



人工智能基础与进阶

聚类和寻优算法

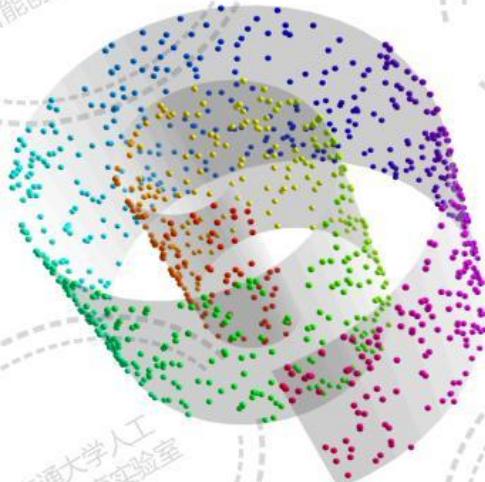
上海交通大学

目录 content

上海交通大学人工
智能创新教育实验室

上海交通大学人工
智能创新教育实验室

上海交通大学人工
智能创新教育实验室



第一节

K-Means聚类

第二节

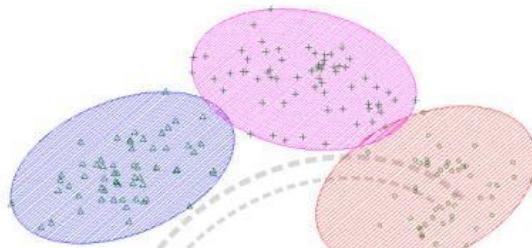
寻优算法

上海交通大学人工
智能创新教育实验室

上海交通大学人工
智能创新教育实验室

上海交通大学人工
智能创新教育实验室

第一节 K-means聚类

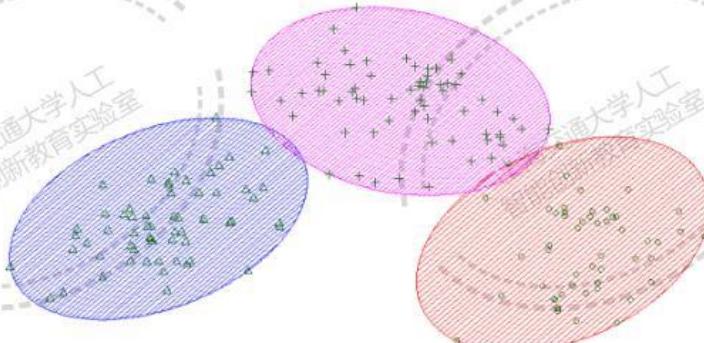


K-means聚类—聚类与分类

聚类和分
类的区别

分类 (classification)：监督学习任
务，利用已知的样本标记训练学习
器预测未知样本的类别

聚类 (clustering)：无监督学习任
务，不知道真实的样本标记，只把
相似度高的样本聚合在一起。



K-means聚类—聚类的定义

聚类的定义

利用样本在多维空间的相对位置，将样本分成两个或多个集团的算法。

按照事物的某些属性，把事物数据分组成为多个类，在同一个类内对象之间具有**较高的相似度**，不同类之间的对象差别较大。即，使类间的相似性尽量小，类内相似性尽量大。

