

## 22. 地震波データの自動検出方式とオンライン 処理システムにおける稼動実験

地震研究所	{	横	田	崇
		周	勝	奎
		溝	上	恵
		中	村	功

(昭和56年7月31日受理)

### §1. はじめに

微小地震観測網の拡大と、そのテレメータ化が進むにつれて、多量の地震波データを自動的に検出処理するためのアルゴリズムの開発が重要な課題となってきた。すでに各種の方式が開発され、そのうちのいくつかは実用化の段階に達している。それらの代表的な方式としては、i) 入力波形データの振幅値の時間的变化により検出する方式と、ii) 入力波形データの振幅値と周期の両面での変化により検出する方式の2つに分類することができる。

例えば、i) に対応する例としては、STEWART (1977) によるハイパスフィルターを用いる方法がある。この方法では、入力信号のうちの短周期成分の振幅を選択的に強調する変換を行なって S/N 比を改善し、その振幅の長期的平均値 (long-term average) と短期的平均値 (short-term average) の比較から地震波信号を検出するという比較的単純な処理方式を用いている。又、ALLEN (1978) によって開発された方式として、入力波形の特性関数を定義し、その振幅値の長期的平均値と短期的平均値との比較から地震波信号を検出する方式もある。しかし、これらの方式はいずれも主として入力波形データの振幅変化に主眼が置かれ、周期についての情報を十分に活用した方式とは言えない。またこれらの方式は、ノイズ地震波信号を識別するための明確な理論的根拠を持たないという欠点がある。ii) の方式に対応する例としては、TJØSTHEIM (1975) による短周期 P 波に対する自己回帰 (AR) モデルを適用した方式があげられる。AR モデルは、振幅・スペクトル構造の2次元座標による情報を、AR 係数による1次元座標により表現できるという大きな利点がある。地震波の検出処理で用いられる情報は、振幅とスペクトル構造およびそれらの時間的变化で、これらの情報を簡単な形で表現できる AR モデルの導入が有効な手法の開発につながる事は論を待たない。しかし、従来開発された方式は、AR モデルの特性を十分に活用しつくしているとは言い難い。

白石・徳弘 (1979) は、地震波信号を AR モデルで表現し、情報理論でよく知られているベイズの解法を適用し、客観的に地震波の到着時刻を決定することを試みた。これは、ある信号の2つの信号源に対する事後確率比 (尤度比 $\geq 1$ ) を計算し、いずれからの

信号であるかを識別する手法である。この白石・徳弘の方法を適用して、浜口・鈴木 (1979) は、P 波の検出方式の開発を行ない、森田・浜口 (1980) は、S 波の検出方式の開発を行なった。しかしながら地震波のような非定常時系列においては、事後確率の値が、信号源としての AR モデル作成区間に依存するため不安定になる。さらに、時系列サンプルの 1 点毎に計算された尤度比は、一意的にある時点以降 1 以上となる場合は少なく、尤度比  $\geq 1$  の点が分散していたり、判定区間においてすべて 1 以上であることも少なくないので、到着時刻決定のためにさらに尤度比の系列を再評価する必要に迫られる。故に、一意的に到着時刻を決定することはできず、客観性が失われてしまう。

本論文では、OZAKI and TONG (1975), KITAGAWA and AKAIKE (1978) らによる局所的定常という概念を拡張し、ある非定常区間を定常な 2 つの区間に分割する手法により、地震波の到着時刻の決定を行なった。これにより数学的客観性を保ちつつ区間を分割することが可能となる。また、異常値検出 (たとえば、GRUBBS, 1956) という立場を時間領域に拡張して地震波の到着時刻の決定を行なったので、これも合わせて検討を試みた。これらの手法は、地震波のみならず一般的な時系列に対しても有効である。

地震波の表現には AR モデルを適用し、その次数の決定、及び到着時刻決定の基準としては、赤池の情報量基準 (AIC) を用いた。

また、これらの手法を、関東地方の微小地震観測網と接続されたオンラインシステムに導入した。その実験結果の詳細についても述べる。

## §2. 赤池の情報量基準 (Akaike's Information Criterion (AIC))

AKAIKE (1973, 1977) は、統計的推論の過程で次の一般化されたエントロピーの導入を提唱した。

$$\begin{aligned} B(f; g) &= \int \log \left\{ \frac{g(z|x)}{f(z)} \right\} f(z) dz \\ &= E_z \log \left\{ \frac{g(z|x)}{f(z)} \right\} \end{aligned} \quad (2-1)$$

ただし、 $x$ ; 観測値ベクトル

$f(z)$ ; 真の分布関数

$g(z|x)$ ; あてはめたモデルの分布関数

エントロピー  $B(f; g)$  と、真の分布からの“距離”を示す Kullback 情報量  $I(f; g)$  (KULLBACK, 1959) は、次の関係にある。

$$B(f; g) = -I(f; g) \quad (2-2)$$

$I(f; g)$  は、非負で、分布  $g(z|x)$  が  $f(z)$  に一致するときのみ 0 となる。したがって、一般化エントロピー  $B(f; g)$  は、

$$B(f; g) \leq 0, \quad (\text{等号は } f=g). \quad (2-3)$$

統計的推論の目的は、観測値  $X$  から真の分布  $f(z)$  を見積ることであり、いいかえれば  $f(z)$  をより良く近似する  $g(z|x)$  を推測することである。 $B(f; g)$  を、 $g(z|x)$  の推定の

基準とすると,  $B(f; g)$  を最大ならしめる  $g(z|x)$  が, 最も良く真の分布を近似している. このように  $g(z|x)$  を選択する立場は, エントロピー最大化の原理と呼ばれている.

いま, 観測値  $X$  は, パラメータ  $\theta$  によって規定される分布関数  $g(x|\theta)$  に従うとし, パラメータ  $\theta$  の推定を行う. (2-1) 式より, エントロピーは,

$$B(f(z); g(z|\theta)) = E_z \log g(z|\theta) - E_z \log f(z) \quad (2-4)$$

(2-4) 式右辺第2項は,  $\theta$  に依存せず, 真の分布にのみ関する項で, 一定である. 故に, エントロピーの最大化は, 右辺第1項  $E_z \log g(z|\theta)$  の最大化と同値である. ところで, 観測値  $X(x_1, x_2, x_N)$  が独立に得られる場合, 対数尤度  $l(\theta)$  は,

$$\begin{aligned} l(\theta) &= \log \prod_{i=1}^N g(x_i|\theta) \\ &= \sum_{i=1}^N \log g(x_i|\theta) \end{aligned} \quad (2-5)$$

となる. 一方,  $E_z \log g(z|\theta)$  は,

$$\begin{aligned} E_z \log g(z|\theta) &= \int f(z) \log g(z|\theta) dz \\ &\sim \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{i=1}^N \log g(x_i|\theta) \end{aligned} \quad (2-6)$$

となり, 最尤法は近似的にエントロピー最大化原理と同等である.

$\theta$  の最尤推定値を  $\hat{\theta}$  とし,  $g(z|\theta_0) = f(z)$  となる真値  $\theta_0$  が存在する場合を考える. ここで, ' は転置を表わすものとし,  $E_z \log g(z|\hat{\theta})$  を  $\theta_0$  のまわりで展開すると,

$$\begin{aligned} E_z \log g(z|\hat{\theta}) &= \int f(z) \log g(z|\hat{\theta}) dz \\ &\sim \int f(z) \log g(z|\theta_0) dz \\ &\quad + \int \frac{\partial}{\partial \theta} f(z) \log g(z|\theta_0) dz (\hat{\theta} - \theta_0) \\ &\quad + \frac{1}{2} (\hat{\theta} - \theta_0)' \int \frac{\partial^2}{\partial \theta \partial \theta'} f(z) \log g(z|\theta_0) dz (\hat{\theta} - \theta_0) \end{aligned} \quad (2-7)$$

となる.  $\theta_0$  は  $E_z \log g(z|\theta)$  の最大値を与えるので,

$$E_z \frac{\partial}{\partial \theta} \log g(z|\theta) |_{\theta=\theta_0} = 0 = \int \frac{\partial}{\partial \theta} f(z) \log g(z|\theta_0) dz.$$

したがって,

$$J(\theta_0) = -E_z \frac{\partial^2}{\partial \theta \partial \theta'} f(z) \log g(z|\theta_0)$$

とおくと, (2-7) 式は, 次のようになる.

$$E_z \log g(z|\hat{\theta}) \sim E_z \log g(z|\theta_0) - \frac{1}{2} (\hat{\theta} - \theta_0)' J(\theta_0) (\hat{\theta} - \theta_0) \quad (2-8)$$

一方,  $E_z \log g(z|\theta_0)$  は次のように書ける.

$$\begin{aligned} E_z \log g(z|\theta_0) &= \left\{ E_z \log g(z|\theta_0) - \frac{1}{N} \sum_{i=1}^N \log g(x_i|\theta_0) \right\} \\ &\quad + \frac{1}{N} \sum_{i=1}^N \{ \log g(x_i|\theta_0) - \log g(x_i|\hat{\theta}) \} \\ &\quad + \frac{1}{N} \sum_{i=1}^N \log g(x_i|\hat{\theta}) \end{aligned} \quad (2-9)$$

