

バイナリセンサを用いた ARX モデルの同定

高橋憲介 足立修一（慶應義塾大学）

System Identification of ARX Model Using Binary Sensors

*K. Takahashi and S. Adachi (Keio University)

Abstract— Wang et al proposed a novel system identification method based on the output data measured by binary sensors. However, there were some problems such as constraints on identification input signal. In this paper, a modified identification method using binary sensors is proposed. The effectiveness of the proposed method is examined through numerical examples which simulates a zirconia O_2 sensor.

Key Words: System identification, binary sensor, ARX model, uncertainty.

1 はじめに

システム同定を行うためには対象の (入) 出力データをセンサを用いて計測する必要があるが、従来の研究ではほとんど線形センサの利用を前提としていた。しかしながら、産業界ではコスト面の理由から非線形センサが利用されることがある。たとえば、自動車のエンジン制御を行うとき、空燃費を検出する必要があるが、安価なジルコニア O_2 センサが広く利用されることが多い¹⁾。この O_2 センサの静特性を Fig.1 に示した。このような非線形センサにより計測された信号を用いてシステム同定を行う方法として、われわれは非線形誤差をパラメータと同時に推定する方法²⁾を提案した。しかしながら、非線形性が強くなり、二値しか計測できないバイナリセンサの場合には、この方法の適用も難しくなった。

最近、Wang らによりバイナリセンサを用いたシステム同定法が提案された³⁾。これは確定的な方法と確率的なそれを組み合わせたシステム同定法であり、バイナリセンサを用いた計測データから FIR (Finite Impulse Response) モデルを同定することができる。しかしながら、この同定法では入力データに対する制約の問題があり、そのままでは実問題へ適用することは難しくなった。そこで、本報告では、この問題点を解決する新しい同定法を提案する。また、提案法では、同定された FIR モデルを ARX (Auto-Regressive with eXtra input) モデルへ変換することにより、対象の伝達関数を求めることもできる。

本報告の構成は以下のとおりである。2 節では文献 3) で提案されたバイナリセンサを用いたゲインシステムの同定法を紹介する。3 節では文献 3) の問題点を解決する新しい ARX モデルの同定法を提案し、数値シミュレーション例を通して提案法の有効性を明らかにする。




Fig. 1: Nonlinearity of zirconia O_2 sensor.

2 バイナリセンサを用いたゲインシステムの同定法

2.1 問題の定式化

本報告では、次式のように ARX モデルで記述される線形離散時間安定システムを考える。

$$y(t) = \phi^T(t)\theta + d(t) \quad (1)$$

ただし、

$$\begin{aligned} \theta &= [a_1, \dots, a_n, b_1, \dots, b_n]^T \\ \phi(t) &= [-y(t-1), \dots, -y(t-n), \\ &\quad u(t-1), \dots, u(t-n)]^T \end{aligned}$$

また、 y は出力、 u は入力、 θ はシステムのパラメータ、 ϕ はデータベクトル、 n はモデルの次数、 t は離散時間インデックス、 d は外乱である。システムと外乱に対する事前情報は、 $\theta \in \Omega(0)$ 、 $d(t) \in [-\delta, \delta]$ で与えられていると仮定する。システムの出力は以下のようなバイナリセンサを用いて測定されるものとする。

$$s(t) = I_{\{y(t) \leq C\}} = \begin{cases} 1, & \text{if } y(t) \leq C \\ 0, & \text{otherwise} \end{cases} \quad (2)$$

以上の準備の下でシステムのパラメータ θ を入力 u とセンサ出力 s から推定することが、本報告で考えるシステム同定の目的である。

2.2 ゲインシステムの同定アルゴリズム

(1) 式において $\phi(t) = u(t)$ 、 $\theta = G \in \Omega(0) = [G(0), \bar{G}(0)]$ とおき、文献 3) で提案された単純な遅延なしゲインシステムの同定法について簡単にまとめる。

