



中国科学技术大学

University of Science and Technology of China



GAMES 102在线课程

# 几何建模与处理基础

刘利刚

中国科学技术大学



中国科学技术大学  
University of Science and Technology of China



GAMES 102在线课程：几何建模与处理基础

# 数据拟合(2)



# 回顾

- 计算机图形学基本内容
- 函数、映射、变换...
- 数据拟合
  - 找哪个?
  - 到哪找?
  - 怎么找?
- 作业1: 尝试、思考、困惑、讨论、理解...
- 补充: “GAMES 102学习材料(1)”

# 假定： 函数形式


- 假定： 仅函数形式， 一般曲线（非函数形式） 后面再学习

$$f: \mathbb{R}^1 \rightarrow \mathbb{R}^1$$
$$y = f(x)$$




# 函数拟合问题

- 输入：一些观察（采样）的数据点 $\{x_i, y_i\}_{i=0}^n$
- 输出：拟合数据点的函数 $y = f(x)$ ，并用于**预测**




这种拟合函数有多少个？

# 拟合函数的“好坏”




# 拟合函数的“好坏”

- 分段线性插值函数  $y = f_1(x)$ 
  - 数据误差为0




# 拟合函数的“好坏”

- 分段线性插值函数  $y = f_1(x)$ 
  - 数据误差为0
  - 函数性质不够好：只有  $C^0$  连续，不光滑（数值计算）




# 拟合函数的“好坏”

- 光滑插值函数  $y = f_2(x)$ 
  - 数据误差为0




# 拟合函数的“好坏”

- 光滑插值函数  $y = f_2(x)$ 
  - 数据误差为0
  - 可能被“差数据”（噪声、outliers）带歪，导致函数性质不好、预测不可靠




# 拟合函数的“好坏”

- 逼近拟合函数  $y = f_3(x)$ 
  - 数据误差不为0，但足够小




# 拟合函数的“好坏”

- 逼近拟合函数  $y = f_3(x)$ 
  - 数据误差不为0，但足够小



# 拟合函数的“好坏”

- 分段线性函数  $f = f_1(x)$
- 光滑插值函数  $f = f_2(x)$
- 逼近拟合函数  $f = f_3(x)$



# 求拟合函数：应用驱动

- 大部分的实际应用问题
  - 可建模为： 找一个映射/变换/函数
  - 输入不一样、变量不一样、维数不一样
- 三步曲方法论：
  - 到哪找？
    - 确定某个函数集合/空间
  - 找哪个？
    - 度量哪个函数是好的/“最好”的
  - 怎么找？
    - 求解或优化： 不同的优化方法与技巧， 既要快、又要好...

# 数据拟合的方法论

- 到哪找?
  - 确定函数的表达形式（函数集、空间）  $L = \text{span}\{b_0(x), \dots, b_n(x)\}$
  - 待定基函数的组合系数（求解变量）  $f_\lambda(x) = \sum_{k=0}^n \lambda_k b_k(x)$
- 找哪个?
  - 优化模型（最小化问题）
    - 能量项 = 误差项 + 正则项
  - 统计模型、规划模型...
- 怎么找?
  - 求解误差函数的驻点（导数为0之处）
  - 转化为系数的方程组
    - 如果是欠定的（有无穷多解），则修正模型
      - 改进/增加各种正则项：Lasso、岭回归、稀疏正则项...
      - 返回修改模型

$f$  由待定系数  $\lambda = \begin{pmatrix} \lambda_1 \\ \dots \\ \lambda_n \end{pmatrix}$  确定

# 1. 多项式插值

# 多项式插值定理

定理：若  $x_i$  两两不同，则对任意给定的  $y_i$ ，存在唯一的次数至多是  $n$  次的多项式  $p_n$ ，使得  $p_n(x_i) = y_i, i = 0, \dots, n$ 。

证明：在幂基  $\{1, x, \dots, x^n\}$  下待定多项式  $p$  的形式为：

$$p(x) = a_0 + a_1x + a_2x^2 + \dots + a_nx^n$$

由插值条件  $p(x_i) = y_i, i = 0, \dots, n$ ，得到如下方程组：

$$\begin{pmatrix} 1 & x_0 & x_0^2 & \dots & x_0^n \\ 1 & x_1 & x_1^2 & \dots & x_1^n \\ 1 & x_2 & x_2^2 & \dots & x_2^n \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_n & x_n^2 & \dots & x_n^n \end{pmatrix} \begin{pmatrix} a_0 \\ a_1 \\ a_2 \\ \vdots \\ a_n \end{pmatrix} = \begin{pmatrix} y_0 \\ y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix}$$