ここで  $\frac{1}{N} \sum_{i=1}^N \log g(x_i|\theta_0)$  を,  $\hat{\theta}$  のまわりに展開すると,

$$\begin{aligned} \frac{1}{N} \sum_{i=1}^N \log g(x_i|\theta_0) &\sim \frac{1}{N} \sum_{i=1}^N \log g(x_i|\hat{\theta}) \\ &\quad + \frac{1}{N} \sum_{i=1}^N \frac{\partial}{\partial \theta} \log g(x_i|\hat{\theta})(\theta_0 - \hat{\theta}) \\ &\quad + \frac{1}{2} (\theta_0 - \hat{\theta})' \frac{1}{N} \sum_{i=1}^N \frac{\partial^2}{\partial \theta \partial \theta'} \log g(x_i|\hat{\theta})(\theta_0 - \hat{\theta}) \end{aligned} \quad (2-10)$$

となる.  $\hat{\theta}$  は最尤推定値であるので,

$$\frac{1}{N} \sum_{i=1}^N \frac{\partial}{\partial \theta} \log g(x_i|\hat{\theta}) = 0.$$

したがって,

$$\frac{1}{N} \sum_{i=1}^N \log g(x_i|\hat{\theta}) \equiv l(\hat{\theta})$$

とすると, (2-8) 式は,

$$\begin{aligned} E_z \log g(z|\hat{\theta}) &\sim l(\hat{\theta}) - (\hat{\theta} - \theta_0)' J(\theta_0)(\hat{\theta} - \theta_0) \\ &\quad + E_z \log g(z|\theta_0) - \frac{1}{N} \sum_{i=1}^N \log g(x_i|\theta_0) \end{aligned} \quad (2-11)$$

となる. ここで

$$\begin{aligned} E \{ (\hat{\theta} - \theta_0)' J(\theta_0)(\hat{\theta} - \theta_0) \} &\sim \text{trace } J(\theta_0)^{-1} I_0(\theta_0) \sim k \\ E \left\{ E_z \log g(z|\theta_0) - \frac{1}{N} \sum_{i=1}^N \log g(x_i|\theta_0) \right\} &= 0 \end{aligned}$$

ただし,  $k$  はパラメータ  $\theta$  の次元,  $I(\theta_0)$  は Fisher の情報行列, ゆえに, (2-11) 式は,

$$E \{ E_z \log g(z|\hat{\theta}) - l(\hat{\theta}) \} \sim -k \quad (2-12)$$

となり,  $l(\hat{\theta}) - k$  は, ほぼ  $E_z \log g(z|\hat{\theta})$  の不偏推定量を与える. この量を  $-2$  倍して, 赤池は, AIC を次のように定義した.

$$\text{AIC} = -2(\text{対数尤度}) + 2(\text{パラメータ数}) \quad (2-13)$$

AIC を最小にすることは, 近似的にエントロピーを最大にすることに相当し, AIC が小

さければ小さい程、モデルはより良く真の分布を近似していることになる。

### §3. AR モデルによる地震波の表現

時系列表現のモデルとしては、AR(Auto-Regresive) モデル、MA(Moving Average) モデル、ARMA (Auto-Regresive Moving-Average) モデル、ARI (Auto-Regresive Intergrated) モデル、IMA (Integrated Moving-Average) モデル、ARIMA (Auto-Regresive Integrated Moving-Average) モデル等がある (たとえば、Box and JENKINS, 1976). ARMA モデルは、AR モデル、MA モデルの混合型で、両者の欠点を補い一般の定常時系列をよく表現する。ARIMA モデルは、ARI モデル、IMA モデルの混合型で、ARMA モデルをさらに一般化し、非線型時系列も表現する。非線型モデルはこの他にも色々開発されている。

地震波信号は、それを時系列としてみたとき、地動ノイズ、P 波、S 波、X 波、コーダ部分、そして再び地動と続く各種位相を含む非定常な信号群である。しかしながら、それらの各種位相部分の系列を、局所的にみれば定常とみなすことができる。定常時系列モデルの中でも、AR モデルは最も扱い易く、地震波信号の特徴を十分に表現できるため、従来、多くの研究者により利用されてきた。本研究においても AR モデルを採用する。

$\gamma$  成分時系列の  $t$  時点での観測値ベクトルを  $X(t)$ 、白色雑音ベクトルを  $U(t)$ 、次数  $m$  の AR 係数行列を  $A(m)$  とし、Backshist operator  $B^m X(t)=X(t-m)$  を導入すると、 $M$  次の AR モデルは次式で表わされる。

$$(I - \sum_{m=1}^M A(m)B^m)X(t)=U(t) \quad (3-1)$$

ただし、

$I$ : 単位行列

$$X(t)=(x_1(t), x_2(t), \dots, x_r(t))'$$

$$A(m)=\begin{pmatrix} a_{11}(m) & \dots & a_{1r}(m) \\ \vdots & \ddots & \vdots \\ a_{r1}(m) & \dots & a_{rr}(m) \end{pmatrix}$$

$$U(t)=(\varepsilon_1(t), \varepsilon_2(t), \dots, \varepsilon_r(t))'$$

ただし、

$$\delta_{ij}=\begin{cases} 0(i \neq j) \\ 1(i = j), \end{cases}$$

$$C=\begin{pmatrix} \sigma_{11} & \dots & \sigma_{1r} \\ \vdots & \ddots & \vdots \\ \sigma_{r1} & \dots & \sigma_{rr} \end{pmatrix} \quad \text{とすると}$$

$$E\{\varepsilon_i(t)\varepsilon_j(t-l)\}=\delta_{l0}\sigma_{ij}$$

$$N[0, C].$$

(3-1) 式を  $i$  成分について書き下すと、次のようになる。

$$x_i(t) = \sum_{m=1}^M \sum_{j=1}^r a_{ij}(m) x_j(t-m) + \varepsilon_i(t) \quad (i=1, 2, \dots, r) \quad (3-2)$$

AR モデルの次数  $M$  の決定には AIC を利用する。このときの AIC は、一定項を無視すれば次式で表わされる (AKAIKE, 1976)。

$$AIC = N \log \{ \det(C) \} + 2P \quad (3-3)$$

ただし、

$$C = C(0) - \sum_{i=1}^M A(m) C(m)'$$

$C(m)$ : ラグ数  $m$  の共分散行列

$P$ : 推測された AR 係数の個数  $P \leq Mr^2$

次数  $M$ , 係数行列  $A(m)$  が決定され、(3-1) 式の AR 表現が求まると、パワースペクトルおよびクロススペクトルを得ることができる (たとえば、赤池, 中川, 1972, Box JENKINS 1976)。パワーおよびクロススペクトルの行列の推定値  $P(f)$  は、

$$S(f) = \sum_{m=0}^M A(m) \exp(-i 2\pi m f) \quad \text{とすると、}$$

$$P(f) = (S(f) * C^{-1} S(f))^{-1} \quad (-1/2 \leq f \leq 1/2) \quad (3-4)$$

で得られる。ただし  $*$  は複素共役を表わし、 $i = \sqrt{-1}$  とする。

パワーおよびクロススペクトル行列が得られれば、コスペクトル、クオドスペクトル、コヒーレンス、フェイズスペクトル、ゲイン、回転スペクトル、周波数応答等をすぐさま得ることができる。つまり、(3-1) 式の多成分 AR 表現が得られれば、予測の問題が解決され、同時にスペクトル構造も明らかになる。逆に、多成分 AR 表現は、これらすべてを含んだものであるといえる。したがって、統計的に独立でない  $r$  種のデータは、 $r$  成分 AR 表現により最良予測が得られる。

AR モデルは、直感的にはスペクトルのピークの表現に適したモデルであり、その位置は、(3-4) 式の特微方程式の根として与えられる。

#### §4. 到着時刻決定のためのモデル

ある位相を含む時系列の任意区間においてその前半部は定常であると仮定する。後半部のある時点において、ある位相が混入することによりその時系列は非定常になる。しかし、その位相混入以降の区間をとると再び定常であると仮定する。したがって到着時刻決定の問題は、その区間を定常な 2 つの区間に分割することに帰着する。地震波信号の表現には AR モデルを、区間分割の適切さの評価基準にはそれぞれ AIC を用いる。

以下、区間分割の数種の数学モデルと手法について述べる。

##### 1) 区間全体を 2 つの AR モデルで表現する方式

OZAKI and TONG (1975), KITAGAWA and AKAIKE (1978) の手法を応用し、上述した考え方に基いて、区間を 2 つの AR モデルで表現する (Fig. 1・I 参照)。区間  $1 \sim K-1$ ,  $K \sim N$  で AR モデルをそれぞれ作成し、それらを  $F_A$ -model,  $S_A$ -model とする。




Fig. 1. Sections of time series for which the AR model is applied through the three different methods of (I), (II) and (III). The point K (or k) corresponds to the minimum of the AIC values.

