


浅议现代信号分析
Modern Signal Processing
框架、应用与思考



桥梁振动控制与健康监测教研室
2017级硕士 简旭东

何为信号分析?

信号分析的最终目标：提取信号特征，解读特征中的信息


如果把信号比作一份加密的情报，信号分析就是破译这份情报

如何破译？信号建模

MORSE CODE LETTERS AND NUMBERS

A ·—	K —·—	U ··—	1 ·— — — —
B —···	L ····	V ···—	2 ·· — — —
C —·—·	M — —	W ·— —	3 ·· — — —
D —··	N —·	X —··—	4 ··· — —
E ·	O — — —	Y —· — —	5 ·····
F ·· — ·	P · — — ·	Z — — ··	6 — ····
G — — ·	Q — — ··		7 — —···
H ····	R ·· — ·		8 — — —··
I ··	S ···		9 — — — ··
J · — — —	T —		0 — — — — —

MORSE电码：解码与组合，得到电报




时域脉冲基函数

Fourier变换对

频域谐波基函数

信号分析问题的框架


基于上述，信号分析的**核心任务**就是**信号建模**，**选择模型种类**就是信号分析的**正问题**。



脉冲模型
时域脉冲基函数

Fourier变换对

谐波模型
频域谐波基函数




$$\hat{f}(t) = \sum_{i=1}^n \alpha_i x_i(t)$$

求解信号模型的系数就是信号分析的**反问题**


$$\min [f(t) - \hat{f}(t)]$$

反问题的**着眼点**是使模型与真实信号之间**误差最小**

何为“现代”信号分析?



大自然肯定是随机的



经典信号分析——确定信号分析 → 现代信号分析——随机信号分析

	经典信号分析	现代信号分析
特点	信号确定，因此信号模型参数确定	信号是随机过程，因此信号模型参数是随机变量
方法	时域卷积运算、频域Fourier分析	在确定信号分析的基础上补充参数估计
核心数学知识	复变函数（积分变换）	随机过程（估计）、泛函分析（优化）


随机信号与系统基本理论

一阶统计量：随机信号的数学期望

二阶统计量	定义	特点	含义
自（互）相关函数	略	时域	信号在时域上的相关性
自（互）协方差函数			
互相关函数			
自（互）功率谱函数		频域	信号在频域上的能量分布
自（互）功率谱密度			
相干函数			