聚类实施过程

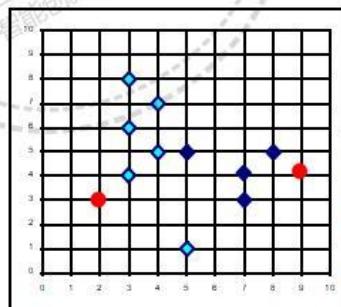
随机选择 k 个对象，每个对象初始地代表一个类的平均值或中心

不断重复这个过程，直到所有的样本都不能再分配为止。

然后重新计算每个类的平均值

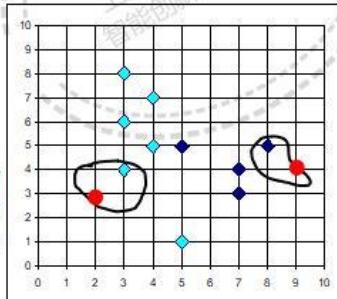
对剩余的每个对象，根据其到类中心的距离，被划分到最近的类

K-means聚类—算法实现



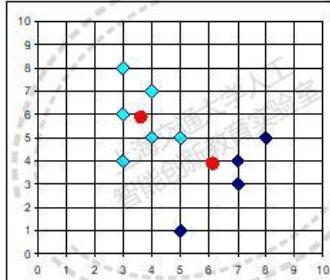
将每个对象赋给最类似的中心

K=2
任意选择 K个对象作为初始聚类中心



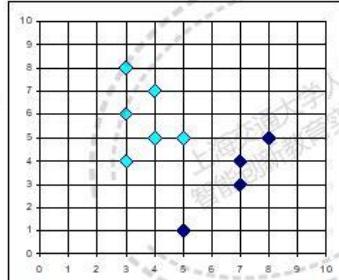
更新簇的平均值

重新赋值



更新簇的平均值

重新赋值



K-means聚类—性能分析

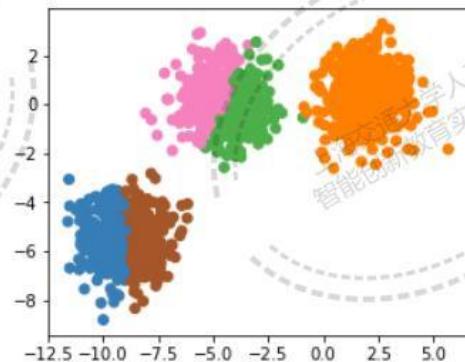
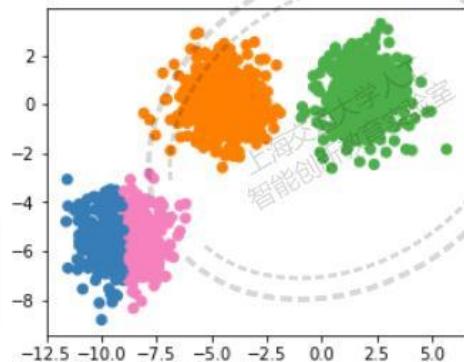
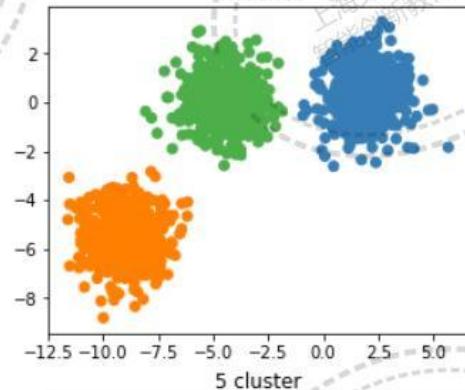
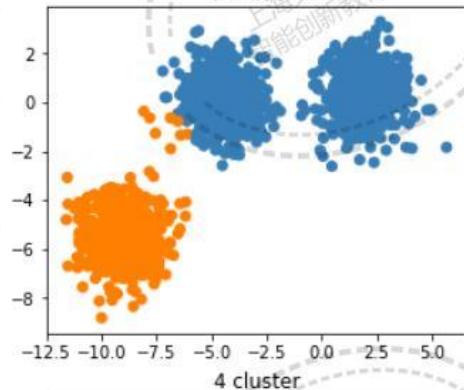
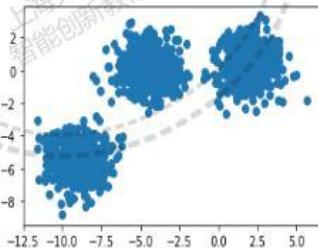
优点：

