

Tadeusz HOCZEK

POLITECHNIKA ŚLĄSKA, WYDZIAŁ AUTOMATYKI ELEKTRONIKI I INFORMATYKI
ul. Akademicka 16, 44-100 Gliwice

Identyfikacja prostych modeli dynamiki poprzez iterowany algorytm genetyczny

Mgr inż. Tadeusz HOCZEK

Doktorant wydziału Automatyki Elektroniki i Informatyki Politechniki Śląskiej. Główny kierunek badań to modelowanie, identyfikacja systemów liniowych oraz wykorzystanie algorytmów genetycznych w sterowaniu procesów przemysłowych. Zawodowo zajmuje się zagadnieniami sterowania procesów ciągłych w przemyśle chemicznym.



e-mail: thoczek@gmail.com

Streszczenie

W niniejszym artykule zaproponowano metodę identyfikacji opartą na iterowanym algorytmie genetycznym dla systemów FOPDT (First Order Plus Dead Time) oraz SOPDT (Second Order Plus Dead Time), w których występują zakłócenia o znacznej amplitudzie. Zbadano również wpływ poziomu zakłóceń na dokładność identyfikacji systemu.

Słowa kluczowe: FOPDT, SOPDT, algorytmy genetyczne, identyfikacja, modelowanie.

Identification of simple dynamics models by iterated genetic algorithm

Abstract

An iterated genetic algorithm for identification of FOPDT (First Order Plus Dead Time) and SOPDT (Second Order Plus Dead Time) models is proposed in the paper. It is designed for high noise/signal ratio systems. The method proposed requires a little knowledge about the identified system, including determination of search space borders. It may be also used for approximation of higher order systems by FOPDT or SOPDT models. The identification results were compared with those obtained from other methods, such as the traditional "two point" method and modern Matlab® ident(.) tool. Additionally, the impact of interference/noise level on the model identification accuracy was analyzed. The identified model can be used for tuning PID regulators or can be implemented in more advanced control schemas e.g. Smith predictor or MPC. System identification with use of a genetic algorithm offers numerous advantages and may be implemented as an efficient alternative to classical methods, especially when the interference level is high.

Keywords: FOPDT, SOPDT, genetic algorithm, system identification.

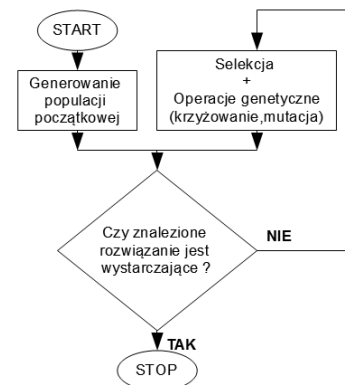
1. Wprowadzenie

Identyfikacja systemu sterowania to wieloetapowy proces, który często bywa bardzo pracochłonny i czasochłonny. Czasami zdarza się, że pomiary uzyskane podczas eksperymentu nie pozwalają nam na jednoznaczne ustalenie parametrów modelu w tradycyjny graficzny sposób. Spowodowane jest to wysokim poziomem zakłóceń w mierzonym sygnale. Algorytmy genetyczne przekształcają zadanie identyfikacji systemu w poszukiwanie optimum funkcji wielu zmiennych. Zaproponowana metoda polega na bezpośredniej estymacji współczynników modelu z danych procesowych. Zastosowanie jej jako metody doboru parametrów modelu powinno pozwolić na identyfikację systemu z dużą szybkością i dokładnością pomimo występujących w nim zakłóceń.

2. Algorytmy genetyczne

Algorytmy genetyczne to rodzina algorytmów, które naśladują proces ewolucji zachodzący w środowisku naturalnym. Ewolucję po raz pierwszy opisał Charles Darwin w książce pt.: "O powstaniu

gatunków" z 1895 r. Podobnie jak w przyrodzie algorytmy genetyczne opierają się na zjawisku doboru naturalnego oraz dziedziczenia. Dobór naturalny w przypadku algorytmów genetycznych polega na dopuszczeniu do reprodukcji tylko tych osobników z spośród populacji, które są najlepiej przystosowane do środowiska (funkcji celu). Następnie osobniki te przechodzą przez fazę krzyżowania, gdzie przekazują swoim potomkom informację zawartą w ich genach. W ciągu kolejnych iteracji tak działającego algorytmu, kolejne generacje są coraz lepiej przystosowane do środowiska (funkcji celu). Zadaniem algorytmów genetycznych jest poszukiwanie optymalnego rozwiązania danej funkcji, jeżeli sposób jego poszukiwania nie jest znany lub jest bardzo złożony obliczeniowo.