バイナリセンサを用いたシステム同定には確定的方法と確率的方法の 2 つがあり、2 つの方法は相補の関係にある³⁾。不確定性範囲 $\Omega(t)$ の平均値を $\mu(t)$ 、半径を $\varepsilon(t)$ とおく。すなわち、

$$\mu(t) = \frac{1}{2} (\bar{G}(t) + G(t)), \quad \varepsilon(t) = \frac{1}{2} (\bar{G}(t) - G(t))$$

また、 $C > 0$ 、 $G > 0$ とし、外乱は有界 ($\delta < \infty$) で、外乱の分布関数 $F(\cdot)$ は既知であると仮定する。以下に、2 つの方法の手順を示す。

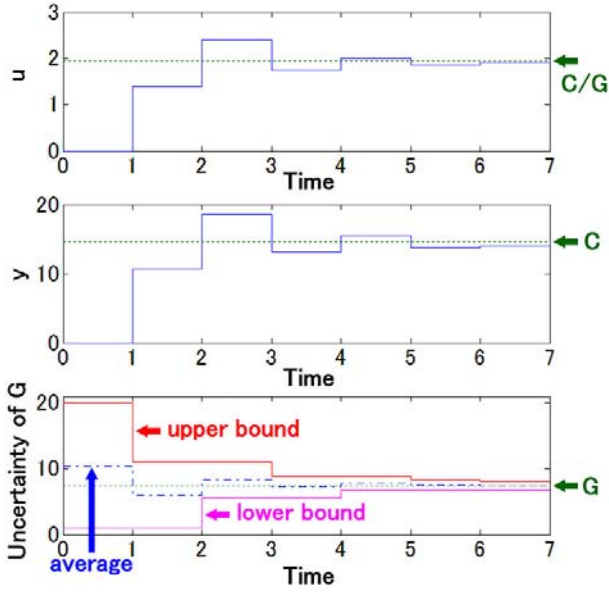


Fig. 2: Input(upper), output(middle) and uncertainty(lower) sequence for deterministic identification.

(1) 確定的方法 これはセンサ出力 $s(t)$ をもとにパラメータの不確定性範囲 $\Omega(t)$ を確定的に削減していく方法であり (不確定性を速く減少させる意味で) 最適な同定入力と不確定性範囲の更新式, パラメータ推定値, そして精度限界はつぎのように与えられる.

i) 最適同定入力

$$u(t) = \frac{C}{\mu(t-1)}$$

ii) 不確定性範囲の更新とパラメータ推定値

$s(t) = 1$ のとき,

$$\bar{G}(t) = \bar{G}(t-1), \quad \bar{\mu}(t) = \mu(t-1) + \delta/u(t)$$

$s(t) = 0$ のとき,

$$\bar{G}(t) = \bar{G}(t-1), \quad \bar{\mu}(t) = \mu(t-1) - \delta/u(t)$$

パラメータ推定値: $\hat{G}(t) = \mu(t)$

iii) 確定的方法の精度限界

$$\varepsilon(t) > \frac{\delta}{|u(t)|} = |\mu(t)| \frac{\delta}{C} \quad (3)$$

確定的方法における入出力信号と不確定性範囲の一例を Fig.2 に示す. ここで, バイナリセンサとして Fig.1 の酸素センサを想定し, $C = 14.6$ とおいた. また, $G = 7.5, \Omega(0) = [1, 20]$ とし, 外乱を $d(t) = [-0.9, 0.9]$ の一様乱数とした.

図より, 実際の G より大きな $\Omega(0)$ の平均値 $\mu(0)$ を目標に入力 $u(1)$ を決定しているため出力 $y(1)$ が閾値 C よりも低くなっている. これによって $s(1) = 1$ が出力され, 真値は $\mu(0)$ よりも低い方であったことがわかるので, 不確定性範囲 $\Omega(1)$ では上半分が削られている. ただし, このとき閾値 C が外乱 $d(t)$ によって揺れ動いていることも考慮して, $\mu(0)$ より $\delta/u(1)$ だけ上の値を $\Omega(1)$ の上限としている. このように最適同定入力の決定と不確定性範囲の更新を交互に繰り返していくのが, 確定的同定法のアルゴリズムである.




