

## 悪条件問題における正則化パラメータの決定法

北川高輔(愛媛大・理)

## 1. 悪条件問題の所在

近年、悪条件問題の重要性が広く認められる様になり、研究を中心として多くの研究者に注目される。悪条件問題に関する国際的シンポジウムも、Ake Björck (Linköping Univ. Sweden 1977), M.J. Nashed (Delaware 1979) 等によく開催されている。

多くの主要な問題の Source は以下の二つに大別できると思われる。

## 1.1. 不適切問題 (Ill-posed Problems)

(又は Incorrectly-posed Problems, Improperly-posed Problems.)

この問題の class は、問題の解がデータの連続性を反映しない、即ち線型作用素方程式  $Kf = g$  ( $K \in [X, Y]$ ,  $X, Y : \text{Hilbert}$ ,  $f \in X$ ,  $g \in Y$ ) の operator  $K$  の逆作用素  $K^{-1}$  が不連続である事による特徴づけられる。数学的諸問題のうち、この class に属するもの代表例として以下のようなものがあげられる。

a) 関数の微分

b) 解析関数の解析接続 (Analytic continuation of a function)

c) 逆熱伝導問題 (The backward heat equation.)

d) デリクレ問題 (Dirichlet type boundary value problem)

e) ラプラス逆変換 (Inversion of the Laplace transform)

これらの問題は、左 2 第一種フレドホルム型積分方程式

$$K(f)(s) = \int_a^b R(s,t) f(t) ds = g(t) \quad (1)$$

に帰着される事が多い。左と元げの関数  $g(t)$  の  $n$  階微分を求める事は、オーバー積分方程式

$$\int_0^t \frac{1}{(n-1)!} (t-s)^{n-1} f(s) ds = g(t) \quad (1) \therefore R(s,t) = \frac{(t-s)^{n-1}}{(n-1)!} b(t-s)$$

で解く事に等しい。

## 1.2. 統計的諸問題

1.2) 未知値の上解く場合の本質的な問題点は、作用素  $K$  の inverse が非有界である事、離散化を精密に行なえば行なう程、解くべき連立方程式が数值的に不安定になる、という二点にある。いわば、主要な問題とは、作用素  $K$  を離散化した

行列が悪条件にある点にある。二点に付し。

- 2a) 多項式によるデータへの近似。  
(Data fitting.)
- 2b) スマーリングによるデータの平滑化。  
(Smoothing.)
- 2c) 自己回帰モデル。  
(Regression problem)

等の統計的諸問題に於けるは、問題自身の感受度がそれ程高くなくとも、データに含まれる誤差が大きいと、単に正規方程式と解いただけでは満足な結果は得られない。二の場合は、データの誤差が大きい事で、解くべき種類の方程式と精度に解こうとすればするほど(具体的には、最小二乗法に於いて残差を小さくしようとすればする程)本来求めようとするモデルには、程遠いものと解として選んでしまう事になる。(左とえば2a)に於いて多項式の次数を高くすれば、残差は小さくなる。)

### 2. 悪条件問題の定義

上記の二つの悪条件問題のクラスを見た事により、悪条件問題へ難しさは、  
i) 線型系の感受度。即ち入力の運動の大きさ、の2つに大きく依存する事がある。  
つまり、悪条件問題は、線型系の感受度が高ければ高い程、入力の運動(データに含まれる誤差)が大きければ大きい程、解きにくくなる。

今、簡略化した線型系と統一的に

$$X\beta = y + \varepsilon \quad (X \in R^{m \times n}, \varepsilon, y \in R^m, \beta \in R^n) \quad (2)$$

と表す。 $\varepsilon$ は入力の運動量とし、 $E\varepsilon\varepsilon = \sigma^2$ ,  $E\varepsilon = 0$  (即ち平均0, 標準偏差0)  
とする。又 $X$ の運動は、 $\alpha$ と定義する。問題の大きさを定量化する。  
すなはち線型系 $X$ の感受度は、 $K(X)$ で表わされる。

$$K(X) = \|X\| \|X^+\|, \quad (\| \cdot \| : ユークリッドノルム,  
X^+ は、X の Moore-Penrose 一般化逆行列。)$$