Rys. 1. Ogólny schemat działania algorytmu genetycznego
Fig. 1. General scheme of a genetic algorithm

Do celów sterowania algorytmy genetyczne zostały użyte po raz pierwszy w roku 1988 przez Goldberga [6] i od tej chwili są coraz szerzej stosowane jako sposób optymalizacji zastępując klasyczne metody. Zostały również wykorzystane do celów identyfikacji systemów [7, 12, 13, 15, 17]. Wszystkie one polegają na globalnym przeszukiwaniu przestrzeni rozwiązań w celu identyfikacji parametrów modelu.

3. Identyfikacja systemu sterowania

Proces identyfikacji systemów można podzielić na kilka odrębnych etapów. Pierwszy z nich to eksperyment identyfikujący. Ma on za zadanie zebranie pomiarów z wejścia oraz wyjścia systemu. Do tego celu stosuje się dodatkowe pobudzenie układu ustalonym sygnałem. W przeprowadzonych eksperymentach wykorzystany został sygnał tzw. skoku jednostkowego. Kolejnym etapem jest ustalenie struktury modelu. Najczęściej polega on na wybraniu jednej z opisywanych w literaturze. Tu skupiono się na prostych modelach w postaci FOPDT oraz SOPDT. Trzecim etapem jest estymacja parametrów systemu, aby jak najdokładniej oddawał realne zachowanie rzeczywistego układu. Kolejnym krokiem jest implementacja tak zidentyfikowanego modelu w strukturze sterowania oraz ocena wyników. Jeżeli są one dostatecznie dobre, możemy uznać proces identyfikacji za zakończony. Jednak, gdy otrzymane wyniki z wybranym modelem nie są zadowalające, należy przeanalizować dotychczasowe dane i zidentyfikować etap, na którym został popełniony błąd. Następnie należy rozpocząć ponowną identyfikację od tego punktu. Można powiedzieć, że identyfikacja systemu $G:U \rightarrow Y$ polega na znalezieniu takiego \hat{G} , aby błąd estymacji był jak najmniejszy $\sum e(t) = (Gu)(t) - (\hat{G})(t)$.

Modele procesów tworzone dla celów sterowania przez automatyków to w przeważającej większości *uproszczone* modele dynamiki w postaci transformatorowych funkcji. Są one opisane często inercją 1-szego rzędu z dodatkowym opóźnieniem transportowym 1a), b) [14]. W bardziej wymagających układach, lub gdy regulacja z tak uzyskanym modelem jest niezadowolająca, stosuje się inercję 2-giego rzędu lub wyższą.