この場合の AIC を,  $AIC(F_A \oplus S_A)$  とする. 区間全体 1~N で, ひとつの AR モデルを作成し, これを O-model とする. この場合の AIC を,  $AIC(O)$  とする. (2-13), (3-3) 式より,  $F_A$ -model,  $S_A$ -model, O-model の共分散行列, 及びパラメータ数を, それぞれ  $\hat{C}_{FA}$ ,  $\hat{C}_{SA}$ ,  $\hat{C}_0$ ,  $P_{FA}$ ,  $P_{SA}$ ,  $P_0$  とすると,  $AIC(F_A \oplus S_A)$  及び  $AIC(O)$  は次のようになる (OZAKI and TONG 1975, KITAGAWA and AKAIKE 1978).

$$\begin{aligned} AIC(F_A \oplus S_A) = & (K-1) \log \{\det(\hat{C}_{FA})\} \\ & + (N-K+1) \log \{\det(\hat{C}_{SA})\} \\ & + 2(P_{FA} + P_{SA} + 2r) \end{aligned} \quad (4-1)$$

$$AIC(O) = N \log \{\det(\hat{C}_0)\} + 2(P_0 + r) \quad (4-2)$$

$AIC(F_A \oplus S_A)$ ,  $AIC(O)$  は, AR モデルの次数決定のために用いられる (3-3) 式と同等であるが, 同時に  $K$  を動かすことにより, 最も良く AR モデルで表現できる 2 つの区間, つまり, 定常な 2 つの区間に分割することができる. したがって,  $AIC(F_A \oplus S_A)$  が最小となる  $K$  の点をもって位相混入とする.

さらにまた, 別種の位相混入の有無を判定するために,  $AIC(F_A \oplus S_A)$  の最小値と  $AIC(O)$  の値の大小を比較し,  $AIC(O)$  の値が  $AIC(F_A \oplus S_A)$  の値よりも小さければ, 区間を分割し 2 つの AR モデルで表現するよりも, 区間全体を 1 つの AR モデルで表現した方が良く, つまり区間全体を定常とみなすことができる. したがって,  $AIC(F_A \oplus S_A) > AIC(O)$  であれば, 別種の位相の混入を否定することができる.

この方法により, ある時系列が定常から非定常へ変化したか否かを判断することができ

る。また同時に、スペクトルの時間的变化を正確に追うこともできる。

II) 区間の最前部, 最後部の AR モデルからの予測誤差を使用する方式

区間の最前部, 最後部のそれぞれで AR モデルを作成し, それらを  $F$ -model,  $S$ -model とする (Fig. 1-II 参照)。それぞれの AR モデルからの  $r$  成分の予測誤差を,  $F$ -model に対しては時間の順方向に,  $S$ -model に対しては時間の逆方向に計算する。(3-1) 式より,  $F$ -model からの予測誤差を  $W_F$ ,  $S$ -model からの予測誤差を  $W_S$  とすると, それらは次式で与えられる。

$$\begin{cases} W_F(i) = X(i) - \sum_{m=1}^{M_F} A_F(m) X(i-m) \\ W_S(j) = X(j) - \sum_{m=1}^{M_S} A_S(m) X(j+m) \end{cases} \quad (4-3)$$

ただし,  $A_F(m)$ :  $F$ -model の AR 係数行列

$A_S(m)$ :  $S$ -model の AR 係数行列

$M_F$ :  $F$ -model の AR 係数の次数

$M_S$ :  $S$ -model の AR 係数の次数

AR モデルの定義より, AR モデルを作成した区間内であれば, 予測誤差は (3-1) 式において, 共分散行列  $C$ , 平均 0 のガウス分布をなす。したがって, (4-3) 式の予測誤差  $W_F$ ,  $W_S$  の系列は,  $F$ -model,  $S$ -model と同じ系列が続いている限りガウス分布に従う。

到着時刻決定の問題は, 非定常な区間を定常な 2 つの区間に分割することに帰着する。したがって, 任意区間におけるこれら予測誤差  $W_F$ ,  $W_S$  の系列が,  $F$ -model,  $S$ -model に対するガウス分布に従うように, 最も適切な時点で  $W_F$  と  $W_S$  の系列に分割すればよい。ここで, 次の 2 つのモデルを考える。

II-i) 予測誤差の分散を  $F$ -model,  $S$ -model の分散に固定する。

判定区間を  $i=1 \sim n$  とし,  $i=1 \sim (k-1)$  の区間は  $F$ -model に従い,  $i=k \sim n$  の区間は  $S$ -model に従うとし, 共分散行列を,  $F$ -model,  $S$ -model の共分散行列  $\hat{C}_F$ ,  $\hat{C}_S$  に固定すると, 予測誤差の系列  $W$  の分布  $f_1$  は, 次のようになる。

$$f_1(W) = \begin{cases} \phi(W_F(i); \mu=0, \hat{C}_F) & (i=1, \dots, k-1) \\ \phi(W_S(i); \mu=0, \hat{C}_S) & (i=k, \dots, n) \end{cases} \quad (4-4)$$

ただし,  $\phi(\cdot; \mu, c)$  は, 平均が  $\mu$ , 共分散行列が  $c$  の  $r$  成分のガウス分布を表わす。

$$\phi(W; \mu, c) = (2\pi)^{-r/2} \{\det(C)\}^{-1/2} \exp \{-1/2(W-\mu)'C^{-1}(W-\mu)\}. \quad (4-5)$$

(4-4) 式において, 対数尤度  $L_1$  は

$$\begin{aligned} L_1 = & \sum_{i=1}^{k-1} \log \phi(W_F(i); \mu=0, \hat{C}_F) \\ & + \sum_{i=k}^n \log \phi(W_S(i); \mu=0, \hat{C}_S) \end{aligned} \quad (4-6)$$

となる。 $\mu$ ,  $\hat{C}_F$ ,  $\hat{C}_S$  は, 最尤推定値と仮定しているので, 上式は対数尤度の最大値を与え



る。ゆえに、このモデルの AIC を  $AIC_1$  とすると、 $AIC_1$  は次のようになる。

$$AIC_1 = (k-1) \log \{\det(\hat{C}_F)\} + (n-k+1) \log \{\det(\hat{C}_S)\} \\ + \sum_{i=1}^{k-1} W_F(i)' \hat{C}_F^{-1} W_F(i) + \sum_{i=k}^n W_S(i)' \hat{C}_S^{-1} W_S(i) + 2P + \text{const.} \quad (4-7)$$

ただし、 $P$ : パラメータ数

上式の  $AIC_1$  が最小になる  $k$  の時点をもって位相混入とする。

このモデルは、分散を  $F$ -model,  $S$ -model の分散に固定することにより、 $F$ -model,  $S$ -model と完全に同じ状態の系列が続くと仮定して、区間分割を行うものである。

II-ii) 予測誤差の分散を推定する。

II-i) の方式で予測誤差の系列の分散を  $P$ -model,  $S$ -model の分散に固定したのに対し、このモデルでは、一般性を持たせるためにそれらの分散を推定する。II-i) と同様に  $i=1 \sim (k-1)$  は  $W_F$  に、 $i=k \sim n$  は  $W_S$  に区間を分割し、 $W_F$  の共分散行列を  $A_F$ ,  $W_S$  の共分散行列を  $A_S$  とし、平均値ベクトルはそれぞれ  $\mu=0$  とすると、予測誤差の系列  $W$  は次の分布  $f_2$  に従う。

$$f_2(W) = \begin{cases} \phi(W_F(i); \mu=0, A_F) & (i=1, \dots, k-1) \\ \phi(W_S(i); \mu=0, A_S) & (i=k, \dots, n) \end{cases} \quad (4-8)$$

したがって、対数尤度  $L_2$  は、

$$L_2 = \sum_{i=1}^{k-1} \log \phi(W_F(i); \mu=0, A_F) + \sum_{i=k}^n \log \phi(W_S(i); \mu=0, A_S) \quad (4-9)$$

となる。上式において、共分散行列  $A_F$ ,  $A_S$  の最尤推定値は次式で与えられる。

$$\begin{cases} \hat{A}_F = \sum_{i=1}^{k-1} W_F(i) W_F(i)' / (k-1) \\ \hat{A}_S = \sum_{i=k}^n W_S(i) W_S(i)' / (n-k+1) \end{cases} \quad (4-10)$$

このモデルの AIC を  $AIC_2$  とすると、 $AIC_2$  は次のようになる。

$$AIC_2 = (k-1) \log \{\det(\hat{A}_F)\} + (n-k+1) \log \{\det(\hat{A}_S)\} \\ + nr + 2\{P + r(r+1)\} + \text{const.} \quad (4-11)$$

ただし、 $P$ : パラメータ数

上式の  $AIC_2$  が最小となる  $k$  の時点をもって位相混入とする。

このモデルにおいて、平均値ベクトルを  $\mu \neq 0$  とすることもできるが、(4-11) 式における影響は一定項のみで、逆に (4-10) 式における共分散行列の最尤推定値が小さくなりバイアスの変化が (4-11) 式の中に表現されなくなるので、 $\mu=0$  とする。

地震波信号の時系列は、局所的には定常とみなせるが、同じ状態の系列が継続するのではなく、位相混入前（あるいは位相混入後）においても時間の経過に伴って多少変化している。このモデルは、 $F$ -model,  $S$ -model からの予測誤差の共分散行列を推定することにより、スペクトル構造はほぼ同じで、時間と共に振幅は変化しているとして区間分割を行な