如果基函数选取不一样，方程组的系数矩阵不同

系数矩阵为 Vandermonde 矩阵，其行列式非零，因此方程组有唯一解。

# 技巧1: 构造插值问题的通用解

- 构造插值问题的通用解

- 给定  $n + 1$  个点  $\{(x_0, y_0), \dots, (x_n, y_n)\}$ , 寻找一组次数为  $n$  的多项式基函数  $l_i$  使得

$$l_i(x_j) = \begin{cases} 1, & \text{若 } i = j \\ 0, & \text{若 } i \neq j \end{cases}$$

- 插值问题的解为:

$$P(x) = y_0 l_0(x) + y_1 l_1(x) + \dots + y_n l_n(x) = \sum_{i=0}^n y_i l_i(x)$$

# 一般形式

- 怎么计算多项式 $l_i(x)$ ?

- $n$ 阶多项式, 且有以下 $n$ 个根

$$x_0, x_1, x_2, \dots, x_{i-1}, x_{i+1}, \dots, x_n$$

- 故可表示为

$$l_i(x)$$

$$= C_i(x - x_0)(x - x_1) \dots (x - x_{i-1})(x - x_{i+1}) \dots (x - x_n)$$

$$= C_i \prod_{j \neq i} (x - x_j)$$

- 由 $l_i(x_i) = 1$ 可得

$$1 = C_i \prod_{j \neq i} (x_i - x_j) \Rightarrow C_i = \frac{1}{\prod_{j \neq i} (x_i - x_j)}$$

# 技巧1: 构造插值问题的通用解

- 最终多项式基函数为

$$l_i(x) = \frac{\prod_{j \neq i} (x - x_j)}{\prod_{j \neq i} (x_i - x_j)}$$

- 多项式 $l_i(x)$ 被称为**拉格朗日多项式**

## 技巧2：更方便的求解表达

- Newton插值：具有相同“导数”（差商）的多项式构造（ $n$ 阶Taylor展开）

定义：

一阶差商：

$$f[x_0, x_1] = \frac{f(x_1) - f(x_0)}{x_1 - x_0}$$

$k$  阶差商：

设  $\{x_0, x_1, \dots, x_k\}$  互不相同， $f(x)$  关于  $\{x_0, x_1, \dots, x_k\}$  的  $k$  阶差商为：

$$f[x_0, x_1, \dots, x_k] = \frac{f[x_1, \dots, x_k] - f[x_0, x_1, \dots, x_{k-1}]}{x_k - x_0}$$

所以 Newton 插值多项式表示为：

$$N_n(x) = f(x_0) + f[x_0, x_1](x - x_0) + \dots + f[x_0, x_1, \dots, x_n](x - x_0) \cdots (x - x_{n-1})$$

# 多项式插值存在的问题

- 系统矩阵稠密
- 依赖于基函数选取，矩阵可能病态，导致难于求解（求逆）

# 病态矩阵示例

- 考虑二元方程组
  - 解为(1,1)

$$\begin{aligned}x_1 + 0.5x_2 &= 1.5 \\0.667x_1 + 0.333x_2 &= 1\end{aligned}$$

- 对第二个方程右边项扰动0.001
  - 解为(0,3)

$$\begin{aligned}x_1 + 0.5x_2 &= 1.5 \\0.667x_1 + 0.333x_2 &= 0.999\end{aligned}$$


- 对矩阵系数进行扰动
  - 解为(2,-1)

$$\begin{aligned}x_1 + 0.5x_2 &= 1.5 \\0.667x_1 + 0.334x_2 &= 1\end{aligned}$$


# 病态问题

- 输入数据的细微变化导致输出(解)的剧烈变化
- 将线性方程看成直线（超平面）
  - 当系统病态时，直线变为近似平行
  - 求解（即直线求交）变得困难、不精确



