

## Nieparametryczna identyfikacja charakterystyk statycznych

WŁODZIMIERZ GREBLICKI

*(Maszynopis wpłynął 19 listopada 1972)*

W pracy przedstawiono nieparametryczną metodę identyfikacji charakterystyk statycznych. Wykorzystano w niej nieparametryczne sposoby estymacji nieznanymi gęstościami prawdopodobieństwa. Rozpatrzono dwa przypadki, gdy gęstość prawdopodobieństwa sygnału wejściowego jest znana i nieznaną. Wykazano, że odpowiednie ciągi charakterystyk modeli są zbieżne do funkcji regresji pierwszego rodzaju, gdy ilość obserwacji wejścia i wyjścia wzrasta.

### 1. Wstęp

Przy identyfikacji charakterystyk statycznych w warunkach probabilistycznych nieznaną charakterystykę obiektu aproksymuje się z reguły funkcjami z pewnej, dość arbitralnie wybranej klasy, co sprowadza zadanie do znalezienia funkcji regresji II rodzaju [1, 3, 4]. Najlepsza, w przyjętej klasie, charakterystyka różni się jednak od charakterystyki najlepszej w ogóle. Ponadto, otrzymany model zależy od rozkładu prawdopodobieństwa sygnału wejściowego, co powoduje, że w sytuacji, gdy po zakończeniu procesu identyfikacji rozkład ten zmieni się, to model przestanie być najlepszy nawet w swojej klasie. Klasę modeli ogranicza się także w sposób pośredni poprzez aproksymację nieznanymi rozkładów prawdopodobieństwa funkcjami z określonej klasy [2].

Powyższych wad i niedogodności można uniknąć, gdy nieznaną funkcję regresji I rodzaju estymuje się metodami nieparametrycznymi [5]. Jak wykazano w poniższej pracy, taki sposób postępowania pozwala, dla kwadratowego wskaźnika jakości identyfikacji, otrzymać model najlepszy wśród wszystkich możliwych modeli. Udowodniono, że otrzymany tą drogą nieparametryczny estymator funkcji regresji I rodzaju jest zgodny.

## 2. Przedstawienie problemu

W pracy identyfikuje się obiekt statyczny o wejściu skalarnym  $u$ , skalarnym wyjściu  $y$ , na który działają zakłócenia natury losowej. Powodują one, że nawet przy ustalonym wejściu wyjście zmieniałoby się losowo. Własności obiektu charakteryzuje warunkowa gęstość prawdopodobieństwa  $f(y/u)$ , o której zakłada się, że nie zmienia się podczas eksperymentu. Własności losowego sygnału wejściowego określa gęstość  $f_u(u)$ . Zarówno obiekt, jak i wejście są stacjonarne, łączna gęstość  $f(u, y)$  jest więc stała. Wejście  $u_n$  i wyjście  $y_n$  zaobserwowane w chwili  $n$  są zatem realizacjami zmiennych losowych  $U_n$  i  $Y_n$  o łącznej gęstości  $f(u, y)$ . Ponadto  $U_n, Y_n$  i  $U_m, Y_m$  są dla  $n \neq m$  stochastycznie niezależne.

Zadanie identyfikacji polega na znalezieniu charakterystyki  $\Phi(u)$  modelu, dla której wskaźnik

$$\int_u \int_y (y - \Phi(u))^2 f(u, y) du dy$$

osiąga najmniejszą wartość. Charakterystyka najlepszego modelu jest, jak wiadomo, funkcją regresji pierwszego rodzaju i wyraża się wzorem

$$\Phi^*(u) \stackrel{\text{def}}{=} \frac{1}{f_u(u)} \int_y y f(u, y) dy. \quad (1)$$

Eksperyment prowadzony jest w warunkach, gdy gęstość  $f(y/u)$ , która charakteryzuje obiekt, nie jest znana. Rozważymy przy tym dwa przypadki, gdy znane są własności statystyczne sygnału wejściowego (tzn. gęstość  $f_u(u)$ ) oraz, gdy gęstość  $f_u(u)$  nie jest znana. Jedyną informacją o obiekcie są obserwacje

$$u_1, y_1; u_2, y_2; \dots; u_n, y_n.$$

Na ich podstawie nieznaną charakterystykę  $\Phi^*(u)$  estymuje się wyrażeniem

$$\Phi'_n(u) \stackrel{\text{def}}{=} \frac{1}{nh(n)f_u(u)} \sum_{i=1}^n y_i K\left(\frac{u-u_i}{h(n)}\right) \quad (2)$$

w przypadku, gdy gęstość  $f_u(u)$  jest znana oraz według wzoru

$$\Phi''_n(u) \stackrel{\text{def}}{=} \frac{\sum_{i=1}^n y_i K\left(\frac{u-u_i}{h(n)}\right)}{\sum_{i=1}^n K\left(\frac{u-u_i}{h(n)}\right)}, \quad (3)$$

gdy gęstość ta jest nie znana;  $h(n)$  jest pewnym ciągiem liczb, a  $K(u)$  odpowiednio dobraną funkcją.