- 简单直观，易于理解与实现；
- 复杂度相对较低，在 K 不是很大的情况下，K-means的计算时间相对较短；
- 会产生密度比较高的簇。

缺点：

- K 需要预先得知，很难预测到准确值；
- 对初始设置很敏感；
- 对噪声和离异点非常敏感。

K-means聚类—k值影响

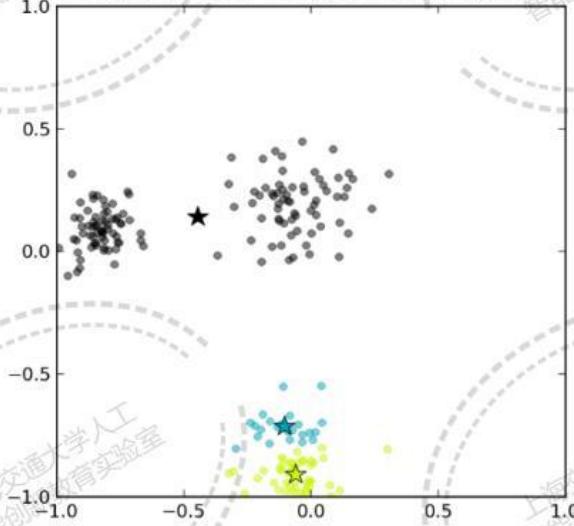


K值的影响

K-means聚类—初始值影响

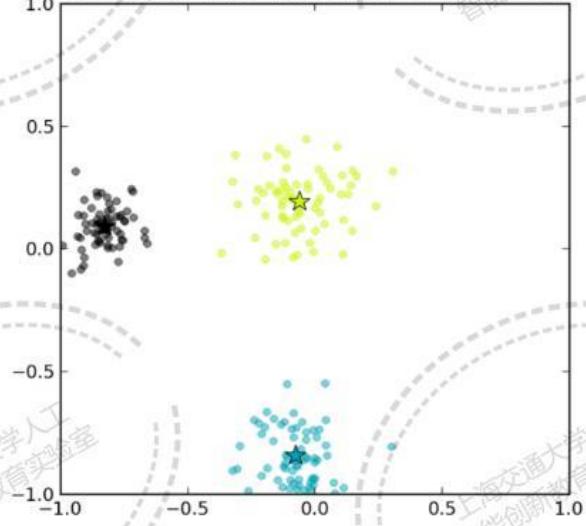
N=200, K=3

K-means with random initialization



N=200, K=3

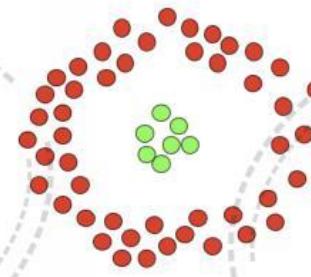
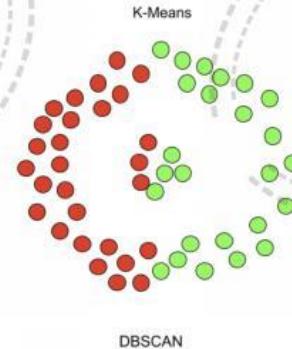
K-means with random initialization



初始值的影响

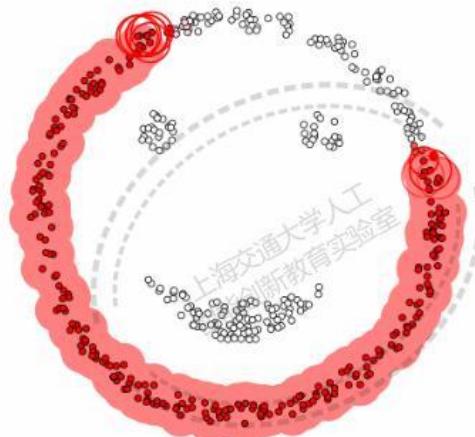
为什么要引入DBSCAN聚类算法？

- 基于距离的聚类算法例如kmeans，在处理非球状结构的数据集时，聚类效果不好。
- 与之不同的是，在基于密度的聚类算法例如DBSCAN中，通过在数据集中寻找被低密度区域分离的高密度区域，将分离出的高密度区域作为一个独立的类别，以此发现任意形状的聚类，



DBSCAN 聚类

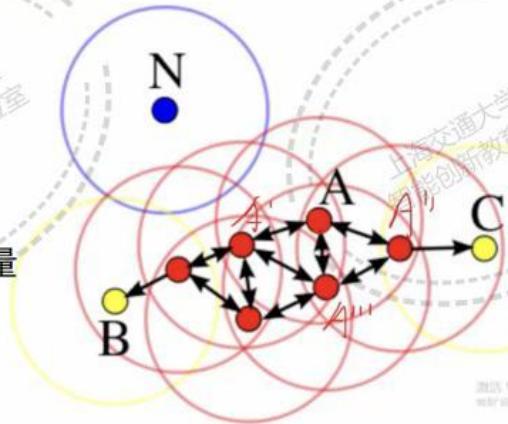
- DBSCAN 全称为 Density-Based Spatial Clustering Algorithm with Noise, 基于密度的噪声空间聚类算法。
- DBSCAN 算法是基于密度对数据点进行处理的，主要是将特征空间中足够密集的点划分为同一个簇，簇的形状可以是任意的，而且数据点中有噪声点的话，不会将这些点划分给某个簇。



DBSCAN 聚类

基本概念

- 核心点：在半径为 r 的邻域内，含有超过 minPts 数目的点，成为核心点
- 边界点：在半径为 r 的邻域内，含有点的数量小于 minPts 个，但与核心点直接相连
- 离群点：既不是核心点也不是边界点的点