又入力の運動の大きさは $\|\alpha\|$ であるから、出力の運動は $\sigma \cdot K(X)$ で推定できる。  
A. 使用する計算機の活動小数点位数を $p$ (p.s) とする( $\beta$ 適5桁)。B. の最小  
二乗解を直交法(Q-R, 修正グラム-シミット法等)で解こうとすると、

$$K(X) \times \max(\sigma, \beta^{-5} \|X\|) \leq \|y\|$$

が満たさなければならない。 $\|X\| \beta^{-5}$ は丸めの誤差レベル(計算機に依存)である。

本稿では上記の条件が満たされない場合、様子系を悪条件問題として定義し該論の対象とする。即ち、以下の条件(i)が、系が悪条件である事の条件であるとする。

$$\|X^+\| \times \max(\sigma, \beta^{-5} \|X\|) \geq 1 \quad (3)$$

以上まとめて。

<定義>

線型系  $X\beta = y + \varepsilon$  ( $X \in R^{m \times n}, \varepsilon, y \in R^m, \beta \in R^n$ ) を  $\mathcal{F}(p.s)$  上で解く時

$$\|X^+\| \times \max(\sigma, \beta^{-5} \|X\|) \geq 1 \quad (X^+ : \text{一般化逆行列}, \sigma = E\varepsilon\varepsilon (\varepsilon の標準偏差))$$

であれば、線型系は悪条件であるといふ。

### 3) 教値解法と問題点

2) 定義した悪条件問題、 $X\beta = y + \varepsilon$  に対する一般的な最小二乗法による解、即ち、 $\min_{\beta} \|X\beta - (y + \varepsilon)\|^2$  を求めることは、無意味である。何故なら、残差  $\varepsilon$  は近づけようとする試みが、入力データの擾動を、 $X$  の不安定性  $\text{r}(X)$  に従って増幅される事により、解  $\beta$  を大きめにしちゃうである。

この為に、最小二乗法は、何らかの意味で修正されたければならない。修正された最小二乗法として以下のものを挙げる事ができる。

#### 1) 最小自乗最短解 (Minimal Norm Least Squares Solution.)

本来は、 $X$  が Singular で解  $\beta$  が一意性がない時、 $\beta$  のノルムが最小にすればその正解となる選択肢である。即ち、 $\bar{y} = y + \varepsilon$  とし、

$$\min_{\beta} \|X\beta - \bar{y}\|^2 \quad (X \in \mathbb{R}^{m \times n}, \text{rank } X < \min(m, n), \beta \text{ は一意性はない。})$$

$$\min_{\beta} \|\beta\| \quad (\text{この条件により } \beta \text{ は一意となる。})$$

一意解  $\beta$  は、 $\beta = X^+ \bar{y}$  ( $X^+$  は一般化逆行列) で与えられる。実際には、 $X$  の特異値に対応する特異ベクトル成分を 0 と (たものと解としないものとなる)。

#### 2) Truncated Singular value.

1) の M.M.I.S.S. 解は、あくまで  $X$  の張る全の特異ベクトル成分で解を構成する。これに対し、解が丑化可能な性質のある微小特異値に対応する特異ベクトル成分を強制的に 0 とせず、意味のある特異値に対応する特異ベクトル成分のみで解を構成するとの事の手法である。この場合、0 とおく特異ベクトル成分の選択が問題となる。 $X$  の特異値を  $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r > 0$  とし対応する左特異ベクトルを  $u_1, u_2, \dots, u_r$  とおく。この場合の解  $\beta$  は、( $\bar{\beta} = V^T \beta$ ,  $V$  は  $X$  の右特異行列>)

$$\min_{\beta} \|X\beta - \bar{y}\|^2, \min_{\beta} \|\beta\| \quad \bar{\beta} \in \text{span}[u_1, u_2, \dots, u_r] \quad (r < n). \quad \text{となる。}$$

#### 3) Damped least squares. (Modified least squares, Regularization)

この手法は、統計的問題に対しての Modified least squares. Ill-posed Problems に対する regularization (正則化法) と呼ばれているが、制約付き最小自乗問題 (Constrained least squares problems) と呼ばれる。

$$\min_{\beta} \|X\beta - \bar{y}\|^2 \quad \text{subject to } \|\beta\|^2 \leq r^2 \quad (\text{制約条件})$$

