

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. Jediną 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

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

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

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

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

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

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

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

oraz

$$\int_{-\infty}^{\infty} y f(u, y) dy = \frac{1}{h} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} y K \left(\frac{v}{h} \right) f(u, y) dy dv.$$

Zatem

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

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

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

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

Dla każdego $\varepsilon > 0$ można teraz wybrać takie $H > 0$ oraz odpowiednio małą liczbę $\delta > 0$, aby otrzymane wyrażenie było mniejsze od ε 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 α 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