Fig. 3: Input(upper), output(middle) and estimate(lower) for stochastic identification.

(2) 確率的方法 これはセンサ出力の経験分布 x と外乱の分布関数 $F(\cdot)$ からパラメータを推定する方法である.

i) 最適同定入力 確定的方法と同様の形式をとるが, 不確定性範囲の更新がないので一定値入力となる.

$$u(t) = \frac{C}{\mu(0)}$$

ii) 経験分布の更新とパラメータ推定値

$$x(t) = \frac{1}{t}s(t) + \frac{t-1}{t}x(t-1) = \sum_{k=1}^t s(k)$$

$$\xi(t) = F^{-1}(x(t))$$

$$\hat{G}(t) = \frac{C + \xi(t)}{u(t)}$$

ただし, $\xi(t)$ は出力の閾値からの偏差 $(y(t) - C)$ の推定値である.

iii) 確率的方法の同定可能範囲

$$\varepsilon(0) \leq \frac{\delta}{|u(t)|} = |\mu(0)| \frac{\delta}{C} \quad (4)$$

確率的方法における入出力信号とパラメータ推定値の一例 ($C = 14.6, G = 7.5, \Omega(0) = [7.4, 8.0]$ とし, 外乱を $d(t) = [-0.3, 0.3]$ の一様乱数とした場合) を Fig.3 に示す. 図より, 入力 $u(t)$ は常に一定値をとり, 出力 $y(t)$ が閾値 C に近い値をとっていることがわかる. $y(t)$ が C をどれぐらいの割合で下回るか, つまり測定出力 $s(t)$ の経験分布が外乱の分布関数に収束することを利用して推定値を求めている.

(3) (確定+確率)的方法 式 (3), (4) より, 2つの方法の適用可能範囲が相補の関係にあるのは明らかであり (確定 \Rightarrow 確率) と組み合わせると外乱の大きさに依らずに真値へ速く収束する同定法となることが期待できる. 具体的には, 確定的方法が以下のような

条件式を満たす程度に収束したのち、確率的方法へ切り替えるなどの方法が考えられる。

【(確定 ⇒ 確率)の切り替え条件】

$$\varepsilon(t) < \frac{\delta + \gamma}{|u(t)|} \quad (5)$$

ただし、 γ は確定的同定から切り替えるタイミングを決定するパラメータである。

以上のような単純なゲインモデルは同定可能であることが証明されている³⁾。同定問題をいかにしてこの形に置き換えるかが「バイナリセンサを用いたシステム同定」の基本となる。

2.3 実用上の問題点

入力 u に制限がなければ上記の方法で G を同定可能であり、文献3)ではこれを用いた FIR モデルの同定法が提案されている。しかし、実際の応用では u が制約をもつため、問題が生じてくる。たとえば、 $-u_{\max} \leq u \leq u_{\max}$ と仮定した場合、 $-\frac{C}{u_{\max}} \leq G \leq \frac{C}{u_{\max}}$ が同定できず、確率的方法を用いても $C > \delta$ では $-(C-\delta)/u_{\max} \leq G \leq (C-\delta)/u_{\max}$ のパラメータ範囲が同定できない。また、負の入力が使えない場合には負のパラメータも同定できない。一般的にインパルス応答は 0 近傍や負に多くのパラメータをもつため、文献3)で提案された方法では実用は難しかった。

3 バイナリセンサを用いた ARX モデルの同定

前節で紹介した Wang らの方法の問題点を解決する新しい ARX モデルのシステム同定法を提案する。この同定法では、まず対象を FIR モデルとして、バイナリセンサのデータから定常ゲイン (G とする) を同定する。つぎに、インパルス応答 (g_k とする) を同定する。この手順において、Wang らの方法に改善を加えた。最後に、同定された FIR モデルから伝達関数に変換する手順を適用して ARX モデルを得る。