Lagrange の未定乗数法によって以下の方程式に変形される。(A は未定乗数)

$$\min_{\beta} \{ \|X\beta - \bar{y}\|^2 + \lambda \|\beta\|^2 \} \iff (X^T X + \lambda I) \beta = X^T \bar{y}$$

この場合問題は存在する。正則化パラメータ  $\lambda$  の選択が問題となる。

#### 4) (Modified) Regularization.

3) の制約条件  $\|\beta\|^2 \leq r^2$  をさらに一般化し  $\|T\beta\|^2 \leq r$  としたものである。

安定化因子  $\lambda$  は、通常微分作用素の離散近似である。 $\lambda$  に対する応答。

$$\min \|X\beta - \bar{y}\|^2 \text{ subject to } \|I\beta\| \leq \gamma^2. \quad (\text{Lagrange or 定乗法による})$$

$$\min \{ \|X\beta - \bar{y}\|^2 + \lambda^2 \|I\beta\|^2 \} \Leftrightarrow (X^T X + \lambda^2 I) \beta = X^T \bar{y}$$

上記式化が何を表すか。 $\lambda$  の場合問題となるべきではない。正則化パラメータの選択が重要である。以下正則化パラメータの決定法を述べる前に、正則化パラメータ決定の定性的な意味について多角的に概観してみる。表中 (controller) とは各 case に対する正則化パラメータ (Regularization Parameter) を対応する量の呼び名である。

Case	large $\leftarrow$ (Controller) $\rightarrow$ small		
1) HNESS (最小二乗最小 ルル解)	残差が 増大する。 (数値的によらず (ヨハ) 値)	(強制的によらず (特異値及び特異ヘルム)	解のルルが増大する。
2) Singular Value Truncation	解の張子空間 の次元の減少	(強制的によらず (特異値及び特異ヘルム)	条件数の増大。 (小正の特異値を使う。)
3) Data Fitting (外挿法による データの近似)	数値的に安定 (多項式への一次挿 入下限。)	(あるいはめど多項 式の次数)	データ点によくよくなつた (次数が高くなる。)
4) オドリ フルトヘルム型 積分方程式	オドリの積分 方程式がよらず (安定化因子導入 なし)	(正則化法で解く と伝定する 正則化パラメータ)	数値的に不安定となる。 (適切な問題ではない)
5) Smoothing (データの平滑化)	Smoothness よりデータが 平滑化される。	(Smoothing parameter)	残差が減少する。 解が振動へはづく ものとなる。
6) 制約付 最小二乗問題	残差が増大し Constraint が減少 ( $\ I\beta\ ^2$ す)	(Lagrange Multiplier)	制約条件が増大し 残差が減少する。
7) Ridge Regression (回帰モデル)	Bias が増大	(Ridge parameter)	Variance の増大
8) 正則化法の 誤差解析	Truncated error (安定化因子導入によ る理論誤差) の増大	(Regularization Parameter)	Round off error (データ誤差 $\varepsilon$ による 誤差) の増大
9) 非線形モデル (二場合問題系 ルマニアン)	ヤコビアンは 安定、Step length は減少する。	(Brennerberg- Marguardt Parameter.)	収束は速くなる。 ヤコビアンは不安定。

以下 2-13. Controller は Regularization parameter を代表し正則化パラメータと呼ぶ事にす。

## 9. 正則化パラメータの決定手法

前節述べた様に、"要条件問題の解を求める" という事は、どの場合も既に、"正則化パラメータを決定する" という問題に帰着される。正則化パラメータの決定に際し、2つの有用と思われる情報をある。それは、

i) 解に関する前知識。解を  $\beta$  とした時  $\|\beta\|^2 = \|\mathbb{E}\beta\|^2$  等の量がわかっている。それが制約条件として用いられる ( $\|\beta\|^2 = \gamma^2$   $\|\mathbb{E}\beta\|^2 = \gamma^2$  とする)

$$\min_{\beta} \|X\beta - (y + \varepsilon)\|^2 \quad \text{subject to} \quad \|\beta\|^2 = \gamma^2 \quad \text{or} \quad \|\mathbb{E}\beta\|^2 = \gamma^2$$

