

Maksym GRZYWIŃSKI (id orcid 0000-0003-4345-3897)
Politechnika Częstochowska, Wydział Budownictwa

OPTYMALIZACJA KRATOWNICY Z ZASTOSOWANIEM ALGORYTMU GENETYCZNEGO

Zaproponowano algorytm genetyczny do rozwiązania problemu minimalizacji masy płaskiej kratownicy, biorąc pod uwagę zmienność pola przekroju. Minimalna masa konstrukcji stalowej to też niska emisja CO₂. Konstrukcja jest zoptymalizowana za pomocą wydajnego algorytmu zwanego Teaching Learning Based Optimization (TLBO). Proces TLBO jest podzielony na dwie części: pierwsza składa się z „fazy nauczyciela”, a druga składa się z „fazy ucznia”. Obliczenia wykonywane są z pomocą programu metody elementów skończonych zakodowanym w MATLAB-ie.

Słowa kluczowe: algorytm genetyczny, optymalizacja przekroju, zmienne dyskretne, minimum masy, emisja CO₂

WPROWADZENIE

Optymalna konstrukcja zawsze była w polu poszukiwań projektantów. Inżynier jest odpowiedzialny za projektowanie konstrukcji o wysokiej niezawodności i niskich kosztach. W tym celu opracowano wiele optymalnych algorytmów, aby rozwiązać postawione zadanie, brano pod uwagę zarówno metody klasyczne, jak i innowacyjne algorytmy. Algorytmy genetyczne (AG) są to algorytmy poszukiwania oparte na mechanizmach doboru naturalnego oraz dziedziczności [1]. Łącząc w sobie ewolucyjną zasadę przeżycia najlepiej przystosowanych z systematyczną, choć losową, wymianą informacji, tworzą metodę poszukiwań najlepszego osobnika. Wykorzystują przy tym doświadczenia poprzednich pokoleń do określenia nowych obszarów poszukiwań o spodziewanej wyższej wydajności. W budownictwie prace naukowe dotyczą głównie optymalizacji konstrukcji kratowych i ramowych. Oto niektóre z nich: w pracy [2] przedstawiono optymalizację kratownic płaskich i przestrzennych, w [3] kratownic i ram, a w [4] kopuł prętowych.

Algorytm Teaching Learning Base Optimization (TLBO) to zaproponowany przez profesora Rao algorytm metaheurystyczny [5, 6]. Łatwość i skuteczność TLBO były wspierane przez prace badawcze opublikowane w [7-9]. W problemie optymalizacji pola przekroju i geometrii konstrukcji kratownicowych pole przekroju i pierwotna geometria konstrukcji zwiększają rozmiar przestrzeni wymiarowej. Nie jest to problemem, gdyż udowodniono, że algorytm TLBO dobrze sprawdza się w zadaniach o dużych i złożonych rozmiarach [10].

1. ALGORYTM GENETYCZNY TLBO

Niedawno zaproponowany nowy algorytm optymalizacji o nazwie TLBO jest zaimplementowany w niniejszym artykule do dyskretnej optymalizacji kratownicy płaskiej. TLBO ma wiele podobieństw do algorytmów genetycznych (AG): początkowa populacja jest losowo wybierana, poszukujemy rozwiązania w drodze do nauczyciela, a koledzy z klasy są porównywani do operatora mutacji w AG. Wybór opiera się na porównaniu dwóch rozwiązań, z których lepszy zawsze przetrwa. TLBO jest algorytmem populacyjnym inspirowanym procesem uczenia się w klasie. Proces poszukiwania składa się z dwóch faz, tj. „fazy nauczyciela” i „fazy ucznia”.

W „fazie nauczyciela” uczniowie najpierw otrzymują wiedzę od nauczyciela, a następnie od kolegów z klasy w „fazie ucznia”. W całej populacji najlepszym rozwiązaniem jest nauczyciel $X_{teacher}$. W tej fazie nauczyciel stara się poprawić wyniki innych osób X_i , zwiększając średni wynik lekcji X_{mean} w stosunku do swojej pozycji $X_{teacher}$. Aby zachować stochastyczne cechy wyszukiwania, dwa losowo generowane parametry r i T_F są stosowane w formule aktualizacji dla rozwiązania X_i jako:

$$X_{new} = X_i + r(X_{teacher} - T_F \cdot X_{mean}) \quad (1)$$

gdzie r jest losowo wybraną liczbą z zakresu od 0 do 1, a T_F jest współczynnikiem nauczania, który może wynosić 1 lub 2:

$$T_F^i = round[1 + rand(0,1)\{2 - 1\}] \quad (2)$$

gdzie X_{new} jest nowym rozwiązaniem, a X_i rozwiązaniem aktualnym.