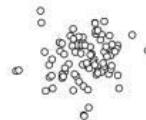


算法步骤

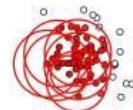
- 任选一个未被访问过的点 p ，若点 p 的 r 邻域包含多 minPts 个点，则创建一个以 p 为核心点的簇；否则，设 p 为离群点；
- 访问该点 r 邻域内的其他点，若还没有被分配一个簇，则将其纳入上一步创建的簇中，若为核心样本，则依次访问其 r 邻域的其他点，以此类推，直到簇内 r 邻域内没有更多核心点为止；
- 选取另一个尚未被访问过的点，重复1, 2步骤。

DBSCAN 聚类——半径的影响

半径 r : 1
阈值 minPts : 4



半径 r : 1.7
阈值 minPts : 4



DBSCAN 聚类——阈值的影响

半径 r : 1
阈值 minPts : 4



半径 r : 1
阈值 minPts : 2



DBSCAN 聚类

优点:

- 不需要我们指定数据集中簇的个数K。
- 前面说K均值聚类通常只在球形分布的数据集上分类效果比较好，而 DBSCAN 聚类则可以用于各种复杂形状的数据集。
- 可以识别出不属于任何簇的离群点，非常适合用来检测离群点。

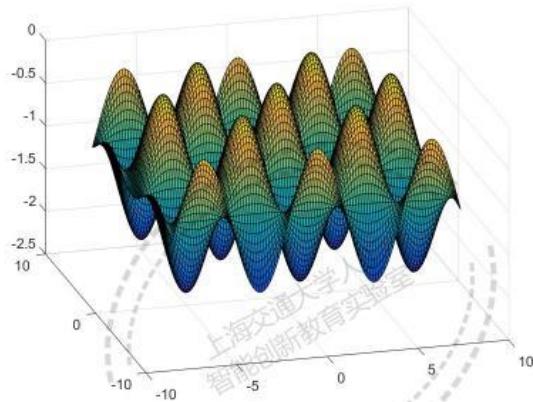
缺点:

- DBSCAN 算法的运行速度要比 KMeans 算法慢一些。
- DBSCAN 算法的两个参数也是要根据具体的数据情况进行多次尝试。
- 对于具有不同密度的簇，DBSCAN 算法的效果可能不是很好。

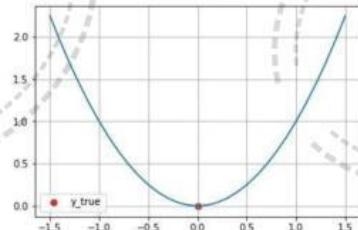
DBSCAN与K-means算法



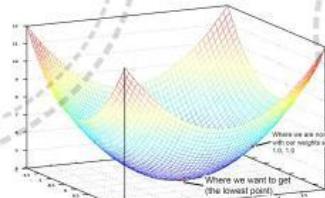
第二节 寻优算法



寻优算法—什么是寻优?



一维寻优



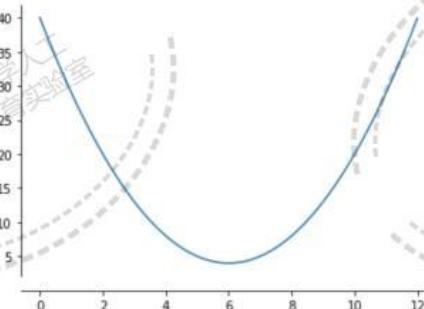
二维寻优

寻优算法的任务，就是找到一个函数的最小值

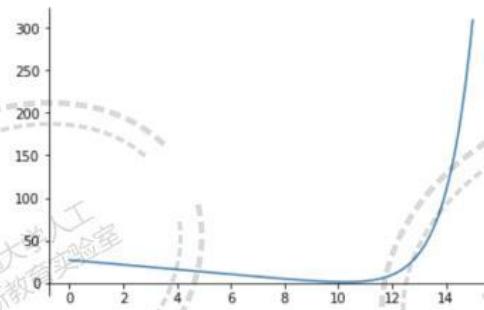
计算最小成本、最短路径、最小损失……

寻优算法—为什么要算法?

$$\min f(x) : x^2 - 6x + 10$$



$$\min f(x) : \frac{e^x}{1000} + \frac{x^2}{10} - 3x + 27$$

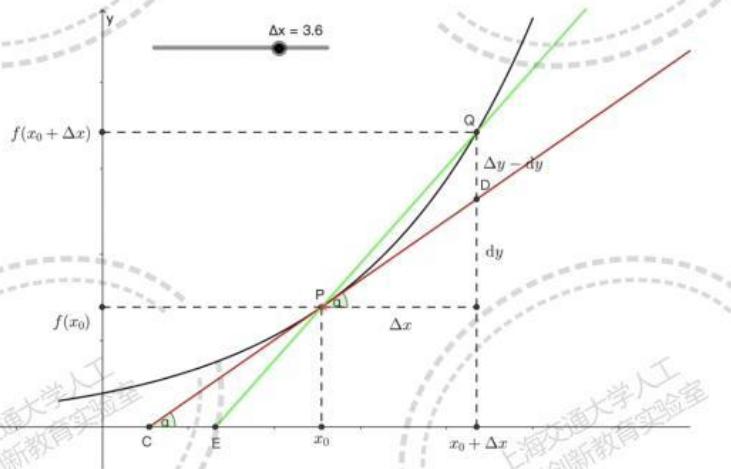


如何找到一个函数的最小值?