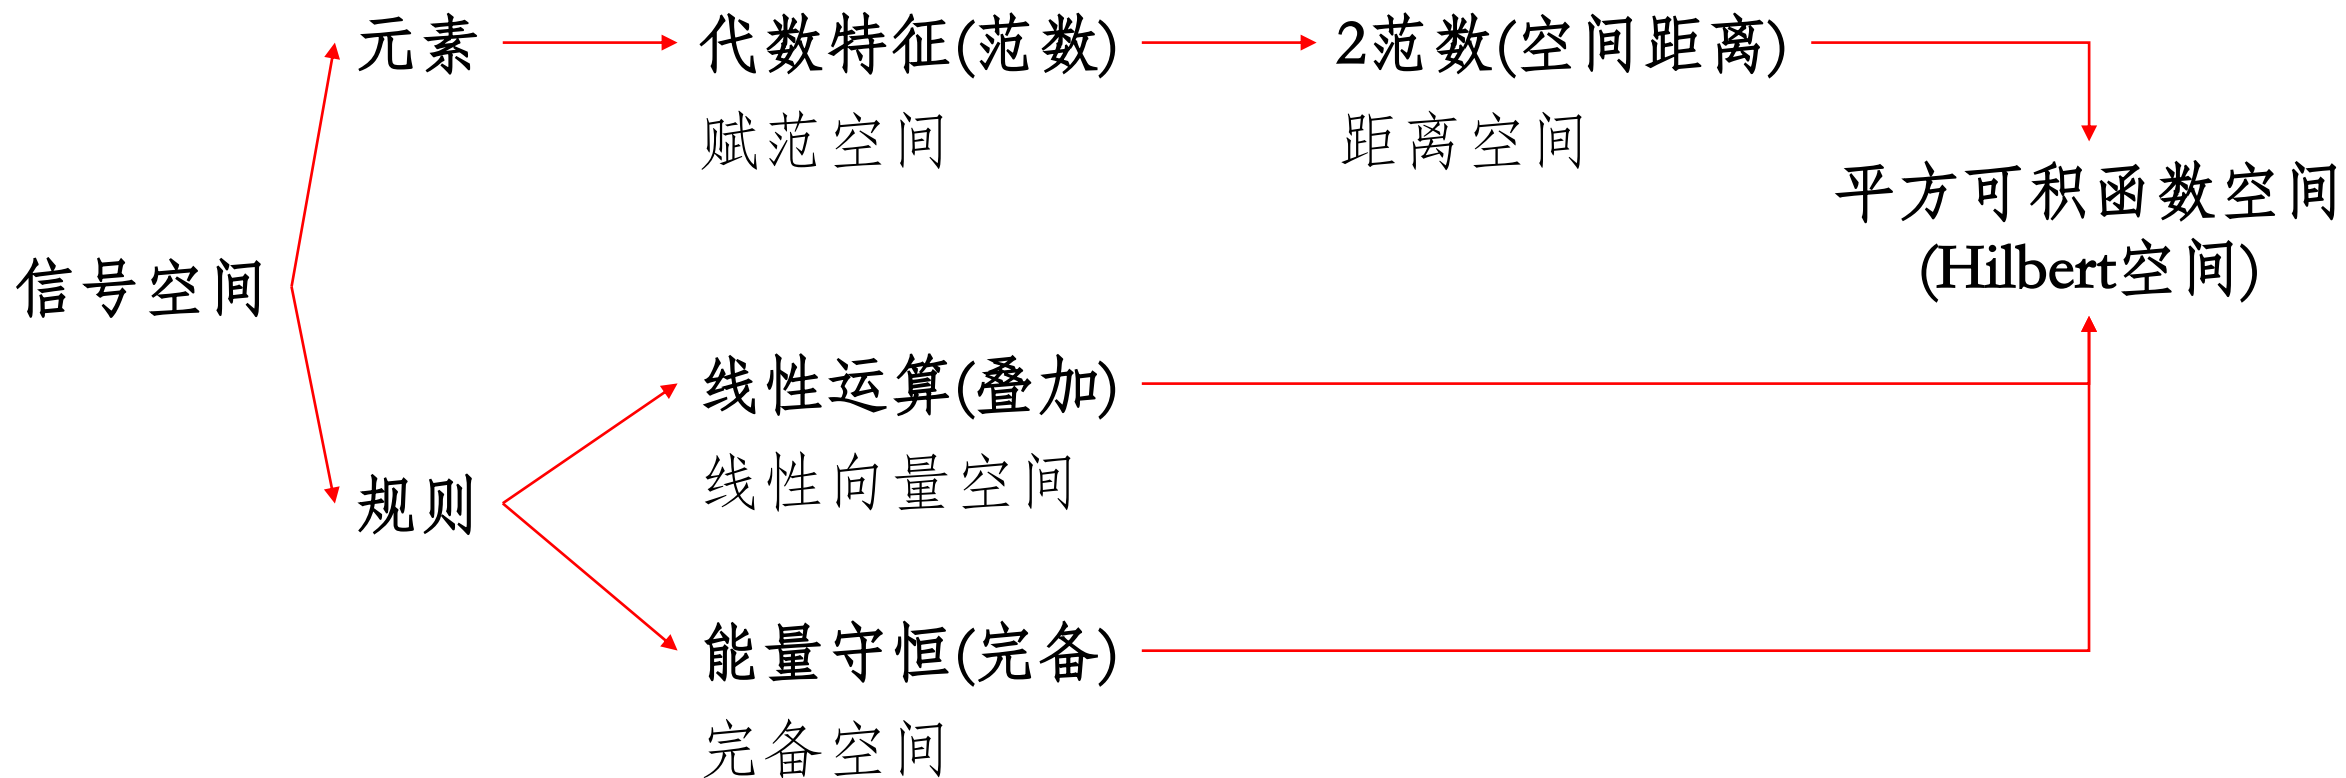
在此基础上定义广义平稳信号（即二阶平稳）、均方遍历信号、独立信号、相关信号、正交信号