っている。当然の事ながら、このモデルは、II-i) のモデルも含んでいる。この方式は、一種のロバスト推定である。(スペクトル構造も多少変化させると、AR 係数を変化させねばならなくなり仮定に反してくる。しかしながら、I) の方式は、多少ともこの場合にも相当させることもできる)。

II-i), II-ii) の方式においても位相混入の有無を判定することができる。

III) 区間の最前部の AR モデルのみからの予測誤差を使用する方式

区間の最前部のみで AR モデルを作成し、それを  $F$ -model とする。 $F$ -model に対する予測誤差を時間の順方向に計算する (Fig. 1・III参照)。

ある時点以降に別種の位相が混入すれば、 $F$ -model からの予測誤差は、その時点以降大きくなる。そこで、到着時刻決定の問題は、異常値解析という見方で考えると、区間の前半部の予測誤差に対する後半部の予測誤差の系列の異常の始まる時点を検出することである。

判定区間を  $i=1 \sim n$  とし、前半部を  $i=1 \sim (k-1)$ 、後半部を  $i=k \sim n$  とすると、分布関数は次のようになる。

$$f(W) = \begin{cases} \phi(W_F(i); \mu=0, A_F) & (i=1, \dots, k-1) \\ \phi(W_F(i); \mu=0, A_{FS}) & (i=k, \dots, n) \end{cases} \quad (4-12)$$

モデルの一般性を失わないために共分散行列を推測する。 $A_F, A_{FS}$  の最推定値は次のようになる。

$$\begin{cases} \hat{A}_F = \sum_{i=1}^{k-1} W_F(i) W_F(i)' / (k-1) \\ \hat{A}_{FS} = \sum_{i=k}^n W_F(i) W_F(i)' / (n-k+1) \end{cases} \quad (4-13)$$

ゆえに AIC は、

$$\begin{aligned} \text{AIC} = & (k-1) \log \{\det(\hat{A}_F)\} + (n-k+1) \log \{\det(\hat{A}_{FS})\} \\ & + nr + 2\{P + r(r-1)\} + \text{const.} \end{aligned} \quad (4-14)$$

上式の AIC が最小になる  $k$  の時点をもって位相混入とする。

このモデルにおいて、後半部  $i=k \sim n$  が従う分布をガウス分布としたが、他の分布にすることもできる。しかしながら、この予測誤差の系列が従う分布関数は不明であり、場合によって異なる。予測誤差の系列から分布関数を求める事もできるが、AR モデルからの予測誤差であること、ガウス分布に分散の大きさによって一般性を持たせることができること、そして扱い易いこと等からここではガウス分布と仮定した。また  $\mu=0$  としたのは、II-ii) と同じ理由からである。

このモデルの場合も I), II) の方式と同様に位相混入の有無を判定することができる。

以上の各モデルにおいて別位相混入時点を、分割された後部の最初の点  $K$  あるいは  $k$  とした。しかしながら、我々が到着時刻を読み取る時は、一般的に、まさに立ち上がりんとする時点を読み取る。特に、立ち上がりの急な場合には、立ち上りの変曲点を読む。ところが、ディジタル値で得られた波形信号において、別位相混入時点は、すでに立ち上




Fig. 2. Definition of the arrival point of seismic wave signals. When a section of incoming signals is divided into the two sections, i.e., of noise and the  $P$  wave signal at the  $K$ -th sampling point, the  $(K-1)$ -th point is taken as the arrival point of the  $P$  wave signal and the time corresponding to the arrival point is defined as the arrival time of the  $P$  waves.

がった時点になり当然のことながら、数学的に分割された別位相混入時点  $K$  あるいは  $k$  も、すでに立ち上がった時点を示す (Fig. 2 参照). そこで、まさに立ち上がらんとする時点をも、到着時刻にする意味で、1 ポイント前にもどした  $(K-1)$  あるいは  $(k-1)$  を到着時刻とする。

## §5. 各モデルによる検出結果の比較

前節の各モデルによって検出された結果の比較・検討を行なう。以下、便宜上、前節の I), II-i), II-ii), III) の各検出方式を、それぞれ、MART, MUPT, MUPET, MUPEO と呼ぶことにする。

テストデータとして、ノイズ部分に地震波を混入した合成波形を使用した。データのサンプリングは、8 msec/point つまり 125 Hz で行なっている。AR モデルの作成及び検出は、1 成分のデータである。Fig. 3 にその結果を示す。A) はノイズ、B) はそれに加えた地震波形、C) はその合成波形である。地震波形を加えた時間は、Fig. 3 に示す原点から 3 sec の場所である。D) はノイズ部分で作成した AR モデルからの予測残差の 2 乗の系列をスムージングしたものである。ある閾値をノイズの AR モデルの分散に対して設定することにより、地震波の到着のフラッグを上げることができる。この場合 AR モデルの予測誤差がガウス分布をなすので、AR モデルの分散に対する閾値の倍率によりその確率を求めることもできる。

E), F) はそのフラッグの前後で AR モデルを作成し、それぞれ MUPT, MUPET による AIC とその最小の位置を示したものである。MUPT によって検出された値は 3.032 sec となり、あらかじめ与えられた到着時刻よりデータサンプル上で 4 ポイント遅れている。MUPET では、3.000 sec となり、あらかじめ与えられた到着時刻を示す。また MUPT の場合に比べ MUPET は、AIC の最小値がより安定した形の谷をもっていることが注

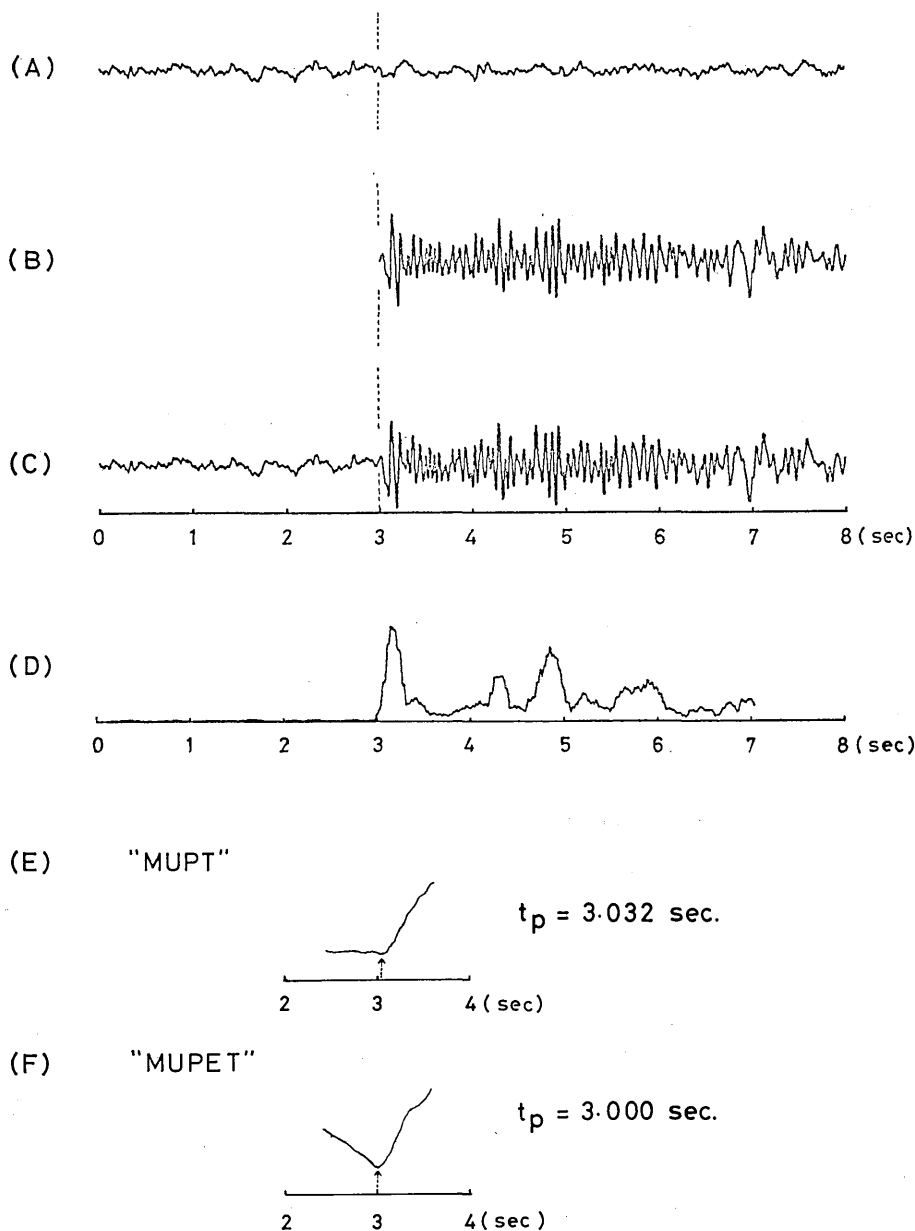


Fig. 3. An example of the procedure of the  $P$  wave arrival time measurements. A time series arbitrarily selected (A) is superimposed by a seismic signal (B) to produce a time series of waveform data (C), divided into the two sections at the point of 3 sec from the origin of the time axis  $t$  as shown by a vertical broken line. Smoothed values of the square of prediction errors (D) are calculated for the entire part of the time series (C) by applying the AR model for the noise section. The minimum point of the AIC estimated by the methods of MUPT (E) and MUPET (F) are indicated by arrows, giving the  $P$  wave arrival time of 3.032 sec and 3.000 sec respectively.