とすればよい。しかし万が一一般に  $\|\beta\|$ ,  $\|\mathbb{E}\beta\|$  の正確な値が入手不可能な事は少ないので、正則化パラメータの決定は入力誤差と共に既存する事、解のノルムに與する知識の有無は、うすく解が求まるらしい事が少い。

ii) 入力データの誤差との標準偏差  $\sigma$ 。これは、解  $\beta$  を最もよく選んだ時の残差が  $\sigma$  である事に対応する。i)と同様に定式化すれば

$$\min_{\beta} \|\mathbb{E}\beta\|^2 \quad \text{subject to} \quad \|X\beta - y\|^2 = \sigma^2$$

となり、解と一緒に定まる事ができる。しかししながら、一般に与えられたデータがうすく推定する事(即ち、モデルの構造と誤差と分離する事)は少々ない。しかも、同じノイズレベルのデータであっても、異る、たゞノイズセットに対する最適の正則化パラメータの値が、大きく異なる、という事がある。

以上より理由から、上記の二つの量を必要とする事、即ち解に関する  $\|\beta\|^2$  や  $\|\mathbb{E}\beta\|^2$  の正確な知識、入力誤差の標準偏差に関する正確な情報は、得られない事、と仮定する。この二つの条件を満たす正則化パラメータ決定手法には、以下がある。

- a) Akaike's Information Criterion. (A.I.C.) : Maximum Likelihood.
- b) Allen's Prediction Sum of Squares (PRESS) : Ordinary Cross Validation.
- c) Generalized Cross Validation. (G.C.V.)
- d) Our method. 以下にその概要を示す。

### 4.a) Akaike's Information Criterion (A.I.C.)

Maximum Likelihood Estimator (最大尤推定法)に基づく推定法である。

$$AIC = (-2) \log \text{maximum likelihood} + 2n \quad (\text{すなはち}) \text{定義式} \text{である}.$$

ここで線型システムは  $y = X\beta + \varepsilon$  ( $X \in \mathbb{R}^{mn}$ ,  $y, \varepsilon \in \mathbb{R}^m$ ,  $\beta \in \mathbb{R}^n$ ) とし、正則化パラメータは、次式に於ける  $\lambda$  である。(以下の手法についても同様)

$$\min_{\beta} \left\{ \frac{1}{m} \|X\beta - y\|^2 + \lambda \|\beta\|^2 \right\} \iff (X^T X + n\lambda I)^{-1} X^T y = X^T y$$

すら  $A(\lambda) = X(X^T X + m\lambda I)^{-1} X^T$ ,  $\hat{\beta}(\lambda) = (X^T X + m\lambda I)^{-1} X^T y$  (上式の解) とおけば  $A(\lambda)y = X\hat{\beta}(\lambda)$  である。maximum likelihood は  $\frac{1}{m} \|(I - A(\lambda))y\|^2$  となる。一般化尤推定 (Maximum Likelihood Estimate M(A)) は、

$$M(\lambda) = \frac{1}{m} \frac{y^T (I - A(\lambda)) y}{[\det(I - A(\lambda))]^m} \quad \text{すなはち、正則化パラメータ} \lambda, M(\lambda) \text{を最小とするものを} \text{選ぶ}.$$

#### 4.b) Allens Prediction Sum of Squares (PRESS)

この手法は、(Ordinary) Cross Validation も呼ばれること。この手法の基本的な考え方は、「与えられたデータ点の一部をとり除き、(通常一点) 残りのデータ点を健て2、解を求めるのがより除かれた点を良く推定するように Bias (誤差) を決定する」というものである。即ち  $k$  番目のデータを除いた余り  $\hat{X}^k, \hat{\beta}^k$  解を  $\beta^k(\lambda)$  とすれば、