Wykażemy, że określone w ten sposób nieparametryczne estymatory funkcji regresji  $\Phi^*(u)$  są zgodne przy właściwym wyborze ciągu  $h(n)$  i funkcji  $K(u)$ .

### 3. Zbieżność procesu identyfikacji

Wykażemy teraz, że przy pewnych założeniach odnośnie do obiektu, ciągu  $h(n)$  i funkcji  $K(u)$  przedstawione powyżej algorytmy identyfikacji są zbieżne.

Oznaczmy jeszcze przez  $U$  i  $Y$  zmienne losowe o łącznej gęstości  $f(u, y)$ .

#### TWIERDZENIE

Jeżeli

$$EY^4 < \infty, \quad (4)$$

$$\left. \begin{aligned} \sup_u |K(u)| < \infty, \quad \int_u K(u) du = 1, \quad \int_u |K(u)| du < \infty, \\ \int_u K^4(u) du < \infty, \quad \lim_{|u| \rightarrow \infty} |uK(u)| = 0 \end{aligned} \right\} \quad (5)$$

oraz

$$h(n) > 0, \quad \lim_{n \rightarrow \infty} h(n) = 0, \quad \lim_{n \rightarrow \infty} nh^2(n) = \infty, \quad (6)$$

to

$$\frac{1}{nh(n)f_u(u)} \sum_{i=1}^n Y_i K\left(\frac{u-U_i}{h(n)}\right) \rightarrow \Phi^*(u) \quad (7)$$

i

$$\frac{\sum_{i=1}^n Y_i K\left(\frac{u-U_i}{h(n)}\right)}{\sum_{i=1}^n K\left(\frac{u-U_i}{h(n)}\right)} \rightarrow \Phi^*(u) \quad (8)$$

według prawdopodobieństwa, gdy  $n \rightarrow \infty$ , w punktach  $u$ , w których zarówno  $f_u(u)$ , jak i  $\Phi^*(u)$  są funkcjami ciągłymi.

**Dowód**

W celu wykazania zbieżności (7) wystarczy oczywiście dowieść, że

$$\frac{1}{nh} \sum_{i=1}^n Y_i K\left(\frac{u-U_i}{h}\right) \rightarrow \int_y yf(u, y) dy \quad (9)$$

(zamiast  $h(n)$  będziemy pisać  $h$ ). Zauważmy w tym celu, że

$$\begin{aligned} E \left\{ \frac{1}{nh} \sum_{i=1}^n Y_i K\left(\frac{u-U_i}{h}\right) - \int_y yf(u, y) dy \right\}^2 = \\ = \text{var} \left[ \frac{1}{nh} \sum_{i=1}^n Y_i K\left(\frac{u-U_i}{h}\right) \right] + |E \left\{ \frac{1}{nh} \sum_{i=1}^n Y_i K\left(\frac{u-U_i}{h}\right) \right\} - \\ - \int_y yf(u, y) dy|^2. \quad (10) \end{aligned}$$

Wykażemy teraz, że obydwa składniki powyższej sumy dążą do zera, gdy  $n \rightarrow \infty$ .

Dla pierwszego z nich otrzymuje się

$$\begin{aligned} \text{var} \left[ \frac{1}{nh} \sum_{i=1}^n Y_i K \left( \frac{u - U_i}{h} \right) \right] &= \frac{1}{nh^2} \text{var} \left[ Y K \left( \frac{u - U}{h} \right) \right] \leq \\ &\leq \frac{1}{nh^2} E \left\{ Y^2 K^2 \left( \frac{u - U}{h} \right) \right\} \leq \frac{1}{nh^2} (E Y^4)^{1/2} \left( E K^4 \left( \frac{u - U}{h} \right) \right)^{1/2} = \\ &\leq \frac{1}{nh^2} E Y^2 \cdot [E K^4(u)]^{1/2} = \frac{1}{nh^{3/2}} (E Y^4)^{1/2} \left( \frac{1}{h} \int_v K^4 \left( \frac{v}{h} \right) f_u(u-v) dv \right)^{1/2}. \end{aligned}$$

Z twierdzenia 1A podanego przez Parzena w pracy [6] oraz założeń (5) i (6) wynika, że

$$\lim_{n \rightarrow \infty} \frac{1}{h} \int_v K^4 \left( \frac{v}{h} \right) f_u(u-v) dv = f_u(u) \int_u K^4(u) du$$

w punktach ciągłości gęstości  $f_u(u)$ , skąd wnioskujemy, że

$$\lim_{n \rightarrow \infty} \text{var} \left[ \frac{1}{hn} \sum_{i=1}^n Y_i K \left( \frac{u - U_i}{h} \right) \right] = 0.$$