3.1 問題の定式化

ARX モデルを FIR モデルで近似して同定を行うので、システムのモデルとセンサは式 (1), (2) とし、

$$\begin{aligned} \theta &= g = [g_1, \dots, g_m]^T \\ \phi(t) &= [u(t-1), \dots, u(t-m)]^T \end{aligned}$$

とにおいて同定する。また、インパルス応答の事前情報は

$$g_k \in \Omega_k(0) = [g_k(0), \bar{g}_k(0)], \quad k = 1, \dots, m$$

で与えられるものとする。このとき、定常ゲインは

$$G = \sum_{k=1}^n g_k \in \Omega(0) = \sum_{k=1}^n \Omega_k(0)$$

となる。さらに、入力 $u(t)$ の制約条件を次式とする。

$$u \leq u(t) \leq \bar{u}$$

全体の時間コスト N (同定に消費するステップ数) を以下のように定義する。

$$\begin{aligned} N &= N_g + N_i = N_d + N_s \\ N_g &= N_{gd} + N_{gs}, \quad N_i = N_{id} + N_{is} \\ N_d &= N_{gd} + N_{id}, \quad N_s = N_{gs} + N_{is} \end{aligned}$$

ただし、 N_g, N_i, N_d, N_s はそれぞれ定常ゲインの同定、インパルス応答の同定、確定的同定、確率的同定にかかる時間コストとする。

3.2 同定アルゴリズム

以下では、一般性を失うことなく $G > 0, C > 0$ と仮定し、外乱の大きさは十分に小さいものとして、確定的方法についてのみ説明する。また、システムが可同定であるための必要条件は以下の通りである。

$$Gu < C < G\bar{u}$$

Step 1 定常ゲインの同定

定常ゲインの不確定性範囲を l 回更新するのに必要な時間コストを $N_g = lm, l = 0, 1, 2, \dots$ とおき、 $u < C/G < \bar{u}, G > 0, C > 0$ を仮定する。また、以下のよう

$$\begin{aligned} u_l &= u(lm + k), \quad k = 1, 2, \dots, m \\ s_l &= s((l+1)m + 1) \end{aligned}$$

このとき、以下の手順でパラメータ推定を行う。

i) 最適同定入力

$$u_l = \frac{C}{\mu(l)}$$

ii) 不確定性範囲の更新とパラメータ推定値

$$\begin{aligned} s(t) = 1 \text{ のとき,} \\ G(l+1) &= G(l), \quad \bar{G}(l+1) = \mu(l) + \delta/u_l \\ s(t) = 0 \text{ のとき,} \\ \bar{G}(l+1) &= \bar{G}(l), \quad G(l+1) = \mu(l) - \delta/u_l \end{aligned}$$

パラメータ推定値: $\hat{G}(l+1) = \mu(l+1)$

iii) 精度限界 式 (3) と同様に次式となる。

$$\varepsilon(t) > \frac{\delta}{|u_l|}$$

定常ゲインの同定における入出力を Fig.4 に示す。

Step 2 インパルス応答の同定

インパルス応答の同定では、定常入力 u_g とインパルス入力 u_i の2つの入力を用いる。Step 1 で定常ゲインの推定値 \hat{G} を得たことによって定常出力 y_g を $\hat{G}u \leq y \leq \hat{G}\bar{u}$ の範囲で自由に移動できるようになったため、仮想閾値 $C' = C - y_g = C - \hat{G}u_g$ と仮想入力 $u' = u_i - u_g$ を用いて同定を行うのが提案法の特徴である。

一つのパラメータ g_k の不確定性範囲 $\Omega_k(t)$ を 1 回更新するには、 $2m$ ステップ (定常出力 y_g が安定するまでの m ステップとインパルス印加後の m ステップ) を必要とするため、インパルス応答列 $g = [g_1, \dots, g_m]^T$ の不確定性範囲 $\Omega(0)$ を j 回更新するのに必要な時間コストを $N_i = 2jm^2, j = 1, 2, \dots$ とおく。また、以下のように定義する。

$$\begin{aligned} u(2(j-1)m^2 + 2(k-1)m + q) \\ = \begin{cases} u_g(j, k), & q = 1, 2, \dots, m, m+2, \dots, 2m \\ u_i(j, k), & q = m+1 \end{cases} \end{aligned}$$