$$G(s) = \frac{K}{T_S + 1} e^{-sT_d} \quad (1)$$

$$G(s) = \frac{K}{(T_1 + 1)(T_2 + 1)} e^{-sT_d} \quad (2)$$

Identyfikację modelu równaniami (1), (2) często przeprowadza się poprzez podanie skoku jednostkowego na wejście systemu i rejestracji jego odpowiedzi. Następnie estymuje się parametry tj. dla FOPDT wzmacnienie K , stałą czasową T oraz czas opóźnienia T_d . Dla SOPDT rozróżniamy dwie stałe czasowe T_1 oraz T_2 . W praktyce do tego celu często wykorzystywane są sposoby graficzne, które obarczone są niejednokrotnie sporym błędem, a w systemach z dużymi zakłóceniami poprawna identyfikacja tymi metodami jest praktycznie niemożliwa. Jako jedni z pierwszych, graficzny sposób wyznaczania parametrów modelu FOPDT opracowali Ziegler i Nichols [1]. Polega ona na wyznaczeniu stycznej w punkcie przegięcia na wykresie przebiegu odpowiedzi skokowej systemu - na tej podstawie oblicza się parametry modelu FOPDT. Dla SOPDT zostały opracowane podobne sposoby [3, 5, 8]. Jednak główną wadą ww. metod jest trudność określenia punktu przegięcia dla danych uzyskanych z procesu. Jako rozwiązanie tego problemu, opracowano sposoby opierające się na wyznaczeniu dwóch lub większej ilości punktów na wykresie odpowiedzi skokowej do estymacji parametrów modelu [4, 9]. Jednym z takich sposobów jest metoda dwóch punktów. Polega ona na wyznaczeniu na wykresie odpowiedzi skokowej punktów odpowiadających kolejno $y(t_1) = 0.28K$ oraz $y(t_2) = 0.4K$. Po ich wyznaczeniu można obliczyć wartości $T = 5.5 \cdot (t_2 - t_1)$ oraz $T_d = 2.8 \cdot t_1 - 1.8 \cdot t_2$. Równocześnie pracowano nad innymi sposobami, które miały umożliwić identyfikację systemu w obecności zakłóceń np. nad metodą powierzchni [9]. Polega ona na wyznaczeniu średniego czasu ustalania $T_{ar} = A_0/K$, gdzie A_0 to powierzchnia ponad wykresem odpowiedzi skokowej ograniczona od góry wzmacnieniem K . Stałą czasową oraz czas opóźnienia oblicza się z powierzchni pod krzywą odpowiedzi skokowej ograniczoną czasem T_{ar} . Identyfikacja procesu z danych uzyskanych podczas eksperymentu skoku jednostkowego to jeden z najprostszych sposobów, dlatego też jest on powszechnie stosowany przez automatyków. Uzyskany model wykorzystywany jest najczęściej do obliczenia parametrów regulatora PID. Algorytmy genetyczne idealnie nadają się do zadania estymacji parametrów równań (1), (2) wprost z danych eksperymentalnych. Nie wymagają one praktycznie żadnej początkowej wiedzy o obiekcie, a funkcję celu można zdefiniować jako minimum sumy kwadratów błędów $\sum_{i=1}^N (y_i - \hat{y}_i)^2$. Dodatkowo algorytmy te potrafią w pewnych granicach linearyzować nieliniowości wynikające z zakłóceń występujących w układzie. Dotychczasowe zastosowanie algorytmów genetycznych do identyfikacji obiektów FOPDT oraz SOPDT [7, 17] polega na przeszukiwaniu dużej wielowymiarowej przestrzeni rozwiązań co jest bardzo czasochłonne, a taki algorytm czasami zawodzi nie znajdując rozwiązania optymalnego.

4. Proponowana metoda

Przestrzeń funkcji celu w zależności od parametrów T oraz T_0 dla modelu FOPDT jest przedstawiona na rysunku 2.




Rys. 2. Przestrzeń poszukiwań parametrów T oraz T_0 dla modelu FOPDT
Fig. 2. Search space of parameters T and T_0 for the FOPDT model

W całym zakresie parametrów jest ona zbieżna do jednego optimum. Dla takiego założenia możliwa jest konwersja zadania znalezienia minimum globalnego na wielokrotne wyszukiwanie minimum lokalnych w wyznaczonych obszarach. Zadanie to możemy podzielić na wiele poszukiwań, zmieniając w każdym kolejnym przestrzeń wyszukiwania tak, aby algorytm miał możliwość podążania w kierunku wartości minimum funkcji celu.

Po zakończeniu poszukiwania w zadanym wycinku przestrzeni, współczynniki najlepszego osobnika porównywane są z zakresem estymowanych parametrów.

Jeżeli osobnik zbliża się do którejś z wartości granicznych obszaru, to jest ona przesuwana, tak aby umożliwić kolejnemu wywołaniu algorytmu przeszukiwanie obszaru znajdującego się dalej w kierunku jego podążania. Kolejne wywołania algorytmu będą kierowały się w stronę minimum globalnego. Na rysunku 3 przedstawiono sposób wyszukiwania minimum. Widać na nim zakresy przeszukiwań „jednostkowych” oraz sposób podążania algorytmu w kierunku minimum globalnego. Aby zachować najlepszy zestaw genów pomiędzy wywoływaniami algorytmu, najlepszy osobnik zostaje dodany do populacji podczas inicjowania kolejnego wyszukiwania. Pozostałe osobniki rozmieszczane są w losowy sposób w przestrzeni poszukiwania. Sekwencja ta jest kontynuowana, dopóki kolejne wywołania znajdują rozwiązania z mniejszą wartością funkcji celu.



