

Jakub Poskrobko^{*}, Andrzej Cader^{**}

Możliwość redukcji zachowań nieregularnych w systemach wieloagentowych

1. Wstęp

W ostatnim czasie systemy wieloagentowe okazały się bardzo skutecznym narzędziem w wielu zastosowaniach zarówno praktycznych, jak i z zakresu symulacji. Jednak ze względu na znaczną liczbę parametrów oraz złożoność opisu współdziałania poszczególnych elementów systemu, rzadko jesteśmy w stanie przewidzieć bądź oszacować pracę systemu w przyszłości. W wielu przypadkach istnieje możliwość zmierzenia aktualnej efektywności pracy; wówczas okazuje się, że zachowanie takiego systemu wykazuje silne tendencje do nieregularności. Występowanie zachowań chaotycznych może znacznie osłabić skuteczność pracy systemu, bądź wręcz uniemożliwić jego działanie. Ponadto regularyzacja może ułatwić dokładniejszą predykcję dalszej pracy systemu [5].

Ze względu na analogię do systemów wieloagentowych i układów dynamicznych istnieje możliwość zastosowania narzędzi dynamiki chaotycznej do analizy zachowania systemów wieloagentowych. Celem badań było opracowanie narzędzi umożliwiających adaptacyjną regularyzację pracy systemu, bazującą wyłącznie na informacji o dotychczasowym jego działaniu. Szczególny nacisk jest położony na możliwość wykorzystania algorytmu dla możliwie jak najbardziej ogólnej klasy systemów; stąd zakłada się brak jakiejkolwiek informacji na temat charakteru analizowanego systemu.

Niniejszy artykuł prezentuje ogólny algorytm redukcji zachowania chaotycznego dyskretnego, deterministycznego systemu wieloagentowego, którego działanie może być sterowane poprzez jednowymiarowy parametr.

2. System wieloagentowy jako system dynamiczny

Rozważmy iteracyjny, dyskretny system wieloagentowy. Dodatkowo założmy, że decyzje dotyczące zarówno zachowania poszczególnych agentów, jak i wpływu środowiska na pracę systemu, są całkowicie deterministyczne. Wówczas – formalnie – taki system

^{*} Zakład Metod Przetwarzania Informacji, Wyższa Szkoła Humanistyczno-Ekonomiczna, Łódź; jposkrobko@wshe.lodz.pl

^{**} Katedra Informatycznych Systemów Zarządzania, Wyższa Szkoła Humanistyczno-Ekonomiczna, Łódź

może zostać opisany poprzez zmienny w czasie (iteracji) wektor stanu oraz zbiór funkcji przejścia, opisujących decyzje i zachowanie agentów [7]. Należy zauważyć, że pełny opis formalny nawet w przypadku prostych systemów wieloagentowych jest praktycznie niewykonalny. Jednak z reguły nie jest wymagana pełna analiza aktualnego stanu, a jedynie jej fragment zawierający informację o skuteczności działania systemu. W dalszej części publikacji zakłada się, że w dowolnej iteracji efektywność systemu może zostać opisana poprzez pojedynczą wartość – jako wartość funkcji, którą system powinien optymalizować.

Ze względu na deterministyczny charakter funkcji przejścia określających działanie takiego systemu, dla ustalonych wartości początkowych otrzymamy za każdym razem identyczne zachowanie systemu. Jednak nawet w przypadku prostych systemów agentowych bardzo często przebieg mierzonej wartości wykazuje zachowanie chaotyczne. Ta tendencja powoduje, że zachowanie systemu jest bardzo wrażliwe zarówno na zmianę warunków początkowych, jak i niewielkie modyfikacje sposobu działania. O ile w praktycznych założeniach z reguły nie mamy wpływu na warunki początkowe (bądź jest niemożliwe ich odpowiednie ustalenie ze względu na złożoność zadania), o tyle działanie poszczególnych agentów może być z reguły modyfikowane. Wprowadźmy w tym celu dowolny, jednowymiarowy parametr, determinujący zachowanie systemu, względem którego będzie optymalizowane jego działanie.

Z teorii systemów chaotycznych wynika [6], że w każdym takim systemie istnieje pewien zakres parametru, w którym system znajduje się w stanie ustalonym – występuje co najwyżej zachowanie okresowe. Znalezienie tej wartości prowadzi do ustalenia regularności zachowania systemu, pod warunkiem, że taki przedział parametru jest możliwy do osiągnięcia z przyczyn praktycznych. W dalszej części publikacji przedział ten będzie nazywany przedziałem optymalnym. Celem działania prezentowanego algorytmu będzie adaptacyjne znalezienie – i utrzymanie – wartości parametru, w którym system będzie regularny oraz możliwie najbardziej efektywny.