W drugiej fazie, tj. „fazie ucznia”, uczniowie próbują zwiększyć swoje informacje poprzez interakcję z innymi. Dlatego osoba uczy się nowej wiedzy, jeśli inne osoby mają więcej wiedzy niż on/ona. W trakcie tej fazy uczeń X_i wchodzi w interakcje losowo z innym uczniem X_j ($i \neq j$) w celu poprawy swojej wiedzy. W przypadku gdy X_j jest lepszy niż X_i (to znaczy $f(X_j) < f(X_i)$ w przypadku problemów z minimalizacją), X_i jest przesuwany w kierunku X_j . W przeciwnym razie jest on odsuwany od X_j :

$$X_{new} = X_i + r(X_j - X_i), \text{ jeśli } f(X_i) > f(X_j) \quad (3)$$

$$X_{new} = X_i + r(X_i - X_j), \text{ jeśli } f(X_i) < f(X_j) \quad (4)$$

Jeśli nowe rozwiązanie X_{new} jest lepsze, jest akceptowane w populacji. Algorytm będzie kontynuowany aż do spełnienia warunku zakończenia.

2. SFORMUŁOWANIE PROBLEMU OPTIMALIZACJI

Podstawowym kryterium przy projektowaniu konstrukcji jest osiągnięcie jak najmniejszego ciężaru (masy). Funkcja celu W została zdefiniowana jako:

$$W = \sum_{i=1}^n \rho_i L_i A_i \quad (5)$$

gdzie: ρ_i - ciężar właściwy materiału, L_i - długość pręta, A_i - pole przekroju poprzecznego pręta, n - liczba prętów.

Optymalizowana konstrukcja musi spełniać również ograniczenia związane z dopuszczalnymi naprężeniami i przemieszczeniami:

$$\sigma_i \leq \sigma_{max} \quad (6)$$

$$\delta_i \leq \delta_{max} \quad (7)$$


Ponieważ algorytmy genetyczne są metodami rozwiązującymi zadania optymalizacyjne bez ograniczeń, dlatego przekształcono rozwiązywane zadanie z ograniczeniami na zadanie bez ograniczeń poprzez obciążenie funkcji celu funkcją kary. W zastosowanym algorytmie najlepszy osobnik przechodzi do następnej iteracji bez zmian (elitaryzm), co gwarantuje nie pogorszenie wyniku w kolejnych krokach.

3. PRZYKŁAD NUMERYCZNY

Zaproponowany algorytm TLBO może być stosowany do szerokiej klasy zagadnień, w której zmienne projektowe należą do dyskretnego zbioru. Efektywność algorytmu sprawdzono na przykładzie płaskiej kratownicy 15-prętowej pokazanej na rysunku 1. Wcześniej kratownicę badali Zhang i in. [11], Li i in. [12] oraz Sabour i in. [13].


Gęstość materiału wynosi $7,8e3 \text{ kg/m}^3$, a moduł sprężystości to 200 GPa. Dopuszczalne naprężenia dla wszystkich elementów wynoszą $\pm 120 \text{ MPa}$. Wszystkie węzły w obu kierunkach mają narzucone ograniczenia przemieszczenia $\pm 10 \text{ mm}$. Zmienne dyskretne są wybrane z zestawu $D = [113,2 \ 143,2 \ 145,9 \ 174,9 \ 185,9 \ 235,9 \ 265,9 \ 297,1 \ 308,6 \ 334,3 \ 338,2 \ 497,8 \ 507,6 \ 736,7 \ 791,2 \ 1063,7] \text{ [mm}^2\text{]}$. Istnieją trzy przypadki obciążeń dla tej kratownicy:

- przypadek 1: $P_1 = 35 \text{ kN}$, $P_2 = 35 \text{ kN}$, $P_3 = 35 \text{ kN}$;
- przypadek 2: $P_1 = 35 \text{ kN}$, $P_2 = 0 \text{ kN}$, $P_3 = 35 \text{ kN}$;
- przypadek 3: $P_1 = 35 \text{ kN}$, $P_2 = 35 \text{ kN}$, $P_3 = 0 \text{ kN}$.



Rys. 1. Konfiguracja kratownicy 15-prętowej

Najlepszym wektorem rozwiązania jest [113,2 113,2 113,2 113,2 736,7 113,2 113,2 736,7 113,2 113,2 113,2 113,2 334,3 334,3] [mm²] i minimalna masa konstrukcji wynosi 105,735 kg. Historia zbieżności minimum masy dla 15-prętowej kratownicy została pokazana na rysunku 2. Jak z tego rysunku widać, wartość średnia rozwiązania jest bliska najlepszemu rozwiązaniu na koniec iteracji. Wyniki uzyskane z tego badania można porównać z wynikami zawartymi w literaturze (tab. 1).