# 矩阵条件数

$$\kappa_2(A) = \frac{\max_{x \neq 0} \frac{\|Ax\|}{\|x\|}}{\min_{x \neq 0} \frac{\|Ax\|}{\|x\|}}$$

- 等于最大特征值和最小特征值之间比例
- 条件数大意味着基元之间有太多相关性


# 矩阵条件数

- 多项式插值问题是病态的
  - 对于等距分布的数据点 $x_i$ ，范德蒙矩阵的条件数随着数据点数 $n$ 呈指数级增长（多项式的最高次数为 $n - 1$ ）



# 为什么？

- 幂（单项式）函数基
  - 幂函数之间差别随着次数增加而减小
  - 不同幂函数之间唯一差别为增长速度( $x^i$ 比 $x^{i-1}$ 增长快)



幂(单项式) 函数


# 函数互相抵消

- 单项式：

- 从左往右
- 首先常函数1主宰
- 接着 $x$ 增长最快
- 接着 $x^2$ 增长最快
- 接着 $x^3$ 增长最快
- ...


- 趋势

- 好的基函数一般需要系数交替
- 互相抵消问题





# 解决方法

- 使用正交多项式基
- 如何获得?
  - Gram-Schmidt正交化



# 多项式插值结果好吗？



**振荡(龙格Runge)现象和对插值点数的高度敏感性**  
**观察  $n = 9$  (10个数据点) 和  $n = 10$  (11个数据点) 的差别**

# 结论

- 多项式插值不稳定
    - 控制点的微小变化可导致完全不同的结果
  - 振荡(Runge)现象
    - 多项式随着插值点数(可以是细微)增加而摆动
- ➔ 需要更好的基函数来做插值
- Bernstein基函数?
  - 分片多项式?

## 2. 多项式逼近


# 为什么逼近?

- 数据点含噪声、outliers等
- 更紧凑的表达
- 计算简单、更稳定

# 最小二乘逼近

- 逼近问题

- 给定一组线性无关的连续函数集合  $B = \{b_1, \dots, b_n\}$  和一组结点  $\{(x_1, y_1), \dots, (x_m, y_m)\}$ , 其中  $m > n$
- 在  $B$  张成空间中哪个函数  $f \in \text{span}(B)$  对结点逼近最好?
- 示例: 给定一组点, 找到最佳逼近的线性函数
- 怎么定义“最佳逼近”?




# 最佳逼近的定义

- 最小二乘逼近

$$\operatorname{argmin}_{f \in \operatorname{span}(B)} \sum_{j=1}^m (f(x_j) - y_j)^2$$

$$\begin{aligned} \sum_{j=1}^m (f(x_j) - y_j)^2 &= \sum_{j=1}^m \left( \sum_{i=1}^n \lambda_i b_i(x_j) - y_j \right)^2 \\ &= (M\lambda - y)^T (M\lambda - y) \\ &= \lambda^T M^T M \lambda - y^T M \lambda - \lambda^T M^T y + y^T y \\ &= \lambda^T M^T M \lambda - 2y^T M \lambda + y^T y \end{aligned}$$



$$M = \begin{pmatrix} b_1(x_1) & \dots & b_n(x_1) \\ \dots & \dots & \dots \\ b_1(x_m) & \dots & b_n(x_m) \end{pmatrix}$$

# 求解

- 关于 $\lambda$ 的二次多项式

$$\lambda^T M^T M \lambda - 2y^T M \lambda + y^T y$$

- 法方程

- 最小解满足

$$M^T M \lambda = M^T y$$

- 提示

- 最小化二次目标函数  $x^T A x + b^T x + c$
- 充分必要条件:  $2Ax = -b$

### 3. 函数空间及基函数

# 为什么用多项式？

- 易于计算，表现良好，光滑， ...
- 稠密性与完备性：**表达能力足够！**
  - 魏尔斯特拉斯Weierstrass定理：令 $f$ 为闭区间 $[a, b]$ 上任意连续函数，则对任意给定 $\varepsilon$ ，存在 $n$ 和**多项式** $P_n$ 使得
$$|f(x) - P_n(x)| < \varepsilon, \forall x \in [a, b]$$
  - Weierstrass只证明了存在性，未给出多项式