3. Przyjęty system eksperymentalny

Doświadczenia przeprowadzone w ramach badań zostały wykonane za pomocą symulacji prostego systemu wieloagentowego. Podstawowym założeniem było stworzenie takiego systemu, który odpowiadałby możliwie jak najszerszej klasie systemów. System doświadczalny składa się z grupy zadań wykonywanych przez agentów. Aktualny stan każdego zadania jest opisany za pomocą pojedynczej wartości, która – w miarę pracy agenta nad konkretnym zadaniem – jest zmniejszana do zera. Dodatkowo, aby uzyskać system niekończący swojej pracy, gdy zadanie nie jest wykonywane przez żadnego agenta, stan zadania jest automatycznie zwiększany (pogarsza się).

W pojedynczej iteracji, dla każdego agenta i zadania wyliczana jest wartość

$$A = W * \sqrt{\frac{p}{d}},$$


gdzie:

- d – odległość agenta od zadania;
- W – wartość, o jaką agent może obniżyć stan zadania (możliwą do wykonania pracą, podczas doświadczeń przyjęto stałą wartość);
- p – parametr pozwalający na sterowanie pracą systemu.

Wybierane są zadania, dla których wyliczona wartość A jest największa.

Jako wartość mierzona – określającą efektywność pracy systemu – przyjęto sumaryczny stan wszystkich zadań.

Taki system dla większości wartości parametrów wykazuje zachowanie nieregularne, nawet po dużej liczbie iteracji. Na rysunku 1 przedstawiono przykładowy przebieg mierzonej wartości.




Rys. 1. Przykładowy przebieg chaotyczny sumarycznego stanu zadań; 7 zadań, 5 agentów, parametr $p = 7$, wykonano 20 000 iteracji

4. Ocena pracy systemu

Algorytm redukcji zachowania chaotycznego modelowanego systemu wieloagentowego wymaga wprowadzenia pewnych statystyk szacujących zarówno efektywność działania, jak i jego regularność. Dodatkowo wymagane jest, aby wyliczenia tych statystyk wymagały możliwie najmniejszej złożoności obliczeniowej.

Jako statystykę mierzącą efektywność działania systemu przyjęto wartość minimalną przebiegu. Doświadczalnie potwierdzono, że – w zależności od przyjętego parametru – przebieg wartości minimalnej wykazuje analogiczny charakter jak przebieg wartości średniej (rys. 2). Zatem – ze względu na mniejszą złożoność obliczeniową – wybrana została wartość minimalna.



Rys. 2. Porównanie wartości minimalnej, średniej oraz wahan dla przebiegów o różnym parametrze działania systemu – symulacja 5 agentów, 7 zadań, 1500 iteracji

Do określenia charakteru przebiegu przyjęto średnie wahanie przebiegu. Niech $\{x_i\}_{i=1..N}$ będzie ciągiem wartości osiąganych przez mierzoną wartość w kolejnych iteracjach systemu. Wówczas średnie wahanie określone jest wzorem

$$W = \frac{\sum_{i=2}^N |x_i - x_{i-1}|}{N-1}.$$

Zależność wyliczonej wartości wahan od różnych wartości parametru działania systemu przedstawia rysunek 2.

Najlepszym wskaźnikiem regularności przebiegu mógłby być wykładnik Lapunowa. Jednak ze względu na złożoność obliczeniową numerycznych metod wyznaczania wykładnika Lapunowa [4], a także ich wrażliwość na błędy zaokrągleń, bardziej korzystne okazało się zastosowanie wahan przebiegu.

Zadanie doboru najlepszej wartości parametru pracy systemu sprowadza się do znalezienia optimum (minimum) funkcji celu zależnej od parametru. W przypadku braku jakichkolwiek założeń dotyczących badanego systemu, jej konstrukcja musi być oparta tylko o powyższe statystyki. Doświadczalnie dobrano funkcję celu jako kombinację liniową minimum oraz wahan, tj.

$$V(p) = C_1 \min_{i=1..N} \{x_i^p\} + C_2 W(\{x_i^p\}),$$

gdzie:

- $\{x_i^p\}_{i=1..N}$ – ciąg kolejnych wartości przebiegu dla parametru p ,
- $W(\)$ – wahanie przebiegu,
- C_1, C_2 – stałe wagi, doświadczalnie przyjęto $C_1=1, C_2=0,1$.