寻优算法——什么是梯度？

导数定义

$$\frac{dy}{dx} = f'(x) = \lim_{\Delta x \rightarrow 0} \frac{f(x + \Delta x) - f(x)}{\Delta x}$$



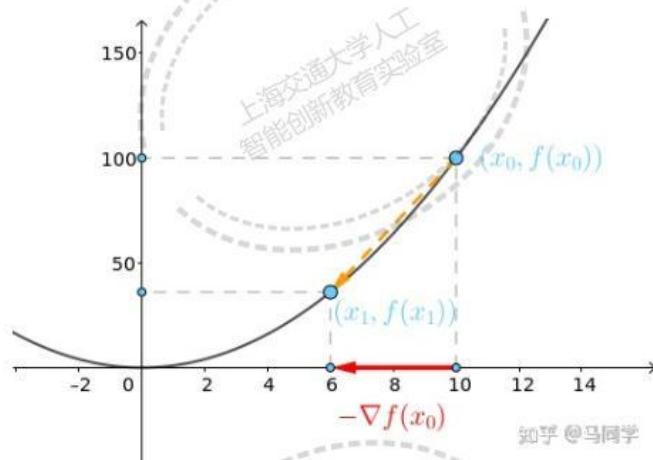
梯度定义

$$\nabla f(x, y)$$

$$= \left(\frac{\partial f}{\partial x}, \frac{\partial f}{\partial y} \right)$$

$$= \frac{\partial f}{\partial x} \cdot i + \frac{\partial f}{\partial y} \cdot j$$

寻优算法—梯度下降法



知乎 @马同学

梯度下降法就是通过沿着负梯度方向不断迭代，找到梯度为0的位置

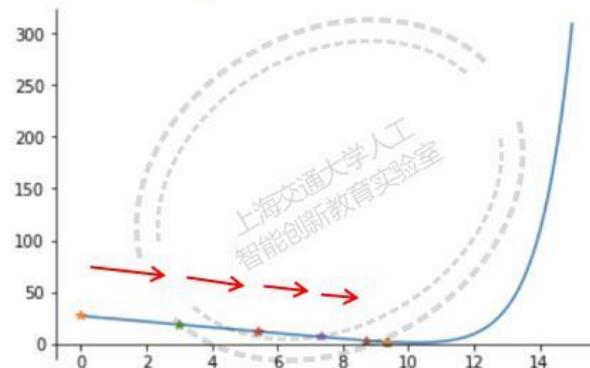
$$\text{迭代公式 } x_{n+1} = x_n - f'(x_n)$$

