

BADANIE ALGORYTMU IDENTYFIKACJI PARAMETRÓW MODALNYCH WYKORZYSTUJĄCEGO WIELE ROJÓW PSO POD KĄTEM ODPORNOŚCI NA ZAKŁÓCENIA POMIAROWE

ADRIAN ORZECZOWSKI ¹, MAREK A. GALEWSKI ²,
MICHAŁ R. MAZUR ³
*Politechnika Gdańska
Wydział Mechaniczny,
Katedra Mechaniki i Mechatroniki,
Gabriela Narutowicza 11/12, 80-233 Gdańsk*
¹ *adrian.orzechowski@pg.edu.pl*, ² *marek.galewski@pg.edu.pl*,
³ *mazur.m.r@gmail.com*

SŁOWA KLUCZOWE: Eksperymentalna Analiza Modalna, Sztuczna inteligencja

STRESZCZENIE

W pracy przedstawiono wpływ zakłóceń pomiarowych na skuteczność algorytmu wykorzystującego wiele rojów PSO [5] do identyfikacji parametrów modalnych w dziedzinie częstotliwości. W pracy przedstawiono wpływ poziomu szumu występującego w sygnale symulującym warunki pomiarowe przy różnych poziomach zakłóceń. Ponadto otrzymane wyniki porównano z wynikami dla metod ERA i pLSCF-d. Uzyskane rezultaty wskazują, że proponowany algorytm w większości badanych przypadków pozwolił uzyskać oszacowania parametrów obciążone niższymi błędami.

1. Wprowadzenie

Analiza modalna skupia się na badaniu parametrów dynamicznych struktur mechanicznych. Problem ten jest powszechnie znany stąd opracowanych zostało wiele metod obliczeniowych [2, 3]. Mimo tego, podejmowane są próby stworzenia alternatywnych algorytmów identyfikacji modalnej opartych m.in. na metodach Sztucznej Inteligencji (np. [4], [6]). W pracy [5] autorzy zaproponowali algorytm oparty na Optymalizacji Rojem Cząstek (ang. *Particle Swarm Optimization* – PSO) w którym użytych jest wielu współpracujących ze sobą rojów. Nowo powstałe metody wymagają

jednak weryfikacji ich odporności na zakłócenia pomiarowe, które są nieuniknione w procesie identyfikacyjnym.

Impulsowy test modalny polega na wymuszeniu drgań swobodnych badanej struktury poprzez uderzenie jej np. młotkiem. Uzyskane drgania swobodne mogą zostać opisane następującymi zależnościami:

$$y(t) = \sum_{m=1}^{nm} Y_{0m} e^{-2\pi f_m \zeta_m t} \sin(2\pi f_m \sqrt{1 - \zeta_m^2} t + \varphi_m) =$$

$$= \sum_{m=1}^{nm} Y_{0m} e^{-\beta_m t} \sin\left(\omega_m \sqrt{1 - \left(\frac{\beta_m}{\omega_m}\right)^2} t + \varphi_m\right) \quad (1)$$

gdzie:

- y - sygnał reprezentujący drgania swobodne,
- m - numer postaci,
- nm - liczba postaci,
- Y_{0m} - początkowa amplituda postaci nr m ,
- ζ_m - bezwymiarowy współczynnik tłumienia postaci nr m ,
- f_m - częstotliwość własna postaci nr m ,
- φ_m - przesunięcie fazowe postaci nr m ,
- t - czas,
- $\omega_m = 2\pi f_m$ - częstość kołowa postaci nr m , (2)
- $\beta_m = \omega_m \zeta_m$ - współczynnik tłumienia postaci nr m . (3)

Identyfikacja modalna, w związku z powyższym modelem, skupia się na znalezieniu amplitud, częstotliwości oraz współczynników tłumienia poszczególnych postaci drgań własnych badanej struktury.