早期的随机信号分析理论，是建立在“**平稳、Gauss、线性**”的假设之上的



如何选取基函数？如何求解基函数系数？


$$\|\mathbf{X}\|_2 := \sqrt{x_1^2 + \cdots + x_n^2}$$



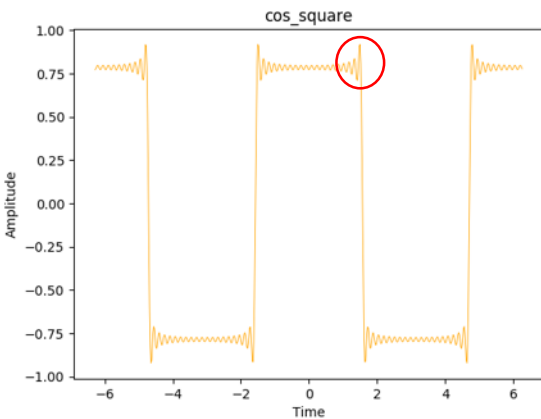
一组好的基函数应该有的特点：精度高的同时，数量要少

精度高：基函数要能够体现信号的特征

数量少：基函数之间的冗余信息越少越好



FT



$$f(a) + \frac{f'(a)}{1!}(x-a) + \frac{f''(a)}{2!}(x-a)^2 + \frac{f'''(a)}{3!}(x-a)^3 + \dots$$

Fourier变换：特征与方波不符，拟合时存在Gibbs现象 Taylor级数：不同基函数之间关联性强，冗余信息多

平方可积函数空间内的信号分析：利用特征向量彻底解相关——KL变换

参数估计理论——求解最优信号模型

描述随机信号的基本数学模型是**概率密度函数**(Probability Density Function)
估计概率密度函数中的**统计量**(比如期望和方差)是参数估计的基本任务

有必要求信号模型的PDF吗? 当然有。

能够求得信号模型的PDF吗? 困难, 因为试验次数有限(当然现在的SHMS可以进行很多次试验)。


所以, 一般假设随机参数服从**Gauss分布**, 原因有三: 大数定律; Gauss线性; 单峰分布
那么随机信号参数估计就退化为, 利用**最优化方法**寻找**代价泛函最小**的Gauss模型参数, 即期望与方差

如何定义最优?

① 无偏性: $b(\hat{\theta}) = E\{\hat{\theta}\} - \theta = 0$

② 一致性: $\min\{var(\hat{\theta})\}$

这样的最优估计方法就叫做**Bayes估计**



Bayes估计：首先定义损失函数 $C(\theta, \hat{\theta})$ ，即估计值与真实值之间的误差。
然后定义风险函数 $R(\theta, \hat{\theta}) = E\{C(\theta, \hat{\theta})\}$ 。Bayes估计就是使风险函数R最小的估计。

根据风险函数定义的不同，Bayes估计的具体形式可以分为：

- ① 最小均方误差方法，Minimum Mean Square Error, MMSE
- ② 最大后验概率估计，Maximum of the A Posterior Density, MAP
- ③ 最大似然估计，Maximum Likelihood, ML
- ④ 线性均方估计，Linear Mean Squares, LMS
- ⑤ 最小二乘估计，Least Square, LS
- ⑥ 加权最小二乘估计，Weighted Least Square, WLS

以上方法均基于Bayes估计思想

可操作性是逐渐提高的，即①最不好操作，⑥最好操作。因为物理意义越来越明确。
数学上的严谨性是逐渐退化的，即①最严谨，⑥最不严谨。

工程师的方法：LMS/LS，模型驱动 \longleftrightarrow 统计学家的方法：ML，纯数据驱动
为机器学习和大数据分析埋下了伏笔

$$\text{观测信号} = \text{理想信号} + \text{噪声}$$

↑
滤波器

所谓最佳滤波，就是基于参数估计理论对信号进行最佳建模，然后减去噪声。美国应用数学家Wiener最早提出，使用线性均方(LMS)方法对Gauss平稳随机信号进行最优滤波器的参数估计，此时最佳滤波可以被称为Wiener滤波。

$$\hat{\theta}_{LMS} = \sum_{i=1}^N w_i x_i \longrightarrow J = E \left\{ (\hat{\theta} - \theta)^2 \right\} \longrightarrow \frac{\partial J}{\partial w_k} = 0 \longrightarrow [w_k]$$