Fig. 4: Input and output data for steady-state gain identification.

$$s_{jk} = s(2(j-1)m^2 + 2(k-1)m + m + k + 1)$$

$$u_{\min} = C/\hat{G}$$

$$u_{\max} = \arg \max_u |C - \hat{G}u|$$

$$u'_{\max} = \begin{cases} \bar{u}, & \text{if } u_{\max} = \underline{u} \\ \underline{u}, & \text{if } u_{\max} = \bar{u} \end{cases}$$

インパルス応答の同定における問題点は、仮想閾値 $C'(j, k) = C - \hat{G}u_g(j, k)$ が可変であるため、目標とするパラメータ $\mu_k(j)$ に対して、同定入力 $u' = C'(j, k)/\mu_k(j)$ が一意に決まらないことである。そこで、仮想入力の大きさ $|u'|$ を最大化する、以下のような式 (3) で表される同定誤差を最小化する意味で最適な同定入力と更新式を提案する。

i) 最適同定入力

(a) $-\infty < \mu_k(j) < \alpha$ のとき,

$$u_i(j, k) = u_{\max}, u_g(j, k) = \frac{C - \mu_k(j)u_i(j, k)}{\hat{G} - \mu_k(j)}$$

(b) $\alpha < \mu_k(j) < \frac{\hat{C}}{2}$ のとき,

$$u_g(j, k) = u'_{\max}, u_i(j, k) = u_g(j, k) + \frac{C - \hat{G}u_g(j, k)}{\mu_k(j)}$$

(c) $\frac{\hat{C}}{2} < \mu_k(j) < \beta$ のとき,

$$u_i(j, k) = u'_{\max}, u_g(j, k) = \frac{C - \mu_k(j)u_i(j, k)}{\hat{G} - \mu_k(j)}$$

(d) $\beta < \mu_k(j) < \infty$ のとき,

$$u_g(j, k) = u_{\max}, u_i(j, k) = u_g(j, k) + \frac{C - \hat{G}u_g(j, k)}{\mu_k(j)}$$

ただし,

$$\alpha = \frac{|u'_{\max} - u_{\min}|}{\bar{u} - \underline{u}} \hat{G}, \quad \beta = \frac{|u_{\max} - u_{\min}|}{\bar{u} - \underline{u}} \hat{G}$$

ii) 不確実性範囲の更新とパラメータ推定値




Fig. 5: Input and output data for impulse response identification.

(a) $\mu_k(j) \neq 0$ のとき,

$\mu_k(j)C'(j, k) > 0 \cap s_{jk} = 1$ または

$\mu_k(j)C'(j, k) < 0 \cap s_{jk} = 0$ のとき,

$$g_k(j+1) = g_k(j), \bar{g}_k(j+1) = \mu_k(j) + \frac{\delta}{u'(j, k)}$$

その他のとき,

$$\bar{g}_k(j+1) = \bar{g}_k(j), g_k(j+1) = \mu_k(j) - \frac{\delta}{u'(j, k)}$$

(b) $\mu_k(j) = 0$ のとき,

$u_{\max} - u_{\min} > 0 \cap s_{jk} = 1$ または

$u_{\max} - u_{\min} < 0 \cap s_{jk} = 1$ のとき,

$$g_k(j+1) = g_k(j), \bar{g}_k(j+1) = \mu_k(j) + \frac{\delta}{u'(j, k)}$$

その他のとき,

$$\bar{g}_k(j+1) = \bar{g}_k(j), g_k(j+1) = \mu_k(j) - \frac{\delta}{u'(j, k)}$$

パラメータ推定値

$$\hat{g}_k(j+1) = \mu_k(j+1) = \frac{1}{2} (\bar{g}_k(j+1) + g_k(j+1))$$

iii) 精度限界 式 (3) と同様に次式となる.