寻优算法—梯度下降法

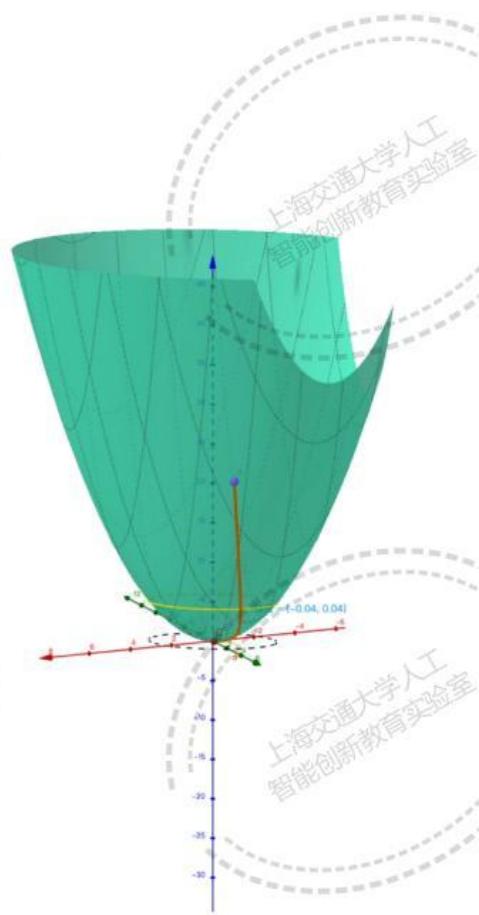
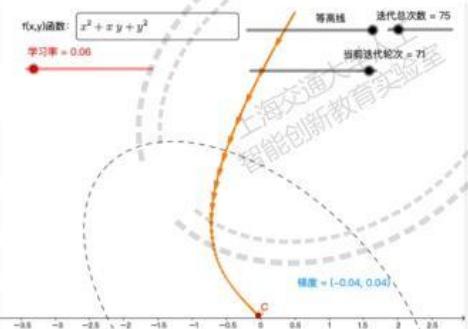
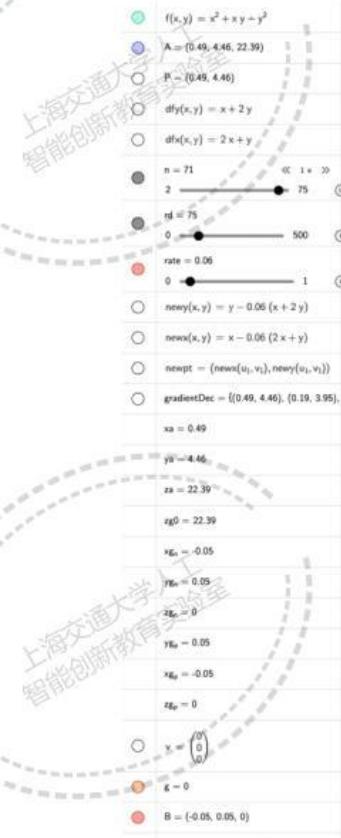
$$\min f(x) : \frac{e^x}{1000} + \frac{x^2}{10} - 3x + 27$$

梯度下降算法步骤：

1. 给定起始点 x_0 计算导数 $f'(x_0)$
2. 迭代： $x_{n+1} = x_n - f'(x_n)$
3. 重复2直至 $f'(x_n)$ 的绝对值足够小

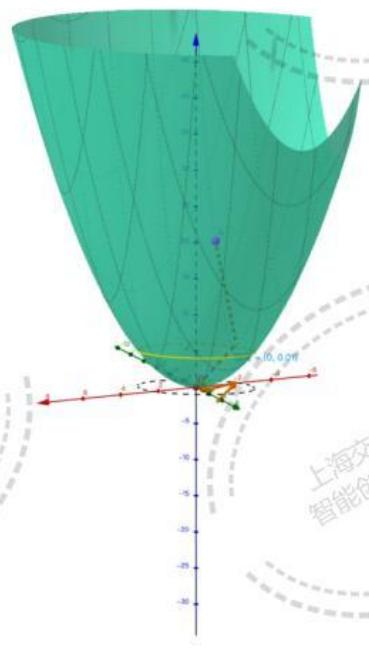
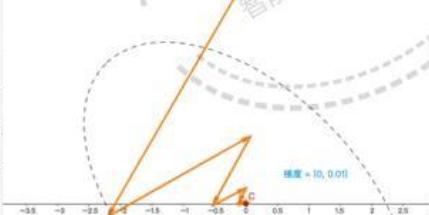


寻优算法—梯度下降法



寻优算法—梯度下降法

增大步长（学习率）的影响：震荡且收敛至最低点



寻优算法—梯度下降法

增大步长（学习率）的影响：震荡且无法收敛

上海交通大学人工智能创新教育实验室

公式输入框：
 $f(x, y) = x^2 + x \cdot y + y^2$

参数设置：
A: (0.49, 4.46, 22.39)
P: (3.49, 4.46)
 $\partial f(x, y) = x + 2y$
 $\partial^2 f(x, y) = 2x + y$

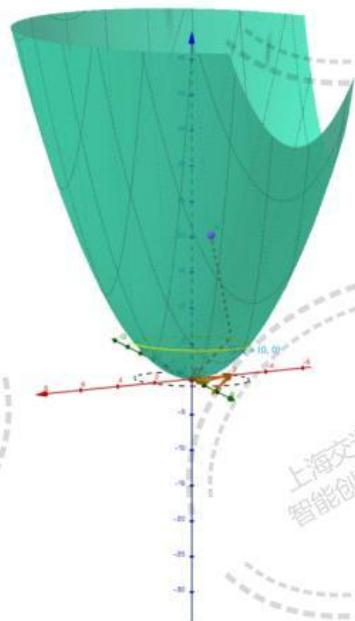
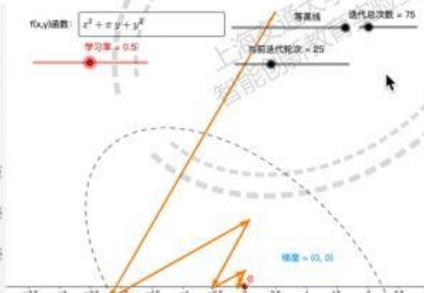
迭代参数：
k: 25
rate: 0.5
nstep: 75
nstep_max: 500