- ①需要用到全局二阶统计量：协方差矩阵 $C_{xx}(\tau) = E\{[x(t) - \mu_x][x(t - \tau) - \mu_x]^*\}$
- ②需要用求极值的方法来求最值
- ③这一套求最优系数 w_k 的方法其实就是神经网络的思想源泉

Wiener滤波有以下缺陷：

①需要用到二阶统计量：信号不平稳，二阶统计量是变量怎么办？

针对这个问题，一般来说，信号的非平稳性是有限的(否则就没有研究价值)，这时可认为信号是局部平稳的，在此假设下，匈牙利裔美国电气工程师Kalman提出Kalman滤波，实现局部最佳滤波。

Kalman滤波：线性AR模型。递推迭代，每一时刻都用观测新信息修正预测模型。其优势在于用每个局部的最优实现全局的最优（类似有限元的思想）。当信号平稳时，Kalman滤波可以退化为Wiener滤波。

$$\mathbf{x}_k = \mathbf{F}_k \mathbf{x}_{k-1} + \mathbf{B}_k \mathbf{u}_k + \mathbf{w}_k$$

经修正的
k时刻预测

k-1时刻
物理模型的预测

k时刻
观测值的修正

噪声

Kalman滤波的成名之战：NASA主导的Apollo登月

Wiener滤波有以下缺陷：

②需要知道响应的全局协方差矩阵，这样的先验知识很难获取的，因此不便于应用

针对这个问题，提出了自适应滤波器。自适应滤波器以期望响应为“导师”，输入信号通过滤波器输出对期望响应进行估计，递推更新滤波器系数，**梯度下降**，不断降低误差，最后得到一组逼近最优滤波器的滤波器系数 w_{k_opt} 。


如果信号是弱非平稳的，且非平稳变换速率慢于自适应滤波器的学习速率，此时自适应滤波器还能自适应地跟踪这种**非平稳变化**。

形象地说，就是用“**边走边看**”取代“**一劳永逸**”

自适应滤波器就是B-P人工神经网络的**雏形!!!**

自适应滤波器的经典应用：

主动振动控制、主动降噪耳机（干扰抵消）





最佳滤波与自适应滤波——最优估计理论的经典应用

Wiener滤波有以下缺陷：

③需要用求极值的方法来求最值：代价函数的分布非Gauss，不是单峰怎么办？

针对这个问题，需要放弃Gauss假设，引入高阶统计量。



谱：换一个角度，从频域考量信号。

经典的谱分析方法基于Wiener-Khinchin定理，直接对随机信号进行谱分析完全没有用上参数估计理论，因此也叫非参数化谱估计

$$R_X(\tau) = \frac{1}{2\pi} \int_{-\infty}^{\infty} P_X(\omega) E^{j\omega\tau} d\omega \xleftrightarrow{\text{Fourier变换对}} P_X(\omega) = \int_{-\infty}^{\infty} R_X(\tau) e^{-j\omega\tau} d\tau$$


时域 频域

经典谱分析方法的缺陷：


①周期图法的弊端：渐进无偏，分辨率低

②为减小泄露，必须加窗函数，非常繁琐

离散时域




周期频域



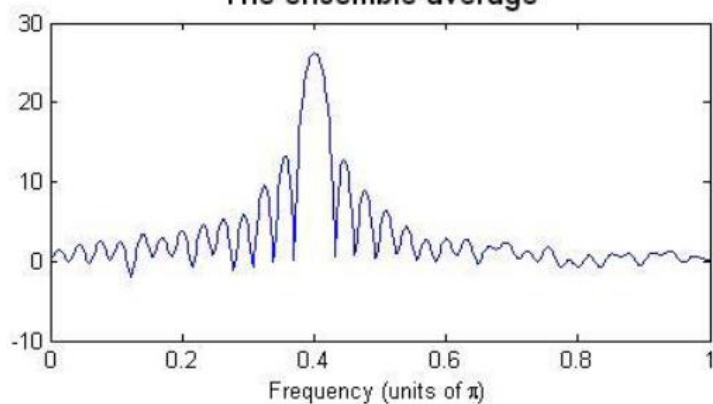
矩形窗、三角窗、Hamming窗、Hann窗、Barlett窗、Blackman窗、Chebyshev窗、Gauss窗、Kaiser窗、Bohman窗……




