决定参数的调整幅度
 - 我们选择指数下降，逐渐逼近

神经网络训练

- 多分类问题交叉熵: $I(x_j) = -\ln(p(x_j))$
 - x_j : 事件; $p(x_j)$: x_j 发生的概率
- 损失函数: 基于抽象的定义

```
1. trait Log {  
2.   log(Self) -> Self // 用于计算交叉熵  
3. }  
4. fn cross_entropy[T : Base + Log](inputs: Array[T], expected: Int) -> Double {  
5.   -inputs[expected].log().value()  
6. }
```

神经网络训练

- 后向微分：计算梯度
 - 从现有参数构建，积累微分

```

1. fn Backward::param(param: Array[Array[Double]], diff: Array[Array[Double]],
2.   i: Int, j: Int) -> Backward {
3.   { value: param[i][j], backward: fn { d => diff[i][j] = diff[i][j] + d} }
4. }

```

- 计算并根据损失函数求微分

```

1. fn diff(inputs: Array[Double], expected: Int,
2.   param_hidden: Array[Array[Backward]], param_output: Array[Array[Backward]]) {
3.   let result = inputs
4.     |> input2hidden(param_hidden)
5.     |> hidden2output(param_output)
6.     |> cross_entropy(expected)
7.   result.backward(1.0)
8. }

```

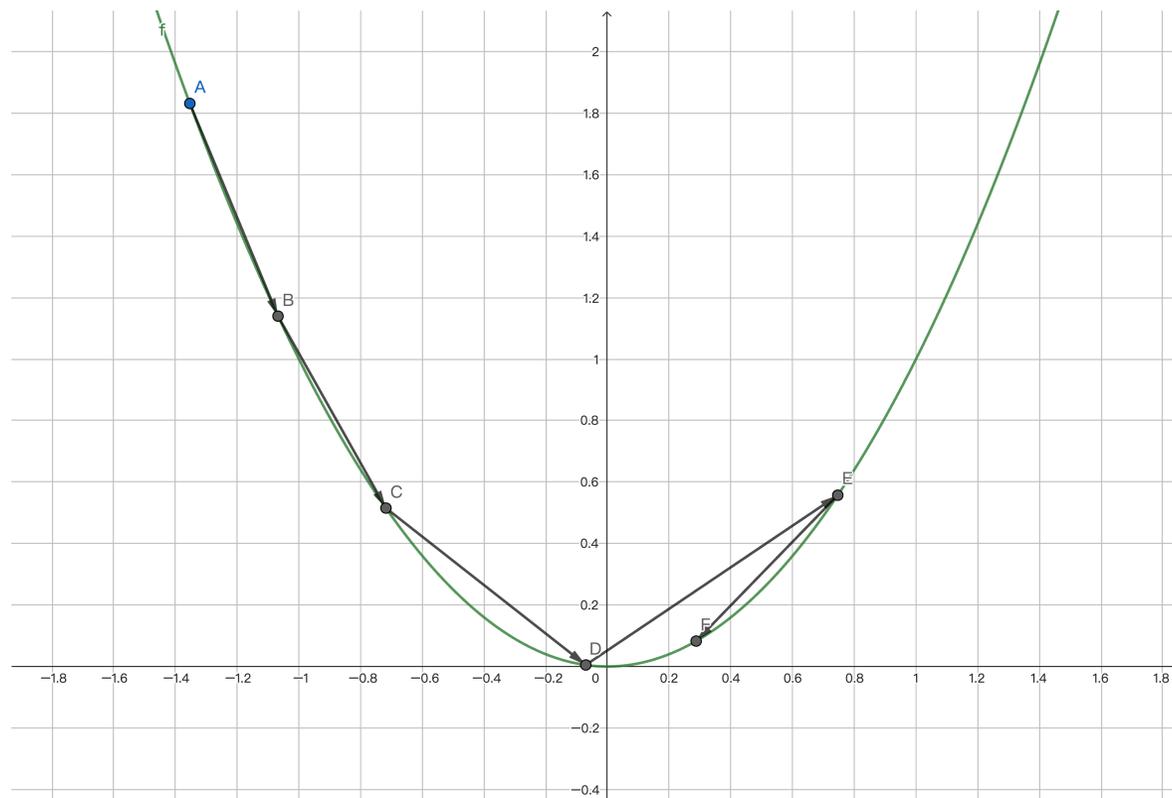
神经网络训练

- 根据梯度更新参数

```
1. fn update(params: Array[Array[Double]], diff: Array[Array[Double]], step: Double) {  
2.   for i = 0; i < params.length(); i = i + 1 {  
3.     for j = 0; j < params[i].length(); j = j + 1 {  
4.       params[i][j] = params[i][j] - step * diff[i][j]  
5.     }  
6.   }  
7. }
```

- 学习率

- 不合适的学习率可能导致学习成果下降，乃至无法收敛获得最佳结果



- 指数衰减学习率: $f(x) = ae^{-bx}$, 其中a、b为常数, x为训练次数

神经网络训练

- 将数据随机分成两个部分
 - 训练集：每一轮根据训练集的数据进行计算并求微分
 - 验证集：在训练结束后验证成果，避免过拟合
- 数据量较少，可以直接进行完整训练
 - 每一轮训练都使用训练集中的全部数据
 - 如果数据较多，则需要考虑分批训练

总结

- 本章节介绍了神经网络的基础知识
 - 神经网络的结构
 - 神经网络的训练
- 具体实现参见月兔试用环境
- 参考资料
 - [What is a neural network](#)