Rys. 3. Przestrzeń rozwiązań wraz ze ścieżką poszukiwań
Fig. 3. Solution space with the search path

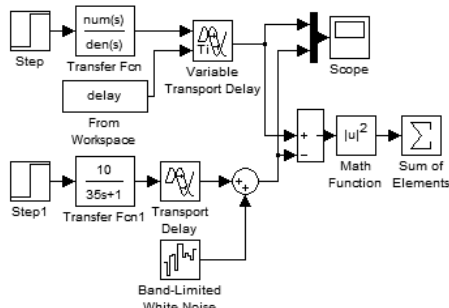
5. Badania porównawcze

Dla celów symulacji identyfikacji systemu wykorzystano model w postaci:

$$G(s) = \frac{10}{35s + 1} e^{-45s} \quad (3)$$

W celu estymacji parametrów systemu użyto funkcję $ga(\cdot)$ z pakietu MATLAB funkcja ta służy do znajdowania minimum funkcji z wykorzystaniem algorytmu genetycznego.

Na rys. 4 przedstawiona jest struktura z programu SIMULINK wykorzystana do celów identyfikacji. Wynikiem przeprowadzonych symulacji jest suma kwadratów błędów w całym przedziale czasowym pomiędzy wyjściami modeli. Aby zasymulować zakłócenia, które występują w rzeczywistych układach, dodany został do wyjścia układu referencyjnego szum o rozkładzie normalnym. Amplituda sygnału zakłócającego będzie regulowana dla kolejnych prób identyfikacji, aby sprawdzić jaki wpływ ma poziom zakłóceń na dokładność estymowanych parametrów modelu.



Rys. 4. Model układu służący identyfikacji systemu
Fig. 4. The simulation model used for identification

Parametry algorytmu genetycznego:

Populacja: 7

Liczba zmiennych: 3

Liczba generacji: 4

Funkcja skalująca: Liniowa

Selekcja: Turniejowa

Prawdopodobieństwo krzyżowania: 0.8

Metoda krzyżowania: Scattered

Mutacja: Adaptacyjna

Aby zbadać wpływ zakłóceń występujących w systemie na estymowane parametry modelu, przeanalizowano 5 prób. Każda wykonana jest z innym poziomem zakłóceń odpowiednio: bez zakłóceń, zakłócenia na poziomie: $0.01 \cdot K$, $0.05 \cdot K$, $0.1 \cdot K$ oraz $0.2 \cdot K$.

Wartości wskaźnika błęd estymacji parametrów zestawiono w tabeli 1. Estymowane współczynniki są bardzo zbliżone do parametrów modelu wzorcowego. Jak widać poziom szumu ma niewielki wpływ na dokładność identyfikacji.

Tab. 1. Zestawienie wyników identyfikacji modelu FOPDT
Tab. 1. Summary of FOPDT model identification results

Metoda Poziom zakłóceń	Proponowana metoda	Klasyczny algorytm genetyczny	Matlab „ident”	Metoda dwóch punktów
Brak zakłóceń	0.03	0.01	0	1.505
Zakłócenia $0.01 \cdot K$	0.14	0.08	0.10	11.33
Zakłócenia $0.05 \cdot K$	0.32	0.40	18.91	11.34
Zakłócenia $0.1 \cdot K$	1.2	1.54	29.33	14.65
Zakłócenia $0.2 \cdot K$	3.33	7.10	35.63	23.04


Dla porównania obok parametrów estymowanych z użyciem proponowanej metody przedstawiono wartości uzyskane przy pomocy klasycznego podejścia z wykorzystaniem algorytmów genetycznych [7, 17]. W kolejnych kolumnach pokazano atrybuty układu zidentyfikowane za pomocą narzędzia `ident()` w środowisku Matlab. Podany wskaźnik jakości jest liczony jako suma kwadratów błędów. Zastosowanie algorytmów genetycznych do identyfikacji systemu daje lepsze rezultaty, gdy poziom zakłóceń w układzie jest większy lub równy $0.05 \cdot K$. Natomiast wykorzystanie proponowanej metody pozwala na znaczne obniżenie liczby