Rys. 2. Historia zbieżności rozwiązania

Tabela 1. Optymalne przekroje dla 15-prętowej kratownicy

Pole przekroju [mm ²]	Zhang i in. [11] HGA	Li i in. [12] PSO	Sabour i in. [13] ICA	Autorskie TLBO
A1	308,6	185,9	113,2	113,2
A2	174,9	113,2	113,2	113,2
A3	338,2	143,2	113,2	113,2
A4	143,2	113,2	113,2	113,2
A5	736,7	736,7	736,7	736,7
A6	185,9	143,2	113,2	113,2
A7	265,9	113,2	113,2	113,2
A8	507,6	736,7	736,7	736,7
A9	143,2	113,2	113,2	113,2
A10	507,6	113,2	113,2	113,2
A11	279,1	113,2	113,2	113,2
A12	174,9	113,2	113,2	113,2
A13	297,1	113,2	113,2	113,2
A14	235,9	334,3	334,3	334,3
A15	265,9	334,3	334,3	334,3
Masa [kg]	142,117	108,96	105,735	105,735
Liczba iteracji	–	500	500	50
Rozmiar populacji	–	50	50	30
Niezależne uruchomienia	–	–	26	20

HGA - hybrid genetic algorithm, PSO - particle swarm optimization, ICA - imperialist competitive algorithm

PODSUMOWANIE

W algorytmach genetycznych, ze względu na ich stochastyczną naturę, głównym problemem jest powolna zbieżność, a co za tym idzie, czasochłonność. Nowy algorytm TLBO bardzo dobrze sobie z tym problemem poradził. Zaprezentowany przykład pokazuje, że otrzymane wyniki są takie same lub lepsze od prezentowanych w literaturze. Metoda TLBO może być łatwo rozszerzona na optymalizację innych typów konstrukcji budowlanych, jak przestrzenne kratownice, ramy czy powłoki lub kopuły prętowe.

Projektowanie konstrukcji stalowej o minimalnej masie to przede wszystkim niski koszt dla inwestora, ale również w procesie produkcji stali niższa emisja CO₂, więc też korzyść dla środowiska.

LITERATURA

- [1] Goldberg D.E., Genetic algorithms in search, optimization, and machine learning, Addison Wesley, 1989.
- [2] Coelle C.A., Christiansen A.D., Multiobjective optimization of trusses using genetic algorithms, Computers and Structures 2000, 75, 647-660.
- [3] Degertekin S.O., Saka M.P., Hayalioglu M.S., Optimal load and resistance factor design of geometrically nonlinear steel space frames via tabu search and genetic algorithm, Engineering Structures 2008, 30, 197-205.
- [4] Grzywiński M., Optimization of single-layer braced domes, Transactions of the VŠB - Technical University of Ostrava, Civil Engineering Series 2017, 17(1), 45-50.
- [5] Rao R.V., Sivasani V.J., Vakharia D.P., Teaching-learning-based optimization: A novel method for constrained mechanical design optimization problems, Computer-Aided Design 2011, 43(3), 303-315.
- [6] Rao R.V., Teaching Learning Based Optimization Algorithm and Its Engineering Applications, Springer, 2016.
- [7] Dede T., Application of teaching-learning-based-optimization algorithm for the discrete optimization of truss structures, KSCE Journal of Civil Engineering 2014, 18(6), 1759-1767.
- [8] Toğan V., Design of planar steel frames using teaching-learning based optimization, Eng. Struct. 2012, 34, 225-232.
- [9] Cheng W., Liu F., Li L.J., Size and geometry optimization of trusses using teaching-learning-based optimization, Int. J. Optim. Civil Eng. 2013, 3(3), 431-444.
- [10] Rao R.V., Sivasani V.J., Vakharia D.P., Teaching-learning-based optimization: An optimization method for continuous non-linear large scale problems, Information Sciences 2012, 183, 1-15.
- [11] Zhang Y.N., Liu J.P., Liu B., Zhu C.Y., Li Y., Application of improved hybrid genetic algorithm to optimize, J. South China Univ. Technol. 2003, 33(3), 69-72.
- [12] Li L.J., Huang Z.B., Liu F.A., A heuristic particle swarm optimization method for truss structures with discrete variables, Computers and Structures 2009, 87(7-8), 435-443.
- [13] Sabour M.H., Eskandar H., Salehi P., Imperialist competitive ant colony algorithm for truss structures, World Applied Sciences Journal 2011, 12(1), 94-105.

OPTIMIZATION OF TRUSS USING GENETIC ALGORITHM

The article proposes a genetic algorithm for solving the problem of minimizing the mass of a plane truss, taking into account the variability of the cross-sectional area. The minimum mass of the steel structure is also low CO₂ emission. The design is optimized using an efficient algorithm called Teaching Learning Based Optimization. The TLBO process is divided into two parts: the first consists of the “teacher phase” and the second consists of the “student phase”. The calculations are performed with the help of the finite element method program coded in MATLAB.

Keywords: genetic algorithm, size optimization, discrete variables, mass minimum, CO₂ emissions