$$\beta^k(\lambda) = (\hat{X}^{k\top} \hat{X}^k + \lambda I)^{-1} \hat{y}^k.$$

この  $\beta^k(\lambda)$  を健て2  $y_k$  に対する残差、 $[(\hat{X}\beta^k(\lambda))]_k - y_k)^2$  を求めると、これが全2のデータ点  $y_i$  ( $i=1, \dots, m$ ) について行方、その総和が最小となる様な  $\lambda$  を、最適の  $\lambda$  として採用する。つまり PRESS の汎関数を  $P(\lambda)$  とすれば、

$$P(\lambda) = \frac{1}{m} \sum_{k=1}^m [(\hat{X}\beta^k(\lambda))]_k - y_k)^2$$

と表わす。  $P(\lambda)$  は、 $B(\lambda) = \text{diag}(1/(1-a_{jj}(\lambda)))$  とすれば、

$$P(\lambda) = \frac{1}{m} \|B(\lambda)(I-A(\lambda))y\|^2 \quad \text{where } A(\lambda) = X(X^\top X + m\lambda I)^{-1} X^\top$$

と表わす。

#### 4.c) Generalized Cross Validation (G.C.V. by Grace Wahba.)

4.b) の Cross Validation は、既に推定値を与えられた事で知られるが、大きな問題点がある。それは、Rotation invariant でない (PRESS 直交変換によつて不变ではない) 事である。上に述べたは、 $\lambda$  推定の為の汎関数  $\Psi(\beta(\lambda))$  を導入した場合、

$$\min_{\beta(\lambda)} \{ \|X\beta - y\|^2 + \lambda \| \beta \|^2 \} \quad \min_{\beta(\lambda)} \Psi(\beta(\lambda)) \quad (4)$$

と2つの汎関数を同時に最小化する解  $\beta(\lambda)$  を求めなければならぬ。この為 Regularization の汎関数を直交変換によつて何らかの意味で標準化しておかないと、計算量が、計算工程に大きなものとなる。とくに  $\lambda$  の選択。

二八要請から考案された手法が Generalized Cross Validation である。即ち G.C.V. は、PRESS (Ordinary Cross Validation) の Rotation Invariant version である。一般化は、 $X$  の特異値分解、とフーリエストリッカ W ( $= f$ ) を実現する。

$$X = UDV^\top \quad [W]_{jk} = \frac{1}{\sqrt{m}} e^{2\pi i j k / m} \quad l = f \quad y = X\beta + \varepsilon \quad z$$

$\hat{y} = WU^\top y = WDV^\top \beta + WU^\top \varepsilon \equiv \hat{X}\beta + \hat{\varepsilon}$  ( $\hat{X} = WDV^\top, \hat{\varepsilon} = WU^\top \varepsilon$ )  
すなはち PRESS  $P(\lambda)$  は G.C.V.  $V(\lambda)$  に変換される。

$$V(\lambda) = \frac{1}{m} \| (I - A(\lambda))y \|^2 / [\frac{1}{m} \text{Trace}(I - A(\lambda))]^2.$$

(5)

#### 4.d) Our Method

我々の提案した手法は、正則化法の誤差解析による。即ち誤差 (データの摂動による誤差) と打ち切り誤差 (正則化パラメータ導入による誤差  $X$  に入り込めた摂動項) の2乗和が最小となる正則化パラメータを推定するものである。

正則化パラメータ推定の為の汎関数として  $J_1(\lambda), J_2(\lambda)$  の2つを導入する。  
実際のアルゴリズムに於けることは、収束速度の安定性、及ぶ最小値を見つける方法の効率のため、変数変換  $\nu = \log_{10} \lambda$  を採用する。 $J_1, J_2$  は Rotation invariant

であり、一つのえらめた $\lambda$ に対し要する計算量は、S.V.D を利用する事により  $O(n)$  である。

$$\mathcal{L}_1(\lambda) = \left| \frac{\partial}{\partial \lambda} \|(\mathbf{X}^T \mathbf{X} + n\lambda \mathbf{I})^{-1} \mathbf{X}^T \mathbf{y}\|^2 \right| \quad (6)$$

$$\mathcal{L}_2(\lambda) = \left\| \frac{\partial}{\partial \lambda} (\mathbf{X}^T \mathbf{X} + n\lambda \mathbf{I})^{-1} \mathbf{X}^T \mathbf{y} \right\| \quad (7)$$