W celu wykazania zbieżności do zera drugiego składnika sumy (10) zauważmy, że

$$E \left\{ \frac{1}{nh} \sum_{i=1}^n Y_i K \left( \frac{u - U_i}{h} \right) \right\} = \frac{1}{h} \int_y \int_v y K \left( \frac{v}{h} \right) f(u-v, y) dy dv$$

oraz

$$\int_y y f(u, y) dy = \frac{1}{h} \int_y \int_v y K \left( \frac{v}{h} \right) f(u, y) dy dv.$$

Zatem

$$\begin{aligned} w_n &\stackrel{\text{def}}{=} E \left\{ \frac{1}{nh} \sum_{i=1}^n Y_i K \left( \frac{u - U_i}{h} \right) - \int_y y f(u, y) dy \right\} = \\ &= \frac{1}{h} \int_y \int_v y [f(u-v, y) - f(u, y)] K \left( \frac{v}{h} \right) dv dy. \end{aligned}$$

Podzielmy teraz prostą całkowania względem zmiennej  $v$  na dwa obszary, w których odpowiednio  $|v| \leq \delta$  i  $|v| > \delta$ . Wówczas

$$\begin{aligned} |w_n| &\leq \sup_{|v| \leq \delta} \left| \int_y y f(u-v, y) dy - \int_y y f(u, y) dy \right| \int_{|v| \leq \delta/h} |K(v)| dv + \\ &+ \int_{|v| > \delta} \left[ \int_y \frac{1}{|v|} y f(u-v, y) dy \right] \frac{|v|}{h} K \left( \frac{v}{h} \right) dv + \left| \int_y y f(u, y) dy \right| \frac{1}{h} \int_{|v| > \delta} |K \left( \frac{v}{h} \right)| dv \leq \end{aligned}$$

$$\begin{aligned}
&\leq \sup_{|v| \leq \delta} |\Phi^*(u-v)f_u(u-v) - \Phi^*(u)f_u(u)| \left| \int_v^u |K(v)| dv \right| + \\
&+ \frac{1}{\delta} \sup_{|v| > \delta/h} |vK(v)| \int_v^u \int_y |y|f(v,y) dv dy + |\Phi^*(u)f_u(u)| \int_{|v| > \delta/h} |K(v)| dv \leq \\
&\leq \sup_{|v| > \delta} |\Phi^*(u-v)f_u(u-v) - \Phi^*(u)f_u(u)| \int_v^u |K(v)| dv + \\
&+ \frac{1}{\delta} E|Y| \sup_{|v| > \delta/h} |vK(v)| + |\Phi^*(u)f_u(u)| \int_{|v| > \delta/h} |K(v)| dv.
\end{aligned}$$

Dla każdego  $\varepsilon > 0$  można teraz wybrać takie  $H > 0$  oraz odpowiednio małą liczbę  $\delta > 0$ , aby otrzymane wyrażenie było mniejsze od  $\varepsilon$  dla wszystkich  $h < H$ , co kończy dowód zbieżności (9), a zatem i (7).

Parzen wykazał [6], że przy założeniach (5) i (6)

$$\frac{1}{nh(n)} \sum_{i=1}^n K\left(\frac{u-U_i}{h(n)}\right) \rightarrow f_u(u)$$

w punktach ciągłości gęstości  $f_u(u)$ . Stąd oraz z udowodnionej powyżej zbieżności (9) wynika teza (8), co kończy dowód.

#### 4. Algorytmy identyfikacji

Dla różnych funkcji  $K(u)$  otrzymuje się różne ciągi charakterystyk modeli. Jeśli np.

$$K(u) = \frac{1}{2} e^{-|u|}$$

to

$$\Phi'_n(u) = \frac{1}{2nh(n)f_u(u)} \sum_{i=1}^n y_i e^{-\frac{|u-u_i|}{h(n)}}, \quad \Phi''_n(u) = \frac{\sum_{i=1}^n y_i e^{-\frac{|u-u_i|}{h(n)}}}{\sum_{i=1}^n e^{-\frac{|u-u_i|}{h(n)}}}.$$

Dla

$$K(u) = \frac{1}{\sqrt{\pi}} e^{-u^2}$$

otrzymuje się

$$\Phi'_n(u) = \frac{1}{\sqrt{\pi nh(n)f_u(u)}} \sum_{i=1}^n y_i e^{-\frac{(u-u_i)^2}{h^2(n)}}, \quad \Phi''_n(u) = \frac{\sum_{i=1}^n y_i e^{-\frac{(u-u_i)^2}{h^2(n)}}}{\sum_{i=1}^n e^{-\frac{(u-u_i)^2}{h^2(n)}}}.$$