目される。AIC も統計量であることを考慮すれば、MUPT による検測結果は不安定であり、MUPET による検測結果は、非常に安定していることがわかる。MUPT でその他の例について検測を行なった結果では、振幅の変化が比較的小さく周期に変化がある場合には正確な検測結果が得られる。ところが  $P$  波初動の立ち上がりが急な場合には 2 つの区間に分けない方がよいという矛盾した結果を示す場合もあった。その場合は、AIC の最小値ではなく極値の前後で再び AR モデルを作成し再検測する必要がある (横田 1980)。これは予測誤差の系列の分散を AR モデルの分散に固定したため、i)  $F$ -model あるいは  $S$ -model の AR 表現の一方が最適予測を与えた場合と、いずれか一方の AR 表現が、非常に悪い場合には、(4-7) 式の数部分の項の影響が大きく、ii) AR 表現は同程度の最適さで振幅が非常に異なる場合は (4-7) 式の第 3, 4 項のいずれか振幅の大きな方の項が、他の項より小さくなってしまったためである。それに比して、MUPET では、これらの欠点を十分に補い最適評価を与えている (横田他, 1981)。

Fig. 4 に 1 成分による MART の検測結果を示す。図中  $P$  波、 $S$  波の矢印は、それぞれ AIC が最小になった時点で、この図に関しては矢印は到着時刻としたポイントよりひとつ後ろである。波形がふり切れている場合でも補正の必要なしにその場所を正確に示し




Fig. 4. Examples of vertical component seismograms and the result of the arrival time measurement of  $P$  and  $S$  waves by the method of MART. The  $P$  and  $S$  wave arrival times indicated by arrows correspond to the point of the minimum of the AIC.

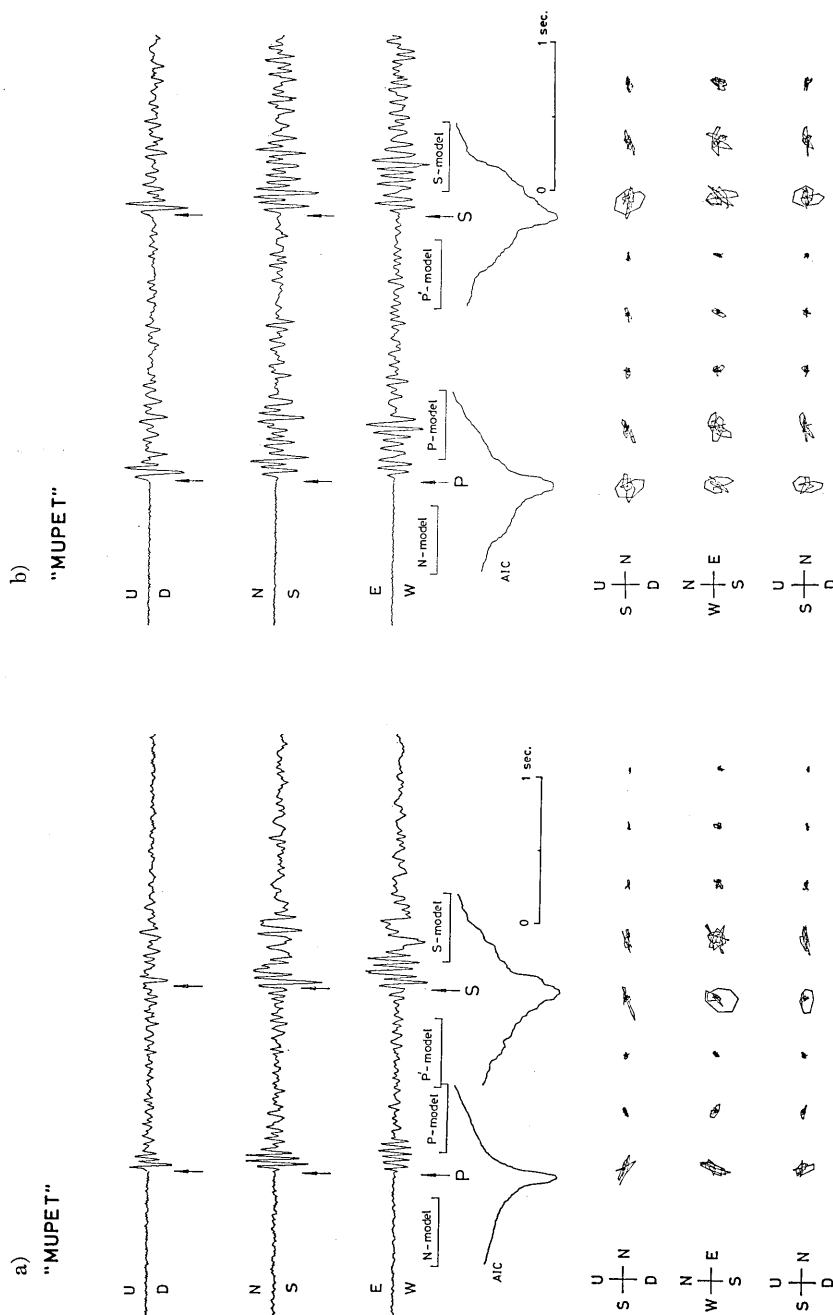


Fig. 5a, b. Examples of three component seismograms and results of the arrival time measurement of P and S waves by the method of MUPET. In the lower part of the figure, particle motions of the seismic wave signals are illustrated for the consecutive sections of the signals.

ていることがわかる。AIC の値がスムーズでないのは、波形からすぐさま推されるように、完全には定常でなく、それぞれの極値の間で波形のスペクトル、振幅が多小変化しているからである。このことから、この方式は到着時刻の検出のみでなく、最も最適なスペクトルの変化を調べるのにも有効なことがわかる。しかしながら、到着時刻の検出に関しては、判定時点毎に AR モデルを 2 ケ作成しなければならないので計算時間を要する。

Fig. 5a, b. に、3 成分の地震波形を用いた MUPET による検出結果を示す。図の下部に各成分間の orbit を示す。N-model, P-model は P 到着時刻を検測するために 3 成分 AR モデルを作成した区間を表し、P'-model, S-model は S 到着時刻を検測するために作成した 3 成分 AR モデルの区間を表わしている。矢印 P, S は、それぞれ検出された P 波、S 波の到着時刻を示している。




Fig. 6. Examples of vertical component seismograms and the results of arrival time measurement of  $P$  and  $S$  waves by the method of MUPET. The sections for which the method is applied are determined by the square of the prediction errors for the model of noise and  $P$  wave signals, so as to cover a constant width of the section before and after the point where the prediction error exceeds a given threshold level.

AIC の系列は、1 成分の場合に比べさらに安定した最小値を与えていることがわかる。これは、3 成分 AR モデルが成分間のスペクトル構造も含めて表現しており、その予測誤差は 3 次元空間で見た波形の形態のほとんどすべての変化（たとえば、振幅、周期、移動方向等）を含んでいるからである。当然、図中に見られる 2 次元平面での orbit のパターンの変化も、3 次元空間で表現されている。したがって、位相混入に伴う変化の情報量が増し、それらの総和として AIC が得られるので、AIC の系列はより安定した谷を与え、検測結果の信頼性は非常に高いものになる。

1 成分による MUPET で検測された数例の地震の結果を Fig. 6 に示す。図中、 $N$ -model,  $P$ -model は  $P$  波到着時を検測するための、 $P'$ -model,  $S$ -model は  $S$  波到着時を検測するため AR のモデル作成区間を示し、矢印  $P, S$  はそれぞれ検測された  $P, S$  到着時を指す。検測対象区間は、他の例と同様に、ノイズ部分の AR モデル、 $P$  波部分の AR モデルからの予測誤差の系列に対して、ある閾値を越えた時点を中心とする前後一定区間をとっている。これは、振幅が振り切った場合にも十分実用的であることがわかる。検測結果は、振幅の変化が小さい波形から大きい波形まで、そして振り切っている場合も含めて、正にその立ち上りの時点を示している。

MUPET による検測の精度、安定性及び信頼性は、MART と比して低くなく、さらに




Fig. 7. Examples of vertical component seismograms and the results of arrival time measurement of  $P$  and  $S$  waves by the methods of MUPEO. The  $P$  and  $S$  wave arrival times indicated by arrows correspond to the point of one sample before the minimum of AIC.