梯度下降法：
 $\text{newy}(x, y) = y - 0.5(x + 2y)$
 $\text{newx}(x, y) = x - 0.5(2x + y)$
 $\text{newnp} = [\text{newy}(u_1, v_1), \text{newx}(u_1, v_1)]$
 $\text{gradientDec} = [(0.49, 4.46), (-2.21, -0.2),$

初始值：
 $x_0 = 0.49$,
 $y_0 = 4.46$,
 $z_0 = 22.39$

梯度：
 $zg_0 = 22.39$
 $xg_0 = 0$,
 $yg_0 = 0$,
 $zg_0 = 0$,
 $xg_0 = 0$,
 $yg_0 = 0$

向量：
 $y = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$
k: 0
B: (0, 0, 0)



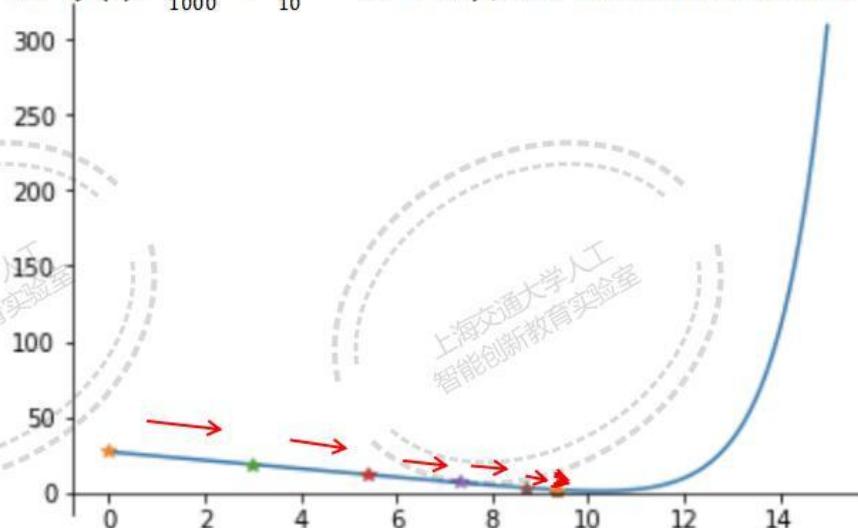
寻优算法—梯度下降法

梯度下降算法的**优点**: 计算简单

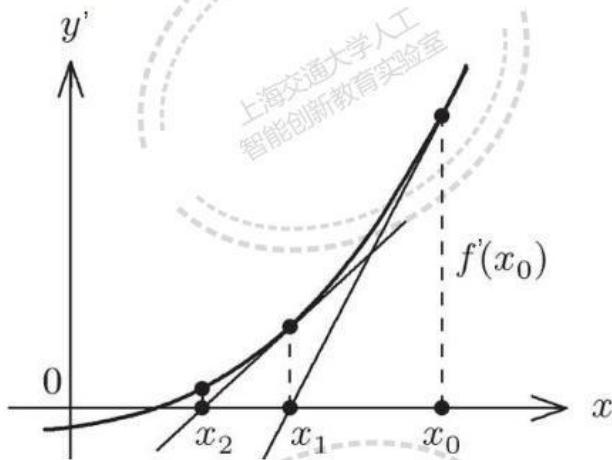
梯度下降算法的**缺点**: 梯度很小时, 迭代过于缓慢!

- $\min f(x) : \frac{e^x}{1000} + \frac{x^2}{10} - 3x + 27$ 需要迭代21次到误差小于 10^{-9}

- $\min (f(x) : \frac{e^x}{1000} + \frac{x^2}{10} - 3x + 27) / 100$ 需要迭代1684次到误差小于 10^{-9} !