2. Algorytm PSO

Podstawowy algorytm PSO został po raz pierwszy zaprezentowany w [1]. Jest on inspirowany socjalnymi zachowaniami stad ptaków w trakcie poszukiwania pożywienia. Z biegiem lat pojawiła się znaczna ilość modyfikacji algorytmu podstawowego [7] w celu zniwelowania jego podstawowych wad. Główna logika algorytmu, z uwzględnieniem inercji układu, sprowadza się do następującej formuły:

$$v_{i,d} = \omega v_{i,d} + \varphi_p r_{p,d} (p_{i,d} - x_{i,d}) + \varphi_g r_{g,d} (g_d - x_{i,d}) \quad (4)$$

gdzie:

- i - numer cząstki,
- d - numer wymiaru,
- v - prędkość cząstki,



x	- położenie cząstki,
ω	- bezwładność indywidualna,
φ	- bezwładność socjalna,
r	- zmienna stochastyczna ,
p	- odnosi się do pamięci cząstki,
g	- odnosi się do pamięci roju.

3. Analizowany algorytm

Proponowany algorytm [5] opiera się na równoległym wykorzystaniu wielu rojów PSO. Każdy z rojów odpowiedzialny jest za identyfikację odrębnej postaci drgań analizowanej struktury. Poprzez wykorzystanie mechanizmu komunikacji między rojami oraz mechanizmu dodatkowej kary, następuje separacja rojów oraz, z upływem kolejnych epok, skupienie się wokół zbiorów parametrów reprezentujących poszczególne postaci. Mechanizmy te uregulowane są poprzez wysokość rang przydzielonych poszczególnym rojom. Roje o wyższych rangach skupiają się na bardziej dominujących postaciach dodatkowo wymuszając opuszczenie danego obszaru przez roje o niższych rangach. Kara uzyskana przez daną cząsteczkę jest normalizowana w celu uodpornienia systemu na wielkość amplitud poszczególnych postaci. Roje początkowo skupiają się na znalezieniu częstotliwości każdej z postaci, następnie skupiając cząsteczki wokół znalezionych częstotliwości roje poszukują wartości amplitud oraz tłumień.

4. Analiza wpływu zakłóceń na wyniki identyfikacji

4.1. Przykład - wprowadzenie

Analizę wpływu zakłóceń na wyniki identyfikacji uzyskane po zastosowaniu proponowanego algorytmu wykonano na przykładzie danych symulacyjnych wygenerowanych z wykorzystaniem (1). Rozpatrywanych jest szereg przypadków. Pierwszym z nich jest sygnał bez szumu. W kolejnych przypadkach stopniowo zwiększano poziom szumu (gaussowski szum addytywny) tak, że stosunek sygnału do szumu (ang. *Signal-to-noise ratio* – SNR) wynosił od 10 dB do 1 dB. Generowany sygnał zawiera 4 postaci drgań własnych. Częstotliwości dwóch z postaci są zbliżone w celu utrudnienia procesu identyfikacji. W Tabeli 1 przedstawione są parametry przyjęte dla generowanego sygnału.



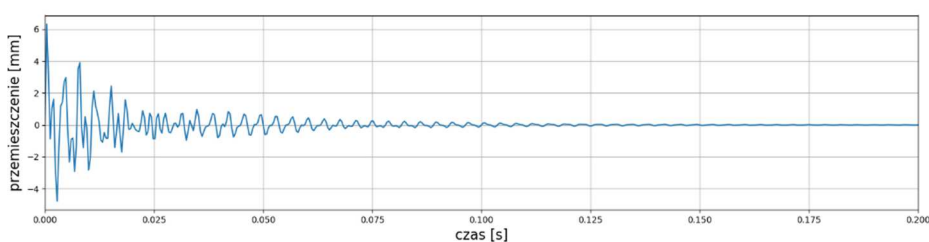
Tab. 1. Parametry poszczególnych postaci przyjęte w procesie generowania sygnału.

parametr	Nr postaci			
	1	2	3	4
Y_0	1,3	2,1	1,5	2,8
f	270	290	550	670
ξ	0,015	0,03	0,01	0,02


Szum w poszczególnych przypadkach dodany został do przebiegu czasowego sygnału, który następnie został poddany transformacji Fouriera (FFT).