計算時間は飛躍的に短縮される。

Fig. 7 に 1 成分の MUPEO によって検出された結果を示す。図中,  $N$ -model,  $P'$ -model はそれぞれ  $P$  波,  $S$  波到着時刻を検出するために AR モデルを作成した区間を示す。矢印  $P$ ,  $S$  はそれぞれ検出された  $P$ ,  $S$  到着時を指す。図から明らかなように, 検出結果は正にその立ち上がりを与えている。また, AIC の系列は安定した谷を形成し, 位相混入後, 急激に増大しているのがわかる。したがって, 得られた検出結果は非常に信頼性の高いものである。

MUPEO による検出の精度, 安定性及び信頼性は, MUPET と比して低くない。また, AR モデルをひとつだけ作成すればよいので, 計算時間は MUPET より短くなる。さらに, 孤立波のようなパルス状の波形の到着時刻の検出に対して, MUPET では, Fig. 1 において選択された  $S$ -model 作成区間によっては, その波形が全く含まれずに  $F$ -model とほとんど同じ AR 表現の  $S$ -model が作成され, その検出結果は孤立波の立ち上りの後ろに求まってしまうが, MUPEO では  $F$ -model だけを作成すればよく, その立ち上りを正確に示すことができる。したがって, MUPEO は MUPET より検出できる位相の範囲が広い。しかしながら, 形態の類似した位相を検出する場合には,  $F$ -model,  $S$ -model からの予測誤差を用いる MUPET の方が MUPEO より AIC の系列は安定している。

MUPEO は, 到着時刻の検出のみならず, 異常値解析という立場から,  $P$  波,  $S$  波,  $X$  波に対してフラッグを上げるのにも有効であり,  $F$ - $P$  時間の検出にも使用できる。この方法によれば, 閾値という主観的な量を用いず客観的にフラッグを上げることができる。

## §6. オンライン処理システムへの導入

以上見てきたように, MUPET, MUPEO による検出方式の精度, 安定性及び信頼性は高く, さらに, 十分な計算時間の短縮がなされている。そこで, これらの手法を, 関東地方の微小地震観測網と接続されたオンライン処理システムに導入し, その稼働実験を行なった。

関東自動処理システムの構成図を Fig. 8 に示す。これらシステムの詳細は溝上らによる別の報告 (未発表) に譲り, ここでは関係ある箇所のみを記す。システムは 3 台の計算機により分散処理を行なっている。120 Hz でサンプリングされた 10 bit のデジタル波形が, 各観測点からテレメータシステムに転送される (溝上, 中村, 1980)。これら波形データが前処理部に転送され, ここでは最大 128 チャンネルの地震波形データに対して  $P$  波,  $S$  波,  $F$ -time の判別と検出及びそれらデータの 1 地震毎のグルーピング, 震源計算等をリアルタイムで行なっている (溝上他, 1980)。これらの情報が後段のオンライン処理部に転送され, さらに高度なアルゴリズムによる再検出処理等が行なわれる。そして, さらに後段のマシンスystemによる処理へとつながる。

今回開発した地震波自動検出アルゴリズムを, オンラインで稼働している第 2 段目の処理部に導入した。組み込まれた位置及び関係する処理ルーチンのデータフローを Fig. 9 に示す。オンライン処理システムでは, 最初に, 前処理情報に基づき同一地震に対する検出データをひとつにまとめる統合処理が行なわれる。統合処理の完了と同時に再震源計算



等が実行され、同時に地震波形データがファイルに転送される。開発されたアルゴリズムによる検出は、現在、この再検出ルーチンを通った地震のみを対象としている（図中、AR Processing）。近い将来、このアルゴリズムによる検出ルーチンは、現在より高い位置で実行される。これらの情報は再検出情報と共にファイルに転送され、地震波形データと共にマスターファイルに登録される。マンマシン処理システムでは、地震波データ、検出情報等を磁気ディスク上のバッファを介してグラフィックディスプレイ装置を用いた会話検出処理等が行なえる。

本論文では、1成分の地震波データによるオンライン検出実験について述べる。多成分の場合の検出処理実験及びマンマシン処理部における自動検出方式とその結果については別に報告する。

## §7. オンライン処理システムにおける自動検出アルゴリズム

オンライン処理システムにおける自動検出の目的は、前処理システムで得られた第一近似のリアルタイム検出値に基づきさらに高度な手法で再検出し、検出精度を高めることにある。今回は、前処理部の  $P$  波、 $S$  波それぞれの到着時刻の検出結果の改良のみを目的とした。そのための自動検出処理のフローチャートを Fig. 10 に示す。また Fig. 11 に、AR モデル作成区間の設定の模型図を示す。

### 1) $P$ 波

前処理による  $P$  波到着時刻の検出値を  $t_{pre, P}$  とする。 $t_{pre, B}$  は、立ち上りの振幅が大きく明瞭な波形の場合は数 10 msec (サンプル数にして数個) で読み取られている。しかし、立ち上りの不明瞭なものについては真の  $P$  到着時より 1 sec 程うしろを読むこともある。数 sec 以上異なることは稀で、このような場合は  $S$  波を  $P$  波と読み誤ったものがその大部分である。また、微小地震観測網の地震計の周期が 1 sec で、現在対象とする地震のほとんどが数 Hz～数 10 Hz である。 $S-P$  時間の短い地震 ( $t_S - t_P \leq 1$  sec) も検出対象である。以上の理由から、Fig. 11 において、 $t_{pre, P}$  に対し AR モデル作成区間を次のように設定した。AR モデルの作成に用いたサンプル数は、 $N_F = N_S = 60$  サンプル。ノイズ部分の AR モデル作成区間設定のため  $t_{pre, P}$  の前に、SHB=160 サンプル。 $P$  波部分の AR モデル作成区間設定のための  $t_{pre, P}$  のうしろに、SHF=30 サンプル。また対象とする地震波のパワースペクトルのピークの数、2～4 程度である場合が多い。AR モデルは、(3-4) 式によってスペクトルが得られそのピークの位置は AR 係数の特性方程式によって決定されるので、ピーク数は AR 次数の半分となる（重根を除く）。ゆえに、AR モデルの最大次数を、 $M_{max}=8$  とし次数  $M$  の決定には、AIC を利用した。これらのパラメータ、 $N_F$ ,  $N_S$ , SHB, SHF,  $M_{max}$  は、システムを停止させることなく変更できる。

$t_{pre, p}$  はある閾値を超えた時点で与えられるので、仮にそれが  $X$  波に相当するものであっても、必ず、真の到着時刻  $t_P$  は、 $t_P \leq t_{pre, P}$  である。ここで検出された到着時刻を  $t_{AP-P}$  とすると、 $t_{AR-P} < t_{pre, P}$  であればそれを到着時刻  $t_P = t_{AR-P}$  として採用する。しかしながら、等しい場合も疑わしきとして、 $t_{AR-P} \geq t_{pre, P}$  でのとき、これが MUPET によって検出されたものであれば、その大部分は、初動部分が 1～数パルスの孤立波であ

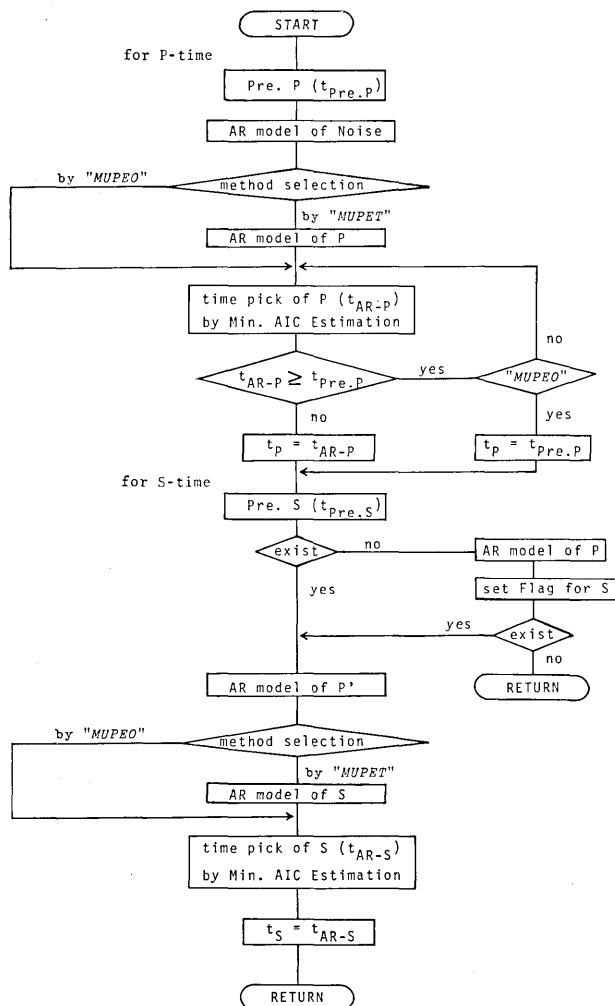


Fig. 10. Flow chart of the AR model application for the arrival time picks.




Fig. 11. Schematic representation of the sections of time series for the AR model applications. The number of samples  $N_F$  and  $N_S$  is taken as 60. The initial points of the noise section SHB and the  $P$  wave section SHF for the AR model application are set at the point of 160 samples before and 30 samples after the  $P$  wave arrival time as given by the pre-processing system.