$\mathcal{L}_1, \mathcal{L}_2$  に関する重要な関係式として以下が導かれる。  
 $\beta$  を真の解、つまり入力誤差  $\sigma$  の系を実数体の上で  $\lambda=0$  として解く解とし  $\|\beta\|$  を有界であると仮定すれば、

$$\left| \frac{\partial}{\partial \lambda} \|\beta - \beta(\lambda)\|^2 - \mathcal{L}_1(\lambda) \right| \leq O(\mathcal{L}_2(\lambda)) \quad (8)$$

$$\left| \frac{\partial}{\partial \lambda} \|\beta - \beta(\lambda)\| \right| \leq \mathcal{L}_2(\lambda), \quad \mathcal{L}_1(\lambda) \leq (\mathcal{L}_2(\lambda))^2.$$

(実際の算法では、(8)(7) に対して差較差係数  $V = \log_{10} \lambda$  を施す。)

### 5. ラプラス逆変換 (Inversion of Laplace Transform.)

i)  $\mathbf{f} = \mathbf{f}(t)$ 、ラプラス逆変換を例にとり、G.C.V. と我々の手法を比較する。  
ii) 未知関数のラプラス変換  $\mathcal{L}(f(t))$  が与えられた時、元の関数  $f(t)$  を求めよ。

$$\mathcal{F}(s) = \int_0^\infty e^{-st} f(t) dt = \mathcal{L}(f(t)) \quad (9) \quad (\Rightarrow \mathcal{L}^{-1}[\mathcal{F}(s)] = f(t) = \frac{1}{2\pi i} \int_{c-i\infty}^{c+i\infty} e^{st} \mathcal{F}(s) ds.)$$

一般には、逆変換は、上に示したプログラムで何種類かにより与えられるが、ここでは、 $f(t)$  を未知関数とした另一种のラプラス変換  $\mathcal{L}(f(t))$  が与えられた時、元の関数  $f(t)$  を求めよ。

(9) は、Gauss-Laguerre quadrature によって離散化される。つまり

$$\mathcal{F}(s_i) = \int_0^\infty e^{-st_i} f(t) dt \approx \sum_{k=1}^n w_k e^{t_k(1-s_i)} f(t_k)$$

つまり  $X_3 = y + \varepsilon$  に対して

$$[X]_{ik} = w_k e^{t_k(1-s_i)} \quad \beta_k = f(t_k) \quad y_i = \mathcal{F}(s_i) \quad \begin{matrix} i=1, \dots, m \\ k=1, \dots, n \end{matrix}$$

とする。

ii) 數値例: (Grace Wahba et al [2] の数値実験例) 及び討論。

具体的に ラプラス逆変換 (9)、解関数  $f(t)$ 、 $s_i, t_k$  をそれぞれ以下のようにとる。

$$\mathcal{F}(s) = \frac{1}{(s+1)^2} + \text{Noise} \quad s_i: (0, 2) \text{ の } m \text{ 等分点},$$

$$f(t) = t e^{-t} \quad t_k \text{ Laguerre Polynomial の零点},$$

Noise  $\varepsilon$ ;  $E\varepsilon=0$   $E\varepsilon\varepsilon=\sigma^2$  (標準偏差) ( $\sigma = \text{AMP}$  を表示する。)

$m=10 \sim 16$  とする。  $\text{AMP}=10^{-2}, \dots, 10^{-6}$

二つの条件数  $\kappa(X) = \|X^+\| \|X\|$  は約  $10^6$  である。(3) との意味に於いて十分な条件となる。

\*Key to the figures;

'AMP' → Standard deviation  $\sigma$  of the noise in the data  $y$ .

'x - axis' →  $-\log_{10}(\text{Smoothing parameter } \lambda)$ .

'y - axis' →  $\log_{10}(\text{G.C.V. } V(\lambda))$ .

'G.C.V.' → Generalized Cross Validation computed by (5).

'Max Error' →  $\|\beta - \beta(\lambda)\|_\infty$  whose minimizer is to be estimated by a functional.

'Tak1, Tak2' → Our functional  $\Lambda_1(\lambda), \Lambda_2(\lambda)$  defined by (6) and (7) respectively.