Wyniki z poszczególnych testów zostały porównane w celu weryfikacji z wynikami metod ERA oraz pLSCF-d.

Na rys. 1 przedstawione zostało 0,2 s przebiegu czasowego wygenerowanego sygnału, natomiast na rys. 2 pokazano jego widmo amplitudowe.



Rys. 1. Przebieg czasowy wygenerowanego sygnału.



Rys. 2. Widmo amplitudowe wygenerowanego sygnału

4.2. Uzyskane wyniki identyfikacji

Analizę z użyciem zaproponowanego algorytmu przeprowadzono dla szeregu wartości SNR. Począwszy od sygnału idealnego bez szumu do sygnału, dla którego wartość SNR wyniosła 1 dB. W Tabeli 2 zgromadzone zostały wyniki uśrednienia błędów względnych dla 10 prób identyfikacji analizowanym algorytmem. Tabela 3 zawiera odchylenia standardowe uzyskanych błędów względnych dla poszczególnych wartości SNR rozpatrywanego sygnału.



Tab. 2. Błędy względne dla poszczególnych parametrów w zależności od wartości SNR rozpatrywanego sygnału.

SNR [dB]	Błąd względny [%]							
	f_1	ζ_1	f_2	ζ_2	f_3	ζ_3	f_4	ζ_4
∞	0,000	0,251	0,001	0,468	0,000	0,026	0,000	0,021
10	0,052	8,620	0,060	15,794	0,060	7,754	0,052	11,843
9	0,068	2,824	0,008	5,730	0,035	2,009	0,051	10,247
8	0,040	4,364	0,015	18,278	0,002	2,347	0,003	12,986
7	0,036	9,919	0,001	7,547	0,003	0,606	0,113	4,953
6	0,096	22,503	0,012	17,937	0,005	2,046	0,049	23,053
5	0,006	7,868	0,121	11,542	0,153	0,147	0,030	42,628
4	0,186	20,515	0,035	37,168	0,064	24,030	0,038	23,108
3	0,015	23,306	0,475	1,210	0,089	5,602	0,137	34,634
2	0,077	22,725	0,465	33,472	0,174	28,914	0,017	57,273
1	0,038	10,219	0,153	98,699	0,026	12,901	0,060	33,172

Tab. 3. Odchylenie standardowe dla poszczególnych parametrów w zależności od wartości SNR rozpatrywanego sygnału.

SNR [dB]	Odchylenie standardowe							
	f_1	ζ_1	f_2	ζ_2	f_3	ζ_3	f_4	ζ_4
∞	0,000	0,352	0,001	0,668	0,000	0,028	0,000	0,022
10	0,000	0,579	0,001	1,015	0,000	0,049	0,001	0,076
9	0,000	0,251	0,001	0,427	0,000	0,021	0,000	0,024
8	0,015	0,950	0,020	2,298	0,002	0,055	0,001	0,083
7	0,001	0,271	0,001	0,518	0,000	0,030	0,000	0,038
6	0,000	0,817	0,002	2,163	0,001	0,024	0,001	0,074
5	0,004	0,304	0,005	0,555	0,000	0,020	0,001	0,072
4	0,001	1,146	0,006	2,354	0,001	0,063	0,001	0,057
3	0,000	1,426	0,002	2,052	0,000	0,080	0,001	0,105
2	0,000	0,257	0,002	0,871	0,000	0,045	0,001	0,040
1	0,012	4,161	0,048	8,316	0,002	0,044	0,005	0,330

Jak można zauważyć, pomimo tendencji do zwiększania się błędów identyfikacji wraz ze wzrostem ilości szumów (której można się było spodziewać), algorytm wykazuje dość dużą odporność na jego negatywny wpływ. Szczególnie detekcja częstotliwości daje bardzo dobre rezultaty – błąd

nie przekroczył 0,5% dla żadnego z przypadków. Wartości tłumienia również zostały zidentyfikowane z zadowalającą precyzją – w zdecydowanej większości przypadków błąd nie przekracza 25%. Odchylenia standardowe przedstawione w Tabeli 3 wskazują dużą powtarzalność uzyskiwanych wyników identyfikacji w kolejnych próbach.