③非一致性：谱估计的方差并不是0




The ensemble average



$N = 128$



The ensemble average



$N = 512$

我们在进行功率谱分析时经常可以发现
增大 N ，分辨率提高，但同时方差增大，毛刺增多
这是经典谱分析不可调和的矛盾


现代谱估计——稳、准、狠

怎么克服经典谱分析的弊端？现代谱估计

现代谱估计：利用参数估计理论（所以这一方法也叫参数化谱估计），对信号进行建模。那么就可以将观测信号划分为理想信号与噪声，然后只对理想信号进行谱分析。

参数化谱估计具有一致性，且其分辨率要显著高于非参数化谱估计，因为该方法进行了滤波降噪。唯一的不足是计算速度稍慢，但这不是问题。

基于时域模型	基于频域特征空间模型
AR模型谱估计	Pisarenko谐波分解
MA模型谱估计	ESPRIT算法
ARMA模型谱估计	MUSIC算法
	CLEAN算法
	扩展Prony方法



高阶谱估计——通向新世界的大门

前面的理论框架基于以下假设：

- ① 信号模型中的系统是**线性**且**最小相位**的
- ② 噪声是**Gauss**白噪声
- ③ 噪声与信号**统计无关**

由此推导出的基于二阶统计量的方法具有以下特点：

- ① 把随机序列视为一系列统计不相关的谐波分量的**叠加**（线性系统）
- ② 各谐波之间**相位**不耦合（FT也有相位谱？），因此完全不能分析相位耦合问题
- ③ 只使用**二阶**统计量（Gauss模型最高只有二阶统计量）

实际问题显然要复杂得多：

- ① 经过塑性材料的信号是**非线性**的！事实上自然界很少有线性行为。
- ② 通过界面反射的信号与原始信号之间是**相位耦合**的！系统是**非最小相位**的！
- ③ 自然界不存在真正的Gauss白噪声，噪声基本都是**非Gauss**的！

所以说，基于二阶统计量的信号分析方法，从**根本上就不可能**准确地分析复杂问题！

二阶统计量只能刻画信号的主干，高阶统计量才能刻画信号的细节！

所以说二阶统计量叫“相关”而不是“相同”！

当然，也不是说刻画信号细节一定需要高阶统计量，Gauss信号只存在二阶统计量，但遗憾的是，我们的世界并不是Gauss的。

$$c_1(0) = m_1 = E[x] \quad \text{一阶}$$

$$c_2(\tau_1) = m_2 - m_1^2 = E[(x - m_1)^2] \quad \text{二阶}$$

$$c_3(\tau_1, \tau_2) = m_3 - 3m_1m_2 + 2m_1^3 = E[(x - m_1)^3] \quad \text{三阶}$$

$$c_4(\tau_1, \tau_2, \tau_3) = m_4 - 3m_2^2 - 4m_1m_3 + 12m_1^2m_2 - 6m_1^4 \neq E[(x - m_1)^4] \quad \text{四阶}$$

.....


当 $\tau_1 = \tau_2 = \tau_3 = 0$ 时，特别称：

- ① $c_1(0)$ 为期望，描述了概率分布的中心
- ② $c_2(0)$ 为方差，描述了概率分布的离散程度
- ③ $c_3(0,0)$ 为斜度，描述了概率分布的不对称程度
- ④ $c_4(0,0,0)$ 为峭度，描述了概率分布的尖锐程度？

事实上，阶数越高，物理意义越不明确（类似于空间维度）

将Wiener-Khinchin定理推广到高阶统计量，就可以得到高阶谱

- ① 二阶谱即功率谱，是单个频率的谱
- ② 三阶谱称为双谱，是两个频率的谱（复函数，因此能够体现相位耦合）
- ③ 四阶谱称为三谱，是三个频率的谱



基于高阶统计量的特点，它可以有以下应用：

- ① 定量辨识非Gauss程度：高阶统计量越大，非Gauss性越强
- ② 定量辨识非线性程度：利用Gauss信号通过线性系统仍然是Gauss的这一特点。
- ③ 定量辨识非最小相位程度与相位耦合程度：高阶统计量越大，相位耦合程度越高。
- ④ 分离高斯信号：高斯信号的高阶统计量为0。
- ⑤ 探明信号的空间特征：相位信息与空间信息密切相关（是否可以损伤定位？）。