5. Algorytm redukcji zachowań chaotycznych

Celem badań było znalezienie algorytmu, który mógłby pracować na podstawie dostarczanych na bieżąco danych opisujących działanie systemu (w szczególności wartości funkcji oceny).

Algorytm składa się z dwóch etapów:

1. obserwacja i ocena pracy systemu dla ustalonego parametru,
2. podjęcie decyzji o modyfikacji wartości parametru, w zależności od regularności i efektywności przebiegu.

Doświadczalnie najlepsze rezultaty dała zmiana parametru co 100 iteracji; ponadto do oceny działania systemu brano tylko ten fragment przebiegu – zatem poprzednie wartości przebiegu nie wpływały bezpośrednio na dobór nowego parametru. Dodatkowo modyfikację parametru rozpoczynano dopiero od pewnego momentu działania systemu (w doświadczeniach po 500 iteracjach), ze względu na początkową fazę, w której zawsze obserwuje się gwałtowny spadek wartości mierzonej.

Podstawową trudnością okazał się fakt, że zależność funkcji oceny od parametru pracy systemu jest nieregularna – zatem większość algorytmów optymalizacji nie może zostać wykorzystanych. Ponadto także nieregularna jest zależność funkcji oceny dla stałego parametru, ale mierzona na podstawie różnych iteracji działania systemu – w przypadku gdy praca systemu wykazuje zachowanie chaotyczne.

Założone zostało także, że może nie istnieć taka wartość (przedział wartości) parametru optymalizująca funkcję celu; zatem w szczególności może nie być możliwości znalezienia rzeczywistego optimum – algorytm powinien wówczas dążyć do jak najlepszej pracy systemu, zarówno pod względem regularności, jak i efektywności – co nie musi zachodzić dla stałej wartości parametru. Ze względu na to założenie, nie można było zastosować algorytmów opartych o procedurę symulowanego wyżarzania [3], gdyż w ogólnym przypadku nie mamy kryteriów określających wartość „temperatury” optymalizacji.

Silna nieregularność zależności funkcji oceny od parametru – a więc duża liczba lokalnych optimum – implikuje zastosowanie metody opartej na algorytmach genetycznych lub procedurach z rodziny algorytmów Monte Carlo [1]. Klasyczne algorytmy genetyczne nie mogły zostać wykorzystane ze względu na konieczność oceny całej populacji, co jest równoważne z porównaniem działania systemu dla różnych parametrów przy tych samych warunkach początkowych, a więc jest sprzeczne z założonym adaptacyjnym charakterem metody.

Do znalezienia optimum funkcji celu opracowano algorytm bazujący na operatorze mutacji klasycznych algorytmów genetycznych [3]. W pierwszym kroku dokonywana jest ocena działania aktualnego parametru, która następnie umieszczana jest na liście. Do dalszych operacji brana jest tylko określona ilość wartości parametru, dla których system uzyskał najlepsze oceny (w doświadczeniach brano 20 wartości) – tak więc, w przypadku gdy aktualny przebieg nie otrzymał wystarczająco korzystnych ocen, wartość parametru zostanie wyeliminowana.

Jako nowy parametr przyjmujemy najlepszą dotychczasową wartość parametru, podając ją losowej modyfikacji w sposób opisany dalej. Należy zauważyć, że może to prowa-

dzić do pozostania w minimum lokalnym, jeżeli poszukiwany optymalny przedział wartości nie jest minimum globalnym. Wówczas zamiast pojedynczej, najlepszej wartości parametru można brać pewien podzbiór dotychczasowych wartości – na przykład ich średnią arytmetyczną. Jednak może to znacznie opóźnić znalezienie przedziału optymalnego; natomiast analogiczne zachowanie można wymusić poprzez odpowiedni dobór funkcji celu.

Zmiennopozycyjna wartość parametru zamieniana jest na reprezentację bitową – co jest odpowiednikiem określenia chromosomu w problemach optymalizacji wykorzystujących klasyczne algorytmy genetyczne. Następnie każdy i -ty bit takiej reprezentacji jest zmieniany na przeciwny – z prawdopodobieństwem P wyliczonym według wzoru

$$P = \frac{C * M * (W + 1) * O}{i + 1},$$

gdzie:

- C – stała normująca prawdopodobieństwo,
- M i W – odpowiednio wartość minimalna i wahanie najlepszego dotychczasowego przebiegu,
- O – wahania wartości wszystkich ocen.