iteracji wymaganych do znalezienia rozwiązania. Dla klasycznego podejścia, aby uzyskać porównywalne rezultaty konieczne jest przeprowadzenie ich około 2250, przy około 1600 z wykorzystaniem proponowanej metody. Sposób ten dał również większą odporność algorytmu na zakłócenia, pozwalając na bardziej dokładne zidentyfikowanie układu. Jednocześnie kolejne rozwiązania były bardziej skupione wokół minimum funkcji celu. Na rysunku 5 pokazano: przebieg pierwotny (bez zakłóceń) zidentyfikowanego systemu (1), przebieg z dodanymi zakłóceniami (2) oraz przebieg modelu, który został zidentyfikowany z sygnału zawierającego zakłócenia (3). Metoda ta równie dobrze spisuje się nie tylko, gdy rząd układu dokładnie odpowiada rządowi modelu. Nadaje się on również do aproksymacji układów wyższych rzędów układem FOPDT lub SOPDT. W tabeli zestawiono oszacowane parametry modelu SOPDT aproksymującego system w postaci:

$$G(s) = \frac{10}{(35s + 1)^5} e^{-45s} \quad (4)$$

Tab. 2. Zestawienie wyników identyfikacji modelu SOPDT
Tab. 2. Summary of SOPDT model identification results

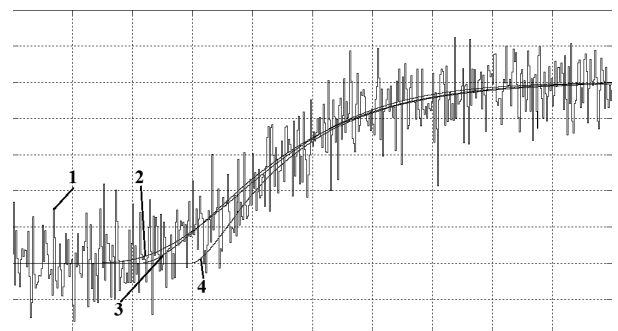
Metoda	K	T1	T2	Td	Err
Proponowana metoda	10.068	64.191	58.772	105.843	15.929
Algorytm genetyczny	10.06	58.03	63.76	106.59	15.343
Matlab (Ident)	10.04	13.97	77.28	146.99	143.58



Rys. 5. Odpowiedź skokowa obiektu i najlepszego modelu dla zakłóceń na poziomie $0.2 \cdot K$

Fig. 5. The best model step response for noise level $0.2 \cdot K$

Na rysunku 6 zestawiono dla porównania: sygnał identyfikowany (1), odpowiedź modelu referencyjnego (2), odpowiedź układu uzyskanego z wykorzystaniem algorytmów genetycznych (3) oraz reakcję modelu estymowanego przy pomocy narzędzia `ident()` w środowisku Matlab (4).



Rys. 6. Porównanie modeli aproksymujących system
Fig. 6. Comparison of approximation models

Metoda iteracyjnej identyfikacji parametrów modelu nadaje się do aproksymacji układów wyższych rzędów poprzez FOPDT oraz SOPDT.

Uzyskany model lepiej odwzorowuje realny układ w porównaniu do narzędzia `ident()` w środowisku MATLAB.

6. Wnioski

Algorytmy genetyczne są bardzo dobrym narzędziem dla celów identyfikacji procesu wprost z danych procesowych. Tak uzyskane modele mogą zostać wykorzystane do strojenia regulatora PID. Dokładność identyfikacji parametrów pozwala na użycie ich również w bardziej zaawansowanych zastosowaniach, jak np. w układzie predyktora Smitha czy MPC. Estymacja parametrów z użyciem iterowanego algorytmu genetycznego zaproponowaną metodą daje porównywalne, a w przypadku dużych zakłóceń nawet lepsze rezultaty identyfikacji od opisanych wcześniej metod. Metoda ta nie wymaga praktycznie żadnej wiedzy o identyfikowanym systemie, nawet zakres estymacji parametrów jest zmienny i zostaje wyznaczony automatycznie przez algorytm. Natomiast czas identyfikacji modeli FOPDT oraz SOPDT jest mniejszy od dotychczas prezentowanych sposobów z wykorzystaniem algorytmów genetycznych.