$$\varepsilon_k(j) > \frac{\delta}{|u'(j, k)|} \quad (6)$$

インパルス応答の同定における入出力データの一例 ($C = 14.6, G = 7.5, 1 \leq u(t) \leq 4$ の場合) を Fig.5 に示す. 図より, u_g の変化によるステップ応答が収束した後に u_i が入力されている. 目標パラメータ $\mu(j, k)$ によって $u'(j, k)$ と $C'(j, k)$ の比が決まっているので, 制約条件のなかで最大の $u'(j, k)$ が取り得るように工夫されている.

また, 目標パラメータ μ と最適同定入力の対応関係の一例 ($C = 14.6, G = 7.5, 1 \leq u(t) \leq 4$ の場合) を Fig.6 に示す. 図より, μ が大きくなるにしたがって入力の形が変化していき, $G/2$ を境にインパルスの向きが逆転していることがわかる.

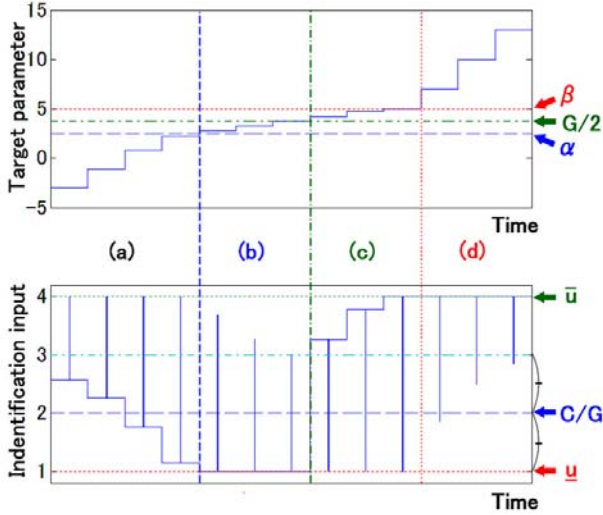


Fig. 6: Correspondence of target parameter(μ) and optimal identification input.

Step 3 インパルス応答列から伝達関数への変換

Steps1,2 で推定されたインパルス応答列 $g = [g_1, g_2, \dots, g_m]^T$ から ARX モデルのパラメータ $\theta = [a_1, \dots, a_n, b_1, \dots, b_n]^T$ に変換する方法を以下に与える．つぎのような m 行 $2n$ 列の行列 G を定義する．

$$G = \begin{bmatrix} G_{11} & G_{12} \\ G_{21} & G_{22} \end{bmatrix}$$

ただし，

$$G_{11} = \begin{bmatrix} 0 & 0 & \dots & 0 & 0 \\ -g_1 & 0 & \ddots & \ddots & 0 \\ -g_2 & -g_1 & \ddots & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 & 0 \\ -g_{n-1} & \dots & -g_2 & -g_1 & 0 \end{bmatrix}$$

$$G_{21} = \begin{bmatrix} -g_n & \dots & -g_2 & -g_1 \\ -g_{n+1} & \dots & -g_3 & -g_2 \\ \vdots & \vdots & \vdots & \vdots \\ -g_{m-1} & -g_{m-2} & \dots & -g_{m-n} \end{bmatrix}$$

$$G_{12} = I_n, \quad G_{22} = O$$

すると、 θ は次式より計算できる．

$$\hat{\theta} = (G^T G)^{-1} G^T g$$

以上の手順より、バイナリセンサを用いた ARX モデルの同定が可能となった．

3.3 数値例

提案法の有効性を検証するために、これまでと同様に閾値 $C = 14.6$ のバイナリセンサを仮定して、数値シミュレーションを行った．

シミュレーションの条件は以下のとおりである．同定対象のシステムは 2 次 ARX モデルで、パラメータは $\theta = [-1.5, 0.7, 1, 0.5]^T$ とし、同定する FIR モデルの次数は $m = 30$ とした．入力 $u(t)$ は $1 \leq u(t) \leq 4$




Fig. 7: Input and output data for identification.