# 用Bernstein多项式做逼近

- 伯恩斯坦Bernstein给出了构造性证明（强大!）
  - 对 $[0, 1]$ 区间上任意连续函数 $f(x)$ 和任意正整数 $n$ ，以下不等式对所有 $x \in [0, 1]$ 成立

$$|f(x) - B_n(f, x)| < \frac{9}{4} m_{f,n}$$

- $m_{f,n} = \text{lower upper bound } |f(y_1) - f(y_2)|$   
 $y_1, y_2 \in [0, 1] \text{ 且 } |y_1 - y_2| < \frac{1}{\sqrt{n}}$
- $B_n(f, x) = \sum_{j=0}^n f(x_j) b_{n,j}(x)$ ，其中 $x_j$ 为 $[0, 1]$ 上等距采样点
- $b_{n,j} = \binom{n}{j} x^j (1-x)^{n-j}$ 为Bernstein多项式


# Bernstein 多项式



- $b_{0,0}(x) = 1$
- $b_{0,1}(x) = 1 - x$ ,  $b_{1,1} = x$
- $b_{0,2}(x) = (1 - x)^2$ ,  $b_{1,2} = 2x(1 - x)$ ,  $b_{2,2} = x^2$
- $b_{0,3}(x) = (1 - x)^3$ ,  $b_{1,3} = 3x(1 - x)^2$ ,  $b_{2,3} = 3x^2(1 - x)$ ,  $b_{3,3} = x^3$
- $b_{0,4}(x) = (1 - x)^4$ ,  $b_{1,4} = 4x(1 - x)^3$ ,  $b_{2,4} = 6x^2(1 - x)^2$ ,  $b_{3,4} = 4x^3(1 - x)$ ,  $b_{4,4} = x^4$

# 用Bernstein多项式做逼近



- Bernstein基函数的美好性质：非常好的几何意义！
  - 正性、权性（和为1） $\rightarrow$ 凸包性
  - 变差缩减性
  - 递归线性求解方法
  - 细分性
  - ...
- Bernstein多项式逼近示例
  - 逼近结果优秀
  - 需要高阶



丰富的理论：CAGD课程

# 关于Bernstein函数...

- $B_n(f, x) = \sum_{j=0}^n f\left(\frac{j}{n}\right) b_{n,j}(x)$
- 两种观点：
  - 几何观点、代数观点



丰富的理论：CAGD课程


## 4. RBF函数插值/逼近

# Gauss函数

- 两个参数：均值 $\mu$ ，方差 $\sigma$

$$g_{\mu,\sigma}(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

- 几何意义：
  - 均值 $\mu$ ：位置
  - 方差 $\sigma$ ：支集宽度



- 不同均值和方差的Gauss函数都线性无关
  - 有什么启发?

# RBF函数拟合


- RBF函数

$$f(x) = b_0 + \sum_{i=1}^n b_i g_i(x)$$


- 方法

- 原因


# 讨论：现象




$\sigma = 0.1$



$\sigma = 1$





$\sigma = 5$



$\sigma = 10$

# 讨论：现象




思考：

- 均值 $\mu$ 和方差 $\sigma$ 是否可以一起来优化？

$$g_{\mu,\sigma}(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

$$f(x) = b_0 + \sum_{i=1}^n b_i g_i(x)$$

- 问题？



## 5. 从另一个角度来看拟合函数

# Gauss拟合函数

- 一般Gauss函数表达为标准Gauss函数的形式


$$g_{\mu,\sigma}(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2} = g_{0,1}(ax + b)$$

$$a = \frac{x}{\sigma}, b = -\frac{\mu}{\sigma}$$

$$f(x) = b_0 + \sum_{i=1}^n b_i g_i(x)$$


$$f(x) = \omega_0 + \sum_{i=1}^n \omega_i \underline{g_{0,1}(a_i x + b_i)}$$

基函数是由一个基本函数通过平移和伸缩变换而来的




# 换个方式看函数：神经网络

- 将Gauss函数看成网络  $f(x) = \omega_0 + \sum_{i=1}^n \omega_i g_{0,1}(a_i x + b_i)$



# 抽象：神经元



# RBF 神经网络


- 高维情形： RBF (Radial Basis Function), 径向基函数
- 一种特殊的BP网络
  - 优化： BP算法
- 核函数思想
- Gauss函数的特性： 拟局部性

