

OPTIMALIZACJA TARCZ Z ZASTOSOWANIEM SZTUCZNYCH SYSTEMÓW IMMUNOLOGICZNYCH I METODY ELEMENTÓW SKOŃCZONYCH

RAFAŁ ROBAK, Automatyka i Robotyka, AB3, 5 rok
Opiekun naukowy: Prof. dr hab. inż. Tadeusz Burczyński

Streszczenie. Praca poświęcona jest zastosowaniu sztucznych systemów immunologicznych i metody elementów skończonych (MES) w zagadnieniach optymalizacji konstrukcji tarczowych. Przedstawiono metodę optymalizacji kształtu, topologii oraz gęstości układów dla przyjętego kryterium masowego przy wprowadzonym ograniczeniu naprężeniowym. Przedstawione w referacie przykłady obliczeń immunologicznych dowodzą, że opracowana metoda optymalizacji, bazująca na połączeniu sztucznych systemów immunologicznych i metody elementów skończonych, jest efektywnym narzędziem wspomagania komputerowego w zagadnieniach poszukiwania optymalnych rozwiązań konstrukcyjnych.

1. Wprowadzenie


Obecnie w sektorze projektowo-konstrukcyjnym coraz większą wagę przykładają do efektywności zarówno w sensie jakości finalnego projektu jak i czasu jego wykonania. Inżynier mając przed sobą dość złożone projekty przy jednoczesnym małym marginesie błędów, musi podjąć decyzje o konkretnym wariantcie konstrukcyjnym, który zostanie wdrożony w życie. W wyborze odpowiedniego wariantu pomaga doświadczenie i zdobyta wiedza. Nie zawsze jednak te umiejętności wystarczają, dlatego też z pomocą przychodzą rozwiązania skierowane do inżynierów mające na celu symulację produktu jeszcze przed jego wytworzeniem. Oprogramowanie z serii CAE (computer aided engineering) pozwala na weryfikację konstrukcji w warunkach zbliżonych do rzeczywistych. Dzięki temu można przeprowadzać analizy zakładając różne warianty obciążeń, wyznaczać parametry modalne, przewidywać krytyczne obszary w konstrukcji mogące ulec pęknięciu, czy też optymalizować układy w celu równomiernego wyłożenia konstrukcji. To tylko niewielka część typów analiz strukturalnych jakie można symulować. Dodatkowo łącząc oprogramowanie analizujące wytrzymałość (w niniejszej pracy MSC.Patran/Nastran) jako narzędzie sprawdzające stan konstrukcji ze sztucznymi systemami immunologicznymi można otrzymać wysoko wyspecjalizowane narzędzie, pozwalające w znaczny sposób przyspieszyć wybór optymalnego wariantu konstrukcyjnego. Systemy takie pozwalają dobrać nie tylko topologię przyszłego środka technicznego, ale także pozwalają oszacować z jakiego materiału powinien zostać on wykonany.

2. Sztuczne systemy immunologiczne

Immunologia [1] jest dyscypliną naukową zajmującą się biologicznymi i biomechanicznymi regułami układu obronno-odpornościowego na patogeny i inne ciała obce. Od strony implementacji tego układu w zadaniu optymalizacji wyłania się system cechujący:

- rozproszoną detekcją - proces detekcji nie podlega scentralizowanemu sterowaniu,
- detekcją anomalii - układ prawidłowo identyfikuje patogeny, z którymi nigdy wcześniej się nie zetknął,

- samoorganizacją - pamięć immunologiczna tworzy sieciową strukturę, tzw. sieć idiotypową, która podlega modyfikacjom w miarę jak pojawiają się kolejne typy patogenów,
- adaptacyjnością - układ odpornościowy potrafi „nauczyć się” i „zapamiętać” patogenne struktury,
- progową detekcją - proces wiązania antygeny przez przeciwciało opiera się jedynie na częściowym podobieństwie obu elementów rys.1,



Rys.1. Schematyczna budowa limfocytu typu B

- brakiem konieczności tworzenia zbioru negatywnych przykładów - układ odpornościowy działa w myśl zasady „toleruj swoje, zwalczaj obce” rys.2.



Rys.2. Zdolność detekcyjną układu immunologicznego

Sztuczny system immunologiczny AIS traktuje zadanie optymalizacyjne jako patogen. Szukając optymalnej postaci konstrukcji, system generuje limfocyty spośród których pozostają najlepiej przystosowane do kryterium zadania.

3. Algorytm optymalizacyjny

Sztuczny system immunologiczny w zadaniu optymalizacyjnym wykorzystuje algorytm selekcji klonalnej. Podczas inicjalizacji system generuje ustaloną liczbę komórek pamięci (limfocytów). Rozmiar pamięci w czasie optymalizacji nie ulega zmianie. Następnie każda komórka produkuje ustaloną wstępnie liczbę klonów, które są poddawane mutacji. W operatorze selekcji klonalnej dla każdego elementu m należącego do wygenerowanego podczas inicjalizacji zbioru jest szukany podobny m^* i z pary elementów (m, m^*) jest pozostawiany lepszy a gorszy zastępowany losowo wygenerowanym osobnikiem. Dodatkowo w kolejnym kroku algorytm przeprowadza „porządkowanie” zbioru komórek pamięci. Jeżeli w pewnym podobszarze X o promieniu d_{min} występuje skupienie pewnej liczby komórek to pozostawia się komórkę najlepiej dostosowaną, a pozostałe zastępuje losowo wygenerowanymi kandydatami. Jeżeli najlepsza z komórek nie spełnia dostatecznie kryterium zadania wtedy proces klonowania zaczyna się od nowa. Element selekcji jest odpowiedzialny

za proces eksploatacyjny algorytmu (usuwanie gorzej przystosowanych komórek), natomiast etap supresji za proces eksploracyjny (poszerzanie przestrzeni poszukiwań).