Fig. 8: ARX estimates(a_1, a_2, b_1, b_2).

の制限をもち、各ステップのインパルス応答 g_k の不確実性範囲をすべて $\Omega_k(0) = [-10, 10]$ とおいた．外乱 d として $N(0, 0.01)$ の正規乱数を入力し、外乱を半径 $\delta = 3\sigma = 0.03$ の有界外乱と仮定した．また、確定的同定の切り替え条件を $\gamma = \sigma$ とおき、全体の同定にかかる時間コストを $N = 16,000$ とした．そして、シミュレーションでの G の推定精度を上げるため、定常ゲインでは確率的同定に時間コスト $N_{gs} = 1,000$ を費やした．同定結果(入出力, ARX 推定値, MSE)を Figs.7~9 に示す．図より、ARX モデルは正しく推定されていることがわかった．

3.4 同定法の改良

前節の結果より、提案法によって ARX モデルの同定が可能であることが明らかになったが、まだ改良の余地を残している．以下では、提案法の入力系列について工夫する．

Fig.7 の初期部分を拡大したものを Fig.10 に示す．シミュレーションの条件において全てのパラメータ g_k に対して同じ不確実性範囲 $\Omega_k(0)$ を与えたために、初期において全く同じ入力が続いている．各パラメータ g_k はそれぞれ観測のタイミングが異なるだけなので同じ入力を用いるなら別々に同定する必要はなく、む




Fig. 9: MSE of FIR model and ARX model.




Fig. 10: Input and output data for identification.

だ時間ステップが (特に初期において) 消費されている．そこで、同じ不確実性範囲をもつパラメータ g_k は 1つの同定グループ $idGroup$ にまとめ、同じ同定入力を利用させるようにアルゴリズムを改良した．前節と同様の条件のもと、このアルゴリズムを用いた場合の同定結果 (入出力と MSE) を Figs.11 ~ 12 に示す．

図より、インパルス応答の同定段階で初期において更新間隔が狭まって、全体の時間コスト N を大幅に抑えることができている．インパルス応答の形にもよるので定量的な解析は難しいが、この改良によって同定速度は数倍向上するものと思われる．また、 m^2 オーダがかかると思われていたインパルス応答の同定段階を大幅に圧縮できたことにより、同定精度も FIR モデルの次数 m に対してそれほどセンシティブではなくなった (改良したアルゴリズムでは $m = 30$ から $m = 40$ に変えても性能差はあまりない)．これによって、ある程度の余裕をもたせた m の選択が可能になるものと思われる．




Fig. 11: Input and output data for identification with improved input sequence.




Fig. 12: MSE of FIR model and ARX model with improved input sequence.

4 おわりに

Wang らにより提案されたバイナリセンサを用いたシステム同定法では同定入力に関する制約が存在し、実システムの同定問題への適用が難しかった．本報告では、この問題点を解決する新しいバイナリセンサを用いた ARX モデルのシステム同定法を提案し、酸素センサを模擬した数値シミュレーション例を通してその有効性を明らかにした．バイナリセンサ出力からシステム同定を行うことができる提案法は、産業界のさまざまな分野への応用が期待できる．なお、提案法の精度限界に関する考察、有界でない外乱の影響などについては、稿を改めて報告したい．

参考文献

- 岡田, 奥田, 足立, 丹羽, 梶谷, 橋本: 可変忘却要素を用いたオンライン同定法による自動車排気ガス用触媒のモデリングと劣化診断, 電学論 D, 126-12, 637/1644 (2006)
- 岡田, 足立, Maciejowski: 非線形性をもつセンサを用いたシステム同定, 計測自動制御学会論文集, 41-2, 142/148 (2005)
- Le Yi Wang, Ji-Feng Zhang and G.George Yin :System Identification Using Binary Sensors, IEEE Trans. on Automatic Control, 48-11, 1892/1907 (2004)