# 思考：激活函数的选择？

- 启发：由一个简单的函数通过（仿射）变换构造出一组基函数，张成一个函数空间
- 表达能力是否足够强：是否完备/稠密的？


## Sigmoid

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




## tanh

$$\tanh(x)$$




## ReLU

$$\max(0, x)$$



## Leaky ReLU

$$\max(0.1x, x)$$




## Maxout

$$\max(w_1^T x + b_1, w_2^T x + b_2)$$

## ELU

$$\begin{cases} x & x \geq 0 \\ \alpha(e^x - 1) & x < 0 \end{cases}$$



# 高维情形：多元函数

(后面的课程再展开解释)

- 变量的多个分量的线性组合



$$(x_1, x_2, \dots, x_n) \longrightarrow g_{0,1}(a_1^i x_1 + a_2^i x_2 + \dots + a_n^i x_n + b_i)$$

- 单隐层神经网络函数：

$$f(x_1, x_2, \dots, x_n) = \omega_0 + \sum_{i=1}^n \omega_i g_{0,1}(a_1^i x_1 + a_2^i x_2 + \dots + a_n^i x_n + b_i)$$


# 多层神经网络：多重复合的函数

- 线性函数和非线性函数的多重复合



Neuron

$$h_{W,b}(x) = f(W^T x) = f(\sum_{i=1}^3 W_i x_i + b)$$



Neural network


$$a_1^{(2)} = f(W_{11}^{(1)} x_1 + W_{12}^{(1)} x_2 + W_{13}^{(1)} x_3 + b_1^{(1)})$$

$$a_2^{(2)} = f(W_{21}^{(1)} x_1 + W_{22}^{(1)} x_2 + W_{23}^{(1)} x_3 + b_2^{(1)})$$

$$a_3^{(2)} = f(W_{31}^{(1)} x_1 + W_{32}^{(1)} x_2 + W_{33}^{(1)} x_3 + b_3^{(1)})$$

$$h_{W,b}(x) = a_1^{(3)} = f(W_{11}^{(2)} a_1^{(2)} + W_{12}^{(2)} a_2^{(2)} + W_{13}^{(2)} a_3^{(2)} + b_1^{(2)})$$

# 用神经网络函数来拟合数据



Regression problem:

Input: Given training set  $(x_1, y_1), (x_2, y_2), (x_3, y_3), \dots$


Output: Adjust **parameters  $\theta$**  (for every node) to make:

$$h(x_i) \approx y_i$$

# Why it works?

- 万能逼近定理：自由度足够多！

$$F(\mathbf{x}) = \sum_{i=1}^N v_i \varphi(\mathbf{w}_i^T \mathbf{x} + b_i)$$




与传统拟合一样存在同样的问题：  
函数个数如何选择？！

调参！

# Deep Learning Frameworks



DL4J Deep Learning for Java



theano



dmlc  
**mxnet**

Caffe



NVIDIA DIGITS




Lasagne

# 使用深度学习的方法

- 问题建模
  - 理解问题、问题分解（多个映射级联）...
- 找哪个？
  - 损失函数、各种Penalty、正则项...
- 到哪找？
  - 神经网络函数、网络简化...
- 怎么找？
  - 优化方法（BP方法）
  - 初始值、参数...

**调参：有耐心、有直觉...**



# 未来课程内容

- 全局函数→局部函数
  - 样条函数
- 多元函数→一般曲线
  - 参数曲线、参数域为本征维数
- 隐函数
- 曲线设计
  - 计算机辅助几何设计
- 曲面设计
  - 张量积的参数曲面

# 作业1情况

- 作业1情况
  - 演示优秀demo
  - 优秀代码和优秀报告
- 其他学员可以继续完成提交
  - 可参照优秀作业尽快完成，赶上大部队

# 作业2

- 任务
  - 使用RBF神经网络函数来拟合数据
    - 仍限制在函数情形
  - 与作业1的方法进行比较
- 目的
  - 理解神经网络优化
  - 学习使用TensorFlow来优化
- 要求
  - 推荐使用无境框架：后面的网格处理较方便
    - Windows, VS2019, DirectX, 显卡要求
  - 可以使用其他语言(Matlab, Python等)或其他框架
- Deadline: **2020年10月24日晚**



中国科学技术大学  
University of Science and Technology of China

谢谢！