W przypadku zadania optymalizacji [2] tarczy minimalizowano funkcjonal masę:

$$J = \int_{\Omega} \rho d\Omega \quad (1)$$

przy ograniczeniu naprężeniowym. Pozwala to jeszcze bardziej zredukować masę konstrukcji usuwając mało wyťažone elementy. Zgodnie z przyjętym kryterium, limfocyt reprezentuje rozkład gęstości w analizowanej tarczy. Zawiera on zbiór wartości punktów kontrolnych, odpowiedzialnych za generowanie powierzchni gęstości. Powierzchnia ta interpolowana na tych punktach opisuje rozkład masy w całym modelu. Pozwoliło to ograniczyć liczbę zmiennych projektowych w zadaniu, uzależniając ich liczbę nie od liczby elementów skończonych, ale od liczby punktów kontrolnych. W każdej z iteracji, wartości powierzchni gęstości są mapowane na elementy skończone. Dla zadania dwuwymiarowego R^2 powierzchnia ta ma wymiar R^3 . Dodatkowo ma ona wpływ na generowanie otworów jeśli wartość powierzchni gęstości znajdzie się poniżej ustalonego minimum p_{min} .



Rys.3. Rozkład gęstości podczas optymalizacji


Program optymalizacyjny zawiera także procedury sprawdzające poprawność konstrukcji oraz procedury wygładzające krawędzie modelu po optymalizacji.

4. Testy numeryczne algorytmu

W przypadku testów numerycznych, gdzie sprawdzano efektywność algorytmu zmieniano liczbę komórek pamięci, liczbę klonów, współczynnik zatłoczenia oraz parametr mutacji Gaussa. Testy przeprowadzono na matematycznej funkcji Bohachevskiego rys.4. Zakres zmiennych oraz ekstremum funkcji zostały zestawione w tabeli 1.

Tabela 1. Parametry funkcji testowej

Liczba zmiennych	$n=2$
Obszar przeszukiwania	$[X,Y]=(-100;100)$
Minimum globalne	$F(X,Y)=0$ dla $X=[0]$ i $Y=[0]$



Rys.4. Funkcja testowa Bohachevskiego

Algorytm był testowany na trzech postaciach tej funkcji. Liczba zmiennych, ich zakres oraz ekstremum nie ulegało zmianie.


$$f_1(x) = x_1^2 + 2x_2^2 - 0.3 \cos(3\pi \cdot x_1) - 0.4 \cos(4\pi \cdot x_2) + 0.7 \quad (2)$$

$$f_2(x) = x_1^2 + 2x_2^2 - 0.3 \cos(3\pi \cdot x_1) \cos(4\pi \cdot x_2) + 0.3 \quad (3)$$

$$f_3(x) = x_1^2 + 2x_2^2 - 0.3 \cos(3\pi \cdot x_1 + 4\pi \cdot x_2) + 0.3 \quad (4)$$

Dobór parametrów algorytmu miał znaczący wpływ na proces optymalizacji, nie tylko ze względu na czas ale także na efektywność pracy algorytmu. Liczbę komórek pamięci i klonów należy dobierać w zależności od stopnia skomplikowania zadania. Program pracując na większej liczbie komórek jest w stanie znaleźć wariant bardziej odpowiadający założonemu kryterium, jednak jest to okupione wzrostem czasu obliczeń.

Optymalizowanym obiektem była tarcza, która ze względu na symetrię w geometrii i warunkach brzegowych mogła być optymalizowana jako połowa układu. Na rysunku 5 przedstawiono optymalizowany układ wraz z warunkami brzegowymi oraz rozmieszczenie punktów kontrolnych.




Rys.5. Optymalizowana tarcza i rozkład punktów kontrolnych

Kształt tarczy osiągnięty po 68 iteracjach przedstawia rysunek 6. Parametry algorytmu zestawiono w tabeli 2.

Tabela 2. Parametry algorytmu

Liczba klonów	8
Liczba komórek pamięci	4
Parametr mutacji Gaussa	0.18
Współczynnik zatłoczenia	0.21



Rys.6. Tarcza po optymalizacji

5. Wnioski

Sztuczne systemy immunologiczne wykorzystane w optymalizacji tarcz mają na celu generowanie optymalnych wariantów rozkładu gęstości zgodnie z założonym kryterium minimum masy. Zadanie optymalizacji zostaje w tym przypadku potraktowane jako patogen, który system immunologiczny stara się zwalczyć generując jak najlepiej dopasowane osobniki (limfocyty). Jako wynik optymalizacji otrzymujemy nie tylko topologie tarczy ale także sugerowany rozkład materiałów.

Literatura

1. Wierzchoń S. Sztuczne systemy immunologiczne. Teoria i zastosowania. Warszawa 2001.
2. Stadnicki J. Teoria i praktyka rozwiązywania zadań optymalizacji z przykładami zastosowań technicznych. WNT Warszawa 2006.