Jeśli natomiast

$$K(u) = \frac{1}{\pi} \frac{1}{1+u^2}$$

to

$$\Phi'_n(u) = \frac{1}{\pi n h(n) f_u(u)} \sum_{i=1}^n \frac{y_i h^2(n)}{h^2(n) + (u - u_i)^2}, \quad \Phi''_n(u) = \frac{\sum_{i=1}^n \frac{y_i}{h^2(n) + (u - u_i)^2}}{\sum_{i=1}^n \frac{1}{h^2(n) + (u - u_i)^2}}.$$

Pewna dowolność istnieje także przy wyborze ciągu  $h(n)$ . Jeśli wybrać go zgodnie ze wzorem

$$h(n) = c^2 n^{-\alpha},$$

to  $\alpha$  musi spełniać nierówność

$$0 < \alpha < \frac{1}{2}.$$

## 5. Zakończenie

Przedstawiony w pracy sposób identyfikacji pozwala otrzymać ciąg charakterystyk modeli, który jest zbieżny do funkcji regresji I rodzaju. Wykorzystano w tym celu metody nieparametrycznej estymacji gęstości prawdopodobieństwa [6]. Jedynym założeniem, jakie czyni się o badanym obiekcie, jest warunek (4), który dla każdego przemysłowego obiektu jest spełniony z uwagi na ograniczone wyjście.

### *Nonparametric Identification of Static Plants*

In the paper the nonparametric method for a static plant identification is presented. The unknown regression function is estimated with a formula

$$\Phi'_n(u) = \frac{1}{n h(n) f_u(u)} \sum_{i=1}^n y_i K\left(\frac{u - u_i}{h(n)}\right)$$

if the density function  $f(n)$  of the input is known and with an expression

$$\Phi''_n(u) = \frac{\sum_{i=1}^n y_i K\left(\frac{u - u_i}{h(n)}\right)}{\sum_{i=1}^n K\left(\frac{u - u_i}{h(n)}\right)}$$

if the density  $f_u(u)$  is unknown;  $u_i$  and  $y_i$  are observed input and output values. It is proved that if the sequence  $h(n)$  and the function  $K(u)$  are suitably chosen then  $\Phi'_n(u)$  and  $\Phi''_n(u)$  converge to the regression function  $E(y/u)$  as  $n$  increases.

*Непараметрическая идентификация статических объектов*

В работе описывается непараметрический метод восстановления характеристики случайного преобразователя. Неизвестная функция регрессии оценивается следующим выражением:

$$\Phi'_n(u) = \frac{1}{nh(n)f_n(u)} \sum_{i=1}^n y_i K\left(\frac{u-u_i}{h(n)}\right)$$

в случае, когда плотность распределения  $f_n(u)$  входного сигнала известна и при помощи формулы

$$\Phi''_n(u) = \frac{\sum_{i=1}^n y_i K\left(\frac{u-u_i}{h(n)}\right)}{\sum_{i=1}^n K\left(\frac{u-u_i}{h(n)}\right)}$$

если плотность  $f_n(u)$  неизвестна,  $u_i$  и  $y_i$  наблюдаемые сигналы на входе и выходе. Доказано, что если последовательность  $h(n)$  и функция  $K(u)$  выбраны соответствующим образом, то  $\Phi'_n(u)$  и  $\Phi''_n(u)$  сходятся с функцией регрессии  $E(y/u)$  при возрастающем  $n$ .

**Literatura**

- [1] Z. Bubnicki, *Metody aproksymacyjne w identyfikacji obiektów, Modele matematyczne i identyfikacja obiektów*, Wyd. Ossolineum, Wrocław 1972.
- [2] Z. Bubnicki, *System Identification via Estimation of Probability Distribution and Moments*, 2nd IFAC Symposium on Identification, Prague 1970.
- [3] J. Z. Суркин, *Адаптация, обучение и самообучение в автоматических системах*, Автоматика и телемеханика, nr 1, 1966.
- [4] W. Greblicki, *Zastosowanie metod określania empirycznych rozkładów prawdopodobieństwa w identyfikacji obiektów. Modele matematyczne i identyfikacja obiektów*, Wyd. Ossolineum, Wrocław 1972.
- [5] W. Greblicki, *Nieparametryczna identyfikacja obiektów statycznych*, Prace V KKA, Gdańsk 1971.
- [6] E. Parzen, *On Estimation of Probability Density Function and Mode*, Ann. Math. Statist. vol. 32, 1962.

DR INŻ. W. GREBLICKI  
 INSTYTUT CYBERNETYKI TECHNICZNEJ, POLITECHNIKA WROCŁAWSKA  
 JANISZEWSKIEGO 11/17, 50-372 WROCŁAW, POLSKA