Fig. 1 ~ 2, 11. AMP =  $10^{-2}$ ,  $10^{-2.5}$  と、データ誤差が大きくなるとどうなるか。  
二の様な場合、解の誤差(即ち max error)は、データの擾動が大きくなると一般に誤差極値を持つ事に過ぎない。我々の手法2-1a. 解の入力に対する微弱数を推定する(式(18))の2-統計量とよく推定する事、我々の手法2-1b. 一般上、正則化パラメータの推定が高精度を要する場合、(データが鋭く、少しひずれの誤差の差成誤差に大きく影響する場合)よりより推定を5元す。G.C.V.は、その意義から、残差に近い小さなオーダーです。(PRESSの定義)が、その小振幅では、主として極値は現れない。この傾向は、1イズレベルが小さくなるればある程は、2)とし2<3。Fig. 3~4 では比較的 G.C.V. はより推定もよいか。Fig. 5~6 では、最小値の同定が難しくなる、2<3。













Fig. 7~10. は、比較的ノイズレベルが小さい ( $10^{-5} \sim 10^{-6}$ ) 場合の数値結果である。ノイズレベルが二の程度になると、線型系の ill-conditioning の問題とから、誤差が大きくなる。しかし、ノイズレベルが大きいほど、誤差は小さくなる。Fig. 7.~10. では、特に G.C.V. が偏差に近い小さな値として、3 種類に見分けられる。文献[1]によれば、G.C.V. ばかりではなく、A.I.G., PRESS もノイズレベルの小さい場合は、正則化パラメータの推定は易い（（極値が鋭くない）にも拘らず、推定の精度がよくない）。我々の手法は、1×2" レベルが、丸めの誤差レベルに適応する。安定して良い推定値を与える。（図中に示したのは、AMP =  $10^{-6}$  だ。）

Fig. 11 は、Fig. 3 (AMP =  $10^{-3}$ ) の G.C.V. をとり出した時の比較的良い推定値を示す。二点は同じ。Fig. 12 は AMP が大きいが異なり、データセット (16 点) を与えたもの。





のと見て。Fig. 13~16. と同様に、ノイズレベルは全  $2 \times 10^{-4}$  である。G.C.V. は Fig. 14. (Fig. 5 に対応) では良い推奨値となるべきが、裏方データセット (Fig. 13, 16), すなはち 2 ケースが異なり、1 ケース (Fig. 15) では大きく変化してしまう。これは (1) データ数が少ないので、誤差範囲が大きいから。二つ目、(2) の著者自身が指摘する G.C.V. の欠点がある。我々の手法では、誤差範囲の形は変化しないが、C = 0.1 は、裏方データセットをいはるノイズセットを取り、そのため X の特異値が変化 (2 の事に到達する) などの場合 (固定 C で推定値と S えて、S (Fig. 13, 15, 16))。

又、G.C.V. 我々の手法と + 定義式による誤差範囲は convex である。2 の裏方データの最小値を見つけた後法が問題となるが、我々の手法では、運動方程  $\lambda = \log_{10} \lambda$  の下で、定義式による誤差範囲は、X の特異値を  $\mu$  とした時  $\lambda = \mu^2$  のとき = 3 で、局所的極大値となる事がわかる、2. 3. 2. 効率よく最小とする正則化パラメータを見つける事ができる。

以上まとめると、我々の手法は、G.C.V. と比較し、以下の点で優れることは見てきた。(Operator Equations は (2.1) 1) 2 元からなるデータ (約 112) セットの変化に対する安定性、2) 装条件に対する強度、3) 定義式による誤差範囲の最小化算法、4) ノイズレベルに応じた 10 ランダム推定の信頼性。

## 6) References

- [1] T.Kitagawa,T.Torii,I.Ninomiya, 'Stabilization of linear system by SVD and Regularization.' Proceeding of IPSJ conference (1980), pp. 595-596. (In Japanese.)
- [2] G.H.Golub,M.Heath,G.Wahba, 'Generalized cross validation as a method for choosing a good ridge parameter.' Technometrics, 21 (1979), pp. 215-223.