7. Literatura

- [1] Ziegler J.G. and Nichols N.B.: Optimum settings for automatic controllers, *Transactions of the ASME* 64:759-768 (1942).
- [2] Astrom K. J. and Eykoff P.: System Identification – A Survey. *Automatica*, 7:123-162 (1971).
- [3] Sundaresan K.R., Prasad C. C. and Krishnaswamy P.R.: Evaluating parameters from process transients, *Industrial and Engineering Chemistry Process Design and Development*, 17:237-241(1978).
- [4] Sundaresan K.R. and Krishnaswamy P.R.: Estimation of time delay, time constant parameters in time, frequency and Laplace domains, *The Canadian Journal of Chemical Engineering*, 56:257-262 (1978).
- [5] Huang C.T. and Clements W.C.: Parameter estimation for the second-order plus deadtime-model, *Industrial Engineering Chemistry Process Design and Development*, 21:601-603 (1982).
- [6] Goldberg D. E.: *Genetic Algorithms in Search, Optimization, and Machine Learning*. Addison-Wesley (1989).
- [7] Vlastu E.: *Using Genetic Algorithms in System Identification*. *Electrical Engineering* 496:85-89 (1991).
- [8] Astrom K.J. and Hagglund T.: *PID Controllers: Theory, Design and Tuning* (Second Edition, Instrument Society of America) (1995).
- [9] Bi Q., Cai W.J., Lee E.L., Wang Q.G., Hang C.C. And Zhang Y.: Robust identification of first-order plus dead-time model from step response, *Control Engineering Practice*, 7,1:71-77(1999).
- [10] Wierzchoń S.T.: *Sztuczne systemy immunologiczne. Teoria i zastosowania* (2001).
- [11] Kealy Tony and O'dwyer Aidan : Comparison of open and closed loop process identification techniques in the time domain. *Proceedings of the 3rd Wislimer Automatisation Symposium*, 1.3-4 (2001).
- [12] Ueda T., Ono I., Okamoto M.: Development of System Identification Technique Based on Real-Coded Genetic Algorithm. *Genome Informatics* 13: 387 (2002).
- [13] Vu Duong and Stubberud A.: System Identification by Genetic Algorithm. *Aerospace Conference Proceedings* 5:5-14 (2002).
- [14] Ljung L.: *Identification for Control: Simple Process Models*. LiTH-ISY-R-2465, (2003).
- [15] Sekaj I.: Genetic Algorithms for Control System Design Applications. *Journal of Cybernetics and Informatics*, 1:31-37 (2003).
- [16] Rao G.P. and Unbehauen H.: Identification of continuous-time systems. *Electrical Engineering*, 153:185-220 (2006).
- [17] Shin G.W.: Genetic Algorithm for Identification of Time Delay Systems from Step Responses, *International Journal of Control, Automation and Systems*, 5:79-85, (2007).

otrzymano / received: 13.05.2012

przyjęto do druku / accepted: 03.09.2012

artykuł recenzowany / revised paper

INFORMACJE

Nowa inicjatywa PAK

Na stronie internetowej Wydawnictwa PAK został utworzony dział: **Niepewność wyników pomiarów** w którym są zamieszczane aktualne informacje dotyczące problemów teoretycznych i praktycznych związanych z szacowaniem niepewności wyników pomiarów. W dziale znajdują się:

- aktualne informacje o publikacjach dotyczących niepewności wyników,
- informacje o przedsięwzięciach naukowo–technicznych i edukacyjnych, o tematyce związanej z niepewnością,
- dokumenty dotyczące niepewności,
- pytania do ekspertów (FAQs).

Zapraszamy:

- autorów opublikowanych prac dotyczących niepewności o nadsyłanie tekstów do zamieszczenia w tym dziale,
- organizatorów przedsięwzięć naukowo – technicznych lub edukacyjnych do nadsyłania informacji o imprezach planowanych lub odbytych,
- zainteresowanych zagadnieniami szczegółowymi do nadsyłania pytań do ekspertów.

Materiały mogą mieć formę plików lub linków do źródeł. Warunkiem zamieszczenia w tym dziale strony internetowej PAK materiałów lub linków jest przysłanie do redakcji PAK pocztą zwykłą zgody właściciela praw autorskich na takie rozpowszechnienie. Zamieszczanie i pobieranie materiałów i informacji w tym dziale strony internetowej jest bezpłatne. Redakcja PAK będzie nadzorować zawartość działu, ale za szczegółowe treści merytoryczne odpowiadają autorzy nadsyłanych materiałów.