寻优算法—牛顿法



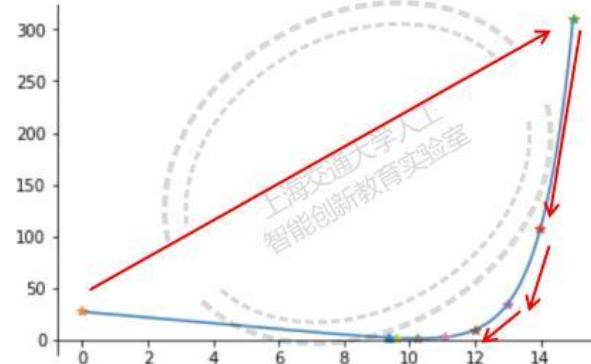
- 牛顿法就把求解函数最小值问题，转化为求解导数零点的问题
- 通过对导函数不断做切线，并找到切线与x轴交点，找到下一个迭代位置
- 迭代公式 $x_{n+1} = x_n - f'(x_n)/f''(x_n)$

寻优算法—牛顿法

$$\min f(x) : \frac{e^x}{1000} + \frac{x^2}{10} - 3x + 27$$

牛顿法步骤：

1. 给定起始点 x_0 计算导数 $f'(x_0)$, 二阶导 $f''(x_0)$
2. 迭代 $x_{n+1} = x_n - f'(x_n)/f''(x_n)$
3. 重复2直至 $f'(x_n)$ 的绝对值足够小

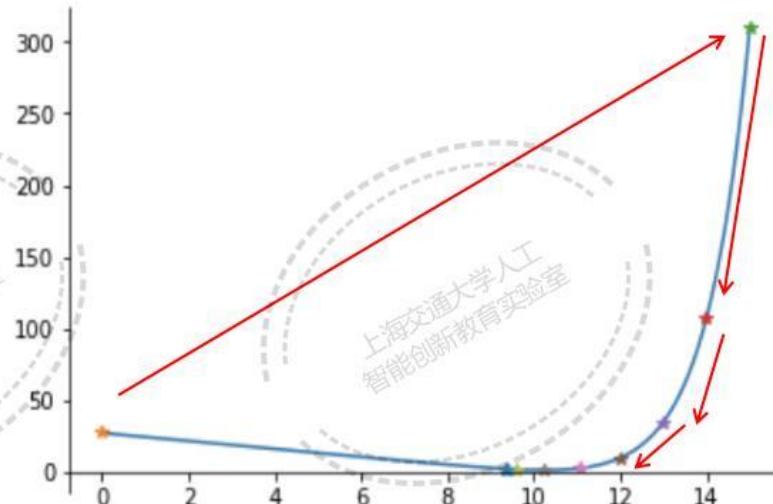


寻优算法—牛顿法

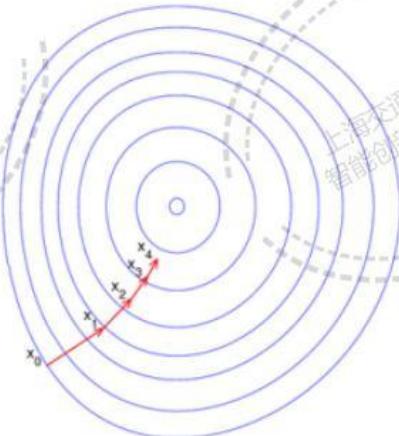
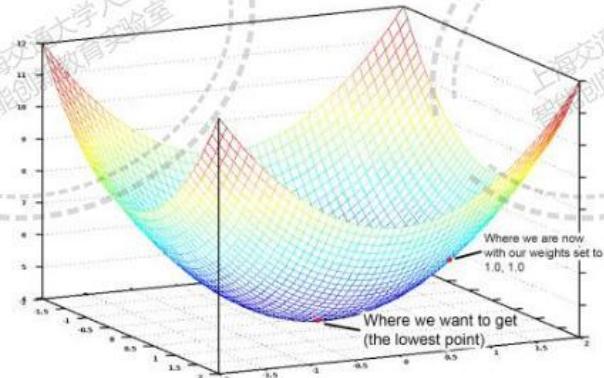
牛顿法的缺点：计算比较麻烦，需要算二阶导甚至H矩阵

牛顿法的优点：能快速通过梯度平稳区域！

- $\min f(x) : \frac{e^x}{1000} + \frac{x^2}{10} - 3x + 27$ 需要迭代10次到误差小于 10^{-9}
- $\min (f(x) : \frac{e^x}{1000} + \frac{x^2}{10} - 3x + 27) / 100$ 需要迭代9次到误差小于 10^{-9} ！



寻优算法—多维寻优



- 梯度下降法: $X_{n+1} = X_n - \nabla f(X_n)$;
- 牛顿法: $X_{n+1} = X_n - H(f(X_n))^{-1} \nabla f(X_n)$
- 多维寻优问题, 寻优算法不但可以提供迭代的距离, 也能提供前进的方向!



谢谢聆听

THANKS FOR YOUR ATTENTION