高阶统计量的研究属于学科前沿，理论都还不成熟，更谈不上应用。

总结——现代信号分析学科的既有框架与未来

框架	说明	研究现状
随机信号与系统基本理论	使用二阶统计量描述随机信号	成熟
信号空间与KL变换	从数学上定义现代信号处理问题的范畴	
参数估计理论	随机信号参数的最优估计	
最佳滤波与自适应滤波	最优估计得到最优信号模型，完成最佳滤波	
现代谱估计	在频域分析中引入估计理论	
高阶谱估计	引入高阶统计量，更精准地刻画随机信号	学科前沿
时频分析 (小波分析、HHT)	现代信号分析II的内容，尚未学习	
主分量分析		
统计学习 (机器学习、大数据)		
神经网络，强非线性深度学习		
.....		

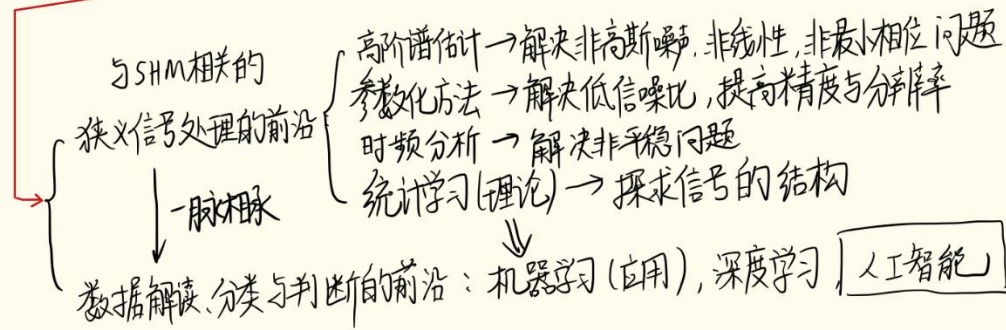
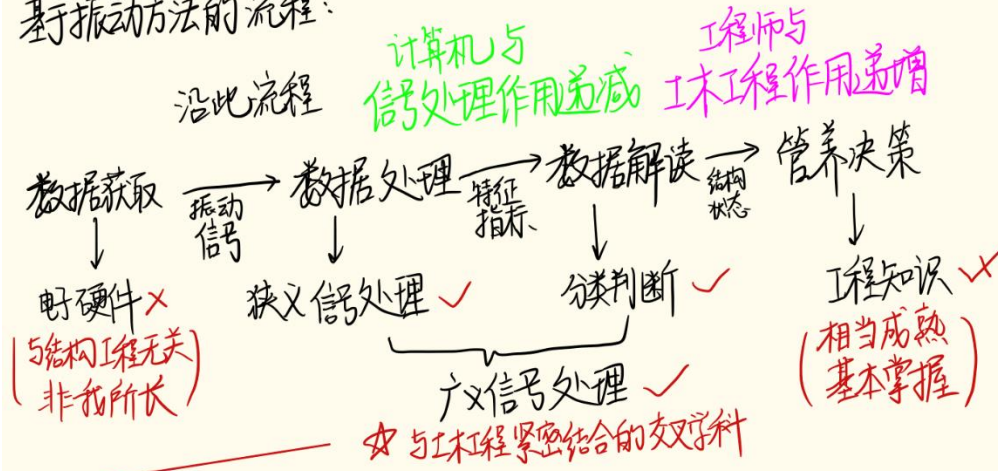
现代信号分析与桥梁健康监测

2018.2.3 关于信号与 SHM 的思考

SHM 根本任务: 损伤识别与定位

SHM 基本方法: 基于振动的方法 (还有其他的吗?)

基于振动方法的流程:



SHM 痛点

- 信噪比相对低 (相对于机械)
- 非线性 (损伤)
- 时变 (性能退化) 非平稳
- 冗余信息多, 探伤如同“大海捞针”

结论: 最新的信号处理技术有很多在 SHM 上应用的可能!

这些痛点不是只靠传感器发展就能解决的!

敬请指正