W tabelach 4 i 5 przedstawione zostały wyniki analizy tych samych co poprzednio sygnałów, ale z użyciem, metod ERA oraz pLSCF-d. W tabelach tych zaznaczono także kolorem jasnoszarym przypadki, w których metody te uzyskały nieco lepsze wyniki (do 10 punktów procentowych różnicy między błędem danego algorytmu a błędem analizowanego algorytmu opartego na PSO), zaś kolorem ciemnoszarym - przypadki, w których uzyskały wyniki znacząco lepsze (powyżej 10 pp różnicy) od algorytmu opartego na PSO. Pozostałe przypadki (bez zaznaczenia kolorem szarym) to te, w których analizowany algorytm wykazuje przewagę nad daną metodą referencyjną.

Jak można zauważyć, algorytm poddany analizie wykazał w większości przypadków przewagę nad metodami referencyjnymi. Szczególnie jest to widoczne dla identyfikacji częstości drgań. Uzyskano także dokładniejsze rezultaty identyfikacji tłumienia w porównaniu z metodą pLSCF-d. Wyniki identyfikacji tłumienia w stosunku do metody ERA w dużej liczbie przypadków były gorsze, ale zwykle tylko nieznacznie (mniej niż 10 pp różnicy błędów).

Ponieważ metody ERA oraz pLSCF-d nie pozwalają na szacowanie amplitud drgań, rezultaty dotyczące błędów identyfikacji amplitud uzyskanych przez analizowaną metodę zostały w niniejszej publikacji pominięte.

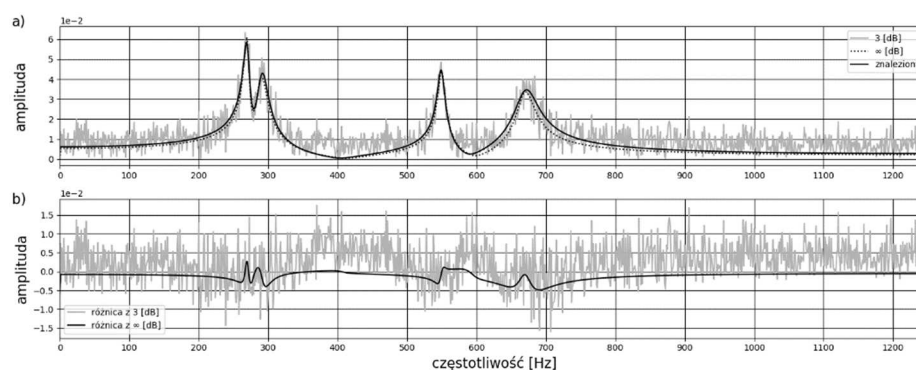
Tab. 4. Wyniki uzyskane dla metody ERA dla poszczególnych parametrów w zależności od wartości SNR rozpatrywanego sygnału.

SNR [dB]	ERA - błąd względny [%]							
	f_1	ζ_1	f_2	ζ_2	f_3	ζ_3	f_4	ζ_4
∞	0,011	0,000	0,045	0,000	0,005	0,000	0,020	0,000
10	0,609	19,655	0,725	12,246	0,031	12,846	0,082	7,004
9	0,572	48,741	0,156	32,513	0,180	20,421	0,087	5,363
8	2,910	145,723	0,137	109,620	0,003	35,359	0,021	7,055
7	0,229	66,936	0,623	11,966	0,013	0,202	0,262	17,497
6	0,431	90,710	1,050	5,819	0,138	0,635	0,236	8,641
5	1,401	63,735	1,279	4,100	0,115	5,498	0,023	5,095
4	0,133	104,353	0,419	22,911	0,145	11,459	0,001	11,475
3	3,014	137,851	2,496	27,016	0,214	27,044	0,053	18,199
2	2,358	145,022	0,662	0,955	0,107	7,690	0,004	6,669
1	0,309	130,312	2,855	16,406	0,142	9,197	0,636	36,667

Tab. 5. Wyniki uzyskane dla metody pLSCF-d dla poszczególnych parametrów w zależności od wartości SNR rozpatrywanego sygnału.