る場合と考えられるので、MUPEO により再検出する。この際において、設定区間を変えなければノイズ部分の AR モデルは MUPET によってすでに得られており、予測誤差もメモリーに入れておけばすぐさまそれを用いればよく、MUPEO による再計算時間はほとんどかからない。MUPEO によって検出された時刻が、 $t_{AR-P} < t_{pre.P}$  であれば、 $t_P = t_{AR-P}$  として採用し、不本意ながら  $t_{AR-P} \geq t_{pre.P}$  であれば、 $t_P = t_{pre.P}$  として前処理部による検出結果をそのまま採用する（遅れても、データサンプル数にして 1~2 ポイント程度であり、遅れることはほとんど皆無に近い）。

## II) S 波

前処理による S 波到着時刻を  $t_{pre.S}$  とする。P 波に比して S 波の前処理部の結果にはまだ不安定な面もあり信頼性が低く、S 波群の検出の後、過去にさかのぼって到着時刻を検出しているため、真の S 波到着時  $t_S$  と、 $t_{pre.S}$  の間の関係は不定である。しかしながら、 $t_S \leq t_{pre.S}$  となる場合の方が多いようである。また、現在検出対象とする地震波形の S 波部分は、I) で述べた特徴と同じであり、 $t_S - t_P \leq 1 \text{ sec}$  の地震も対象にしている。故に、 $t_{pre.S}$  に対する Fig. 11 の変数を次のように設定した。 $N_F = N_S = 60$  サンプル、SHB=120 サンプル、SHF=60 サンプル。AR モデルの最大次数  $M_{\max}$  は、I) で述べたのと同じ理由から  $M_{\max} = 8$  とし次数  $M$  の決定には AIC を用いた。これらのパラメータ  $N_S$ ,  $N_P$ , SHB, SHF,  $M_{\max}$  も I) と同様に可変である。また  $(t_{pre.S} - t_{pre.P})$  によっても変更可能である。

前処理で S 波到着時刻が検出できなかった場合は、独自に S 波に対しフラッグを上げる方法として、3 成分の波形の振幅情報のみを用いる方法と、予測誤差を用いる方法が 3 種の計 4 種の方法を持っている。これらはパラメータにより選択可能である。各手法の統一的な比較結果は別に報告する。現在、テストの意味も含めて予測誤差に対しある閾値を設定し、フラッグを上げる方式をとっている。

S 波に関しては P 波の場合とは異なり、検出された到着時刻  $t_{AR-S}$  が、たとえそれが前処理部による検出結果  $t_{pre.S}$  より遅れた場合でも、前処理部の結果は採用しない。つまり、いつも  $t_S = t_{AR-S}$  を採用している。

## §8. オンライン処理システムによる実験結果

Fig. 12a~c に P 波に対する検出結果をグラフィック・ディスプレイに表示したものを示す。図中、P は、前処理部による検出結果で、X0 は、オンライン処理部における検出結果である。それらの後の数値は、検出された到着時刻の正秒からの値（単位は秒で、百分一秒まで表示）で、それぞれのバーの先端が検出されたポイントを示している。これらは、表示すれば自動的についてくる。

これらの図から、明らかに MUPET あるいは MUPEO による検出は、正にその立ち上りを示していることがわかる。立ち上りの急なもの、P 波がすでに振り切っているものに関しても明らかにその立ち上りを示している。また、立ち上りの不明瞭なものに関してもその立ち上りを示している。P 波に関しては、95%以上の確率で誤差は 0~2 サンプル程度、90%以上は、正にその立ち上りを示している。残り 5%は、N-model に対する区間が、すでに P 波の始まりを含んでいた場合に相当している。この問題も、SHB をもう




Fig. 12a 0 1 sec.

Fig. 12a.b.c. Enlarged illustrations of the *P* wave signals and the results of arrival time measurements by the pre-processings (designated as *P*) and those by the AR model processings (designated as *X0*). Note that the arrival time given by the pre-processings is significantly improved by the application of the AR model processings.




Fig. 12b 0 1 sec.




Fig. 12c







Fig. 13a






Fig. 13c

少し大きくすることにより数%は解決される. あと数%は,  $S$  波を  $P$  波と前処理が読み誤った場合である.

Fig. 13a~c に  $S$  波の検測結果を示す. 今回 オンラインシステムには 1 成分 ( $N/S$  あるいは  $E/W$ , 水平動のない観測点は  $U/D$ ) による検測結果である. 図中,  $S$  は前処理部による検測結果で,  $X1$  はオンライン処理部による検測結果である.

特に  $S$  波は非定常なので, モデル作成区間の選択等の問題もあるが, 前処理部による検測結果が正しい,  $S$  波の近傍を示している場合には, 90%以上の確率で,  $\pm 0.1$  sec 以内にその立ち上がりを示している.

本来, これらの手法は特に  $S$  波及び  $P$  波の立ち上りの不明瞭なものを検測する為に開発されたものであり, 高次の情報 (たとえば, 2 成分, 3 成分の地震波形) を導入することによりさらに精度の向上が望まれ  $P$  波と同程度の精度 (サンプリングレイト依存) で

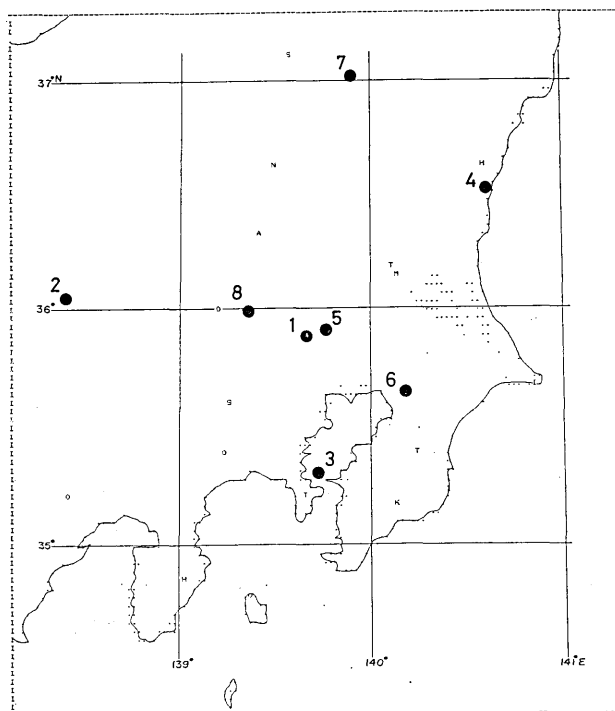



Fig. 14. Map showing the location of earthquakes (as numbered 1-8), the seismograms of which recorded at the stations (indicated by one letter abbreviation) in the Kanto district are exemplified in Fig. 15 to show the results of arrival time measurements by the automatic data processings.

Fig. 13a, b, c. Enlarged illustrations of the  $S$  wave signals and the results of arrival time measurements by the pre-processings (designated as  $S$ ) and those by the AR model processings (designated as  $X1$ ). Note that the arrival time given by the pre-processings is significantly improved by the application of the AB model processings.

## Earthq. No.1



## Earthq. No.2





Fig. 15a

## Earthq. No.3



## Earthq. No.4





Fig. 15b

Earthq. No.5



Earthq. No.6





Fig. 15c

## Earthq. No.7



## Earthq. No.8




Fig. 15d

Fig. 15a. b. c. d. Examples of multi-channel seismograms of microearthquakes in the Kanto district (see Fig. 14) and the arrival time measurements for *P* and *S* waves. The results of the arrival times for the *P* and *S* waves given by the pre-processings are designated as *P* and *S*, and those given by the AR model processings are designated *X0* and *X1* respectively.



検出が可能になる。またオンラインの実験結果では、それが確認されている。

S波は人間が介してもかなり主観が入り、検出者によっては、 $\pm 0.01 \sim 0.5$  sec 程度の差が認められる。このことを考慮すれば、MUPET, MUPEO による手法は、1成分でも十分それに対等である。まして判定区間においてその到着時刻は、数学的裏付けに基づいており、検出者の読み取りに比して、客観的である。問題は、前処理からのS波の読み取り値が正しいS波立ち上りの近傍を示しているかどうかである。

Fig. 15a~d に、観測された地震の各観測点の波形を同一画面に表示したものを示す。又、Fig. 14 には、それらの地震に対応した震源を示す。この震源座標は、前処理部の検出値を基にしている。近く MUPET, MUPEO による検出ルーチンのプライオリティーが高くなれば、さらに精度は高くなる。

## §9. お わ り に

I) P波, S波, X波等に関する到着時刻の決定及びそれらの位相の有無に対する検出の一般化を AIC を利用する事により展開した。用いた因子は AR モデルからの予測誤差で、これは振幅、スペクトル構造を反映したものである。

展開した理論は時系列一般に使用することができ、AR モデルを用いたのは地震波を対象としたからである。データによっては、たとえば ARI モデルを用いれば、地殻変動等にすぐさま適用することができる。また、MUPET, MUPEO に関しては、モデルからの予測誤差を使用せずとも、データそのものにあてはまることもできる。また予測誤差を使用する場合でも、予測誤差に再びモデルをあてはめ、予測誤差の予測誤差を用いることも可能である。このことにより時系列表現のモデルの悪さが改良されてゆく。