SNR [dB]	pLSCF-d - błąd względny [%]							
	f_1	ζ_1	f_2	ζ_2	f_3	ζ_3	f_4	ζ_4
∞	0,011	0,000	0,045	0,000	0,005	0,000	0,020	0,000
10	0,106	7,485	0,103	29,802	0,051	10,776	0,026	13,092
9	0,349	8,909	0,484	32,207	0,031	9,439	0,065	29,437
8	0,171	6,629	0,033	26,770	0,023	20,333	0,085	20,455
7	0,217	8,050	0,250	38,301	0,085	18,876	0,211	41,284
6	0,058	10,965	0,269	27,457	0,064	23,423	0,028	27,583
5	0,058	10,965	0,269	27,457	0,064	23,423	0,028	27,583
4	0,003	3,591	0,002	46,847	0,127	33,745	0,123	52,741
3	0,381	12,355	0,442	53,013	0,100	49,134	0,392	71,235
2	0,478	38,723	0,561	63,139	0,189	56,137	0,059	93,238
1	0,733	51,681	0,923	82,725	0,214	80,137	0,501	90,119

Przykładowe widmo sygnału wygenerowanego na podstawie uzyskanych wyników identyfikacji przedstawione zostało na rys 3. Dotyczy ono analizy sygnału, dla którego wartość SNR wynosiła 3dB (moc szumów wynosi $\sim 50\%$ mocy sygnału użytecznego). Sygnał wygenerowany został na podstawie uśrednienia parametrów zidentyfikowanych w 10 próbach analizy.



Rys. 3.

- a) widmo amplitudowe sygnału idealnego (kropkowany szary), sygnału o SNR = 3 dB poddanego analizie (ciągły szary), sygnału zidentyfikowanego (ciągły czarny),
 b) różnica widma sygnału zidentyfikowanego względem widma sygnału idealnego (czarny) oraz widma sygnału poddanego analizie (szary)

5. Podsumowanie

Przeanalizowany algorytm oparty na PSO pozwala uzyskać lepsze, w porównaniu z metodami referencyjnymi, oszacowania częstotliwości drgań a także, w wielu przypadkach, lepsze oszacowania wartości współczynników tłumienia. Przeprowadzone badania wykazały także zadowalającą, a w porównaniu z metodą pLSCF-d nawet wyższą odporność na zakłócenia występujące w danych pomiarowych. Na tej podstawie można stwierdzić, że analizowany algorytm wykorzystujący wiele rojów PSO, może być wykorzystywany jako metoda asystująca innym znanym metodom w analizie modalnej.

Bibliografia

- [1] Eberhart R.C., Kennedy J., A new optimizer using particles swarm theory. In: Proceedings of the 6th international symposium on micro machine and human science; 1995, s. 39–43.
- [2] Maia N.M.M., Silva J.M.M., Modal analysis identification techniques. Phil Trans R Soc Lond A 2001, vol. 359, s. 29–40.
- [3] Heylen W., Lammens S., Sas P., Modal analysis theory and testing. Leuven: KU Leuven, 2007.
- [4] Sitarz P., Powalka B., Modal parameters estimation using ant colony optimisation algorithm, Mechanical Systems and Signal Processing, vol. 76, 2016, s. 531-554
- [5] Galewski M.A., Orzechowski A. Spectral-Based Modal Parameters Identification with Multiple Particle Swarms Optimization, In: Selected Problems of Mechatronic Design, Ed. Manka M. 2017, Krakow, Wydawnictwo AGH, s. 49-58
- [6] Galewski, M.A., Spectrum-based modal parameters identification with Particle Swarm Optimization, Mechatronics, vol. 37, 2016, s. 21-32
- [7] Ab Wahab M. N., Nefti-Meziani S., Atyabi A. A comprehensive review of swarm optimization algorithms. PloS one, vol. 10(5), 2015