以下に各手法の特徴を記す。

### i) MART

信頼性は高く統計的にもその意味は明確である。しかし AR モデルを判定ポイント毎に作成する為に計算時間がかかる。スペクトル構造の変化を研究するのに適している。

### ii) MUPT

計算時間は MART に比べ飛躍的に短縮されるが、不安定で信頼性の面では劣る。特に、S/N の良いものに対しては、極値の近傍で再び AR モデルを作成し再評価する必要がある。

### iii) MUPET

MUPT の欠点を補い精度、安定性及び信頼性は MART と比較しても低くはない。MUPT の長所はそのまま受けついでおり、計算時間も速い。

### iv) MUPEO

MUPET よりさらに計算時間は短縮される。精度、安定性及び信頼性は MUPET と比しても低くなく、さらに、AR モデルをひとつだけ作成すればよいので、孤立波に対しても有効になり、MUPET より検出対象の波形の範囲がひろがる。

II) MUPET, MUPEO の手法による検出方式をオンライン処理システムに導入した。P波, S波の判定は行なわず、前処理で高速検出されたP波, S波の到着時を候補者としてその結果を改良する意図で実験した。

i) *P* 波

$U/D$  1 成分を用いたが, その結果は  $\pm 0.01$  秒で約 95% 以上が読み取れる. 判定区間を広げれば残り数パーセントに対しても同程度の精度で読み取りが可能になる.

ii) *S* 波

前処理の情報を用いている為, 不安定さはあるが前処理で真の *S* 波の近傍を示したものに對しては  $\pm 0.1$  秒程度で約 90% 以上が読み取り可能である. 今回オンラインシステムに入れたのは水平動 1 成分のみを用いる手法であって, 2 ないし 3 成分を使用するようになれば, 正しく *S* 波が示されたものに関しては *P* 波と同程度の読み取りが可能になる. これはすでに導入段階にある.

iii) *P* 波及び *S* 波の到着時刻の決定に要する時間

1 ステーションにつき, *P* 波, *S* 波それぞれ 1 秒以内, 両方の読み取りがある場合は約 2 秒間で計算できる. 精度及び計算時間の両面からも十分にオンライン自動処理に適している. またプログラムを簡便化し, アセンブラで作成すれば, 十分リアルタイムとしても使用できることが示唆される.

## III) 自動検出処理における問題点と将来的手法

入力波形データを連続的に百数十チャンネル走査すると極めて長い処理時間が必要である (参考までに 1 観測点 90 秒間の波形を最初から AR モデルで走査し独自に *P* 波, *S* 波, *F* 時間の候補者を検出し MUPET, MUPEO で再検出するのに約 5~10 秒かかる).

この難点を解決する為の方法として, 高精度検出処理システムの前段に, 入力波形信号を連続的に高速走査し, *P* 波及び *S* 波到着時の第 1 近似処理を行う 前処理システムを設ける (現在の関東自動処理システムがそれを持つ). *P* 波及び *S* 波についてのモデル設定区間の位置はこの前処理検出値の前後に設定すればよく, 連続走査の必要がなくなる. 前処理システムを設ける事により, 分散処理形態が整えられる為, 地震波位相の第 1 次近似検出, 後段の高精度再検出が実行できるので, 多チャンネルデータの高速, 高精度処理が可能となる.

以上 2 段をオンライン処理とすれば, さらに後段にオフライン処理として人間の介入した処理システムを設ける事により, オンライン処理による位相同定の誤り及び第 1 次近似の誤りを是正することができる. ここに, AR モデルによる自動検出を併用すれば検出者は各データを読み取る必要はなく数十チャンネル, 数十地震を同時に表示し, その誤りを是正するだけで良い (Fig. 9 参照). また, このオフライン検出は非同期に行えるので, 計算時間等は気にする事なくさらに精度の高い処理方式を導入する事もできる. 1 チャンネルあたり 1 秒間に 120 サンプルで 10 bit のデジタル波形を内部に記憶しているので, 検出者は時間軸, 振幅とも非常に圧縮されたものを同時に多数見る事ができる. 以上のような分散処理形態を持つ事により, 読み取り値の精度向上及び同定の是正等がマンマシンシステムとして完成する. また到着時刻に関しては, 検出者の経験の差によらず, 客観的に高精度での読み取りが可能になる. 本論文では高精度検出方式とオンラインシステムにおける 1 成分での実験結果を示した. 次回はさらに高次の情報を用いたオンラインシステムとオフライン処理における実験結果を示す.

## 謝 辞

モデルの開発にあたって種々助言をいただいた統計数理研究所、北川源四郎博士、オンラインシステムの導入においてご協力くださった日本電気のシステムエンジニアの皆様に感謝致します。

また、グラフィックへの表示等を手伝ってくださった地震研究所、萩原弘子女史、千葉平八郎氏、吉田満氏に感謝致します。

## 参 考 文 献

- AKAIKE, H., 1973, Information theory and an extension of the maximum likelihood principle. *2nd International Symposium on Information Theory*, eds. B.N. Petrov and F. Csaki, pp. 267-281, Akademiai Kiado; Budapest.
- AKAIKE, H., 1976, Canonical correlation analysis of time series and the use of an information criterion. *System Identification*, eds. R.K. Mehra and D.G. Lainiotis, pp. 27-96, Academic Press; New York.
- AKAIKE, H., 1977, On entropy maximization principle. *Proc. Symposium on Amsterdam*; North-Holland.
- 赤池弘次, 中川東一郎, 1972, ダイナミックシステムの統計的解析と制御, サイエンス社; 東京.
- ALLEN, R. V., 1978, Automatic earthquake recognition and timing from signal trace, *Bull. Seism. Soc. Am.* 68, 1521-1532.
- BOX, G. E. P. and G. M. JENKINS, 1976, *Time series analysis—forecasting and control* (revised, ed), Holden-Day; California.
- GRUBBS, F. E., 1956, Procedures for detecting outlying observations in samples, *Technometrics*, 11, 1-21.
- 浜口博之, 鈴木次郎, 1979, 微小地震 P 波初動の自動検出とその信頼性について, 自然災害特別研究成果 No. A-54-2, 62-83.
- KULLBACK, S., 1959, *Information theory and statistics*, Wiley; New York.
- KITAGAWA, G. and H. AKAIKE, 1978, A procedure for the modeling of non-stationary time series, *Ann. Inst. Statist. Math.*, 30-B.
- 溝上 恵, 中村 功, 1980, 微小地震観測ネットワークシステムについて, 地震予知観測室観測技術報告, 1. 地震研究所地震予知観測情報センター.
- 溝上 恵, 中村 功, 萩原弘子, 千葉平八郎, 吉田 満, 1980, 1980年伊豆半島東方沖の群発地震のリアルタイム検出—システムの稼働実験, *Bull. Earthq. Res. Inst.* 55, 949-1015.
- 森田裕一, 浜口博之, 1980, 地震波の自動処理 (2)—S 波検出, 地震学会講演予稿集, No. 2.
- OZAKI, I. and H. TONG, 1975, *Proc. 8th Hawaii Int. Conf. System Sciences*, pp. 225-226.
- 白石克彦, 徳弘一路, 1979, 地震波初動の自動検出, 地震 II, 32, 141-147.
- STEWART, S. W., 1977, Real time detection and location of local seismic events in central California, *Bull. Seism. Soc. Am.* 67, 433-452.
- TJØSTHEIM, D., 1975, Autoregressive representation of seismic p-wave signals with an application to the problem of short-period discriminants, *Geophys. J. Roy. Astron. Soc.*, 43, 269-291.
- 横田 崇, 1980, 地震波の自動検出 (I)—Arrival time の決定, 地震学会講演予稿集, No. 1.
- 横田 崇, 溝上 恵, 中村 功, 1981, 地殻深部反射波の検出及び不連続面の物理的性質, 地震学会講演予稿集, No. 1.

22. *An Automatic Measurement of Arrival Time of Seismic Waves  
and Its Application to an On-line Processing System.*

By Takashi YOKOTA, Shengkui ZHOU, Megumi MIZOUE  
and Isao NAKAMURA,

Earthquake Rerearch Institute.

In a number of cases, the time series of seismic wave data under study may be considered to be stationary in the wide sense, at least within certain time intervals. A computer based system has been developed for the automatic measurement of the arrival times of seismic signals. The parametric models of an autoregressive type are applied to the small sections of ground noise and seismic wave signals containing the *P* and *S* and unidentified *X* phases of microearthquakes.

In measuring the arrival time of the *P* waves, autoregressive (AR) models are given for two separated sections, one for ground noise section before the *P* waves and the other for the section containing the *P* wave signals. According to the definition of the AR model, the prediction error calculated for the given model is represented by the normal distribution. Therefore, the maximum likelihood estimate associated with each of the two models provides an effective method for the measurement of the *P* arrival time. As a practical application of the method, the Akaike's Information Criterion (AIC) is introduced. An extensive application of the method for the measurement of the arrival times of *S* and unidentified phases has proved to give satisfactory results.

Experiments using the on-line system linked with the telemetering network of microearthquake observation in the Kanto district show arrival time measurements almost exactly the same as those measured by experienced interpreters, giving the *P* arrival times within the error of  $\pm 0.01$  sec for about 95% of the detected events for *P* and within the error of  $\pm 0.1$  sec for 90% for *S*. The time required for the determination of arrival time for each channel is about one second.