Wprowadzenie wartości M obniża prawdopodobieństwo modyfikacji, jeżeli parametr spowodował bardziej efektywny przebieg. Analogicznie, wartość W wahań powoduje preferowanie bardziej regularnych przebiegów. Wprowadzenie numeru bitu daje mniejsze prawdopodobieństwo zmiany starszych bitów, co ogranicza gwałtowne modyfikacje parametru.

Stać normująca C jest dobierana doświadczalnie; może zostać oszacowana poprzez przewidywaną efektywność systemu oraz wahanie dążące do zera.

Wprowadzenie wahań wartości ocen umożliwia silne preferowanie przebiegów o dobrej ocenie w przypadku znalezienia optymalnego przedziału parametrów oraz – ze względu na nieregularność – duże modyfikacje przebiegów w przypadku, gdy dobre oceny zostały osiągnięte dla wartości parametru dającego minimum lokalne funkcji oceny. Przykładowe znalezienie lokalnego minimum daje niskie wartości M oraz W ; co znacznie obniża prawdopodobieństwo dalszej modyfikacji parametru, a więc praktycznie przekłada się to na zawężenie obszaru poszukiwań tylko do najbliższego otoczenia. Jeśli natomiast zostanie znalezione kilka wartości o porównywalnych, dobrych ocenach, znacznie obniża się wówczas wartość wahań ocen O , co powoduje skupienie dalszych poszukiwań w najbliższym otoczeniu wyznaczonego parametru. Zatem wartość ta może być odpowiednikiem szerokości przedziału poszukiwań (lub temperatury w algorytmach symulowanego wyżarzania).


Po dokonaniu modyfikacji reprezentacji bitowej nowej wartości parametru dokonywana jest jej zamiana na wartość zmiennopozycyjną, którą ustalamy jako nową wartość parametru systemu.

Należy zaznaczyć, że ze względu na wprowadzone prawdopodobieństwo zmiany (mutacji) bitu nie gwarantuje ona znalezienia optymalnego przedziału. Skuteczność można poprawić poprzez odpowiedni dobór współczynników (stałych) wykorzystywanych w funkcji oceny i przy wyliczaniu prawdopodobieństwa.


6. Wyniki badań

Na rysunku 3 porównano przebieg ze stałym parametrem oraz ze zmiennym, wykorzystującym zaprezentowany algorytm, dla symulacji systemu składającego się z 5 agentów, 7 zadań, z początkową wartością parametru $p = 7$. Dla tej liczby zadań i agentów, optymalną wartością parametru jest $p = 1,40$; jako przedział optymalny wartości parametrów można przyjąć zakres $p = [1,0; 1,7]$. Ustabilizowana optymalna wartość parametru wyniosła $p = 1,4213$.

Na rysunku 4 przedstawiono wartości funkcji oceny i kolejne wartości parametru symulacji.



Rys. 3. Porównanie przebiegu stanu systemu oryginalnego (ze stałym parametrem $p = 7$) oraz przebiegu z zastosowaniem proponowanego algorytmu redukcji; 5 agentów, 7 zadań, 20 000 iteracji



Rys. 4. Przebieg wartości funkcji oceny oraz zmiana parametru dla przedstawionego na rysunku 3 systemu z zastosowanym algorytmem redukcji (wartości znormalizowane do 1)

7. Podsumowanie

Przedstawiona propozycja adaptacyjnego algorytmu optymalizacji i redukcji zachowania chaotycznego powinna być traktowana jako pewien zarys postępowania. Dla konkretnej klasy systemów zarówno wartości wag, funkcja oceny oraz sposób wyliczania prawdopodobieństwa modyfikacji (mutacji) nowego parametru powinna zostać dobrana w oparciu o specyficzne cechy rozważanego systemu. Jednak ze względu na niewielką złożoność obliczeniową i szybki czas działania, wydaje się metodą, która skutecznie może poprawić regularność – a co za tym idzie, także efektywność działania systemu wieloagentowego. Stąd bardzo silny nacisk został położony na uniwersalność metody i możliwie jak najłabsze założenia.

Przedstawione wyniki są traktowane jako pewne narzędzia umożliwiające dalszą analizę oraz konstrukcję specyficznych systemów wieloagentowych. W szczególności odnosi się to do systemów, w których szczególnie istotna jest współpraca pomiędzy agentami oraz skuteczne rozłożenie wykonywanych zadań.

Ponadto należy zauważyć, że nawet stosunkowo nieskomplikowane systemy wieloagentowe z reguły generują zachowania nieregularne. Ich redukcja może znacznie ułatwić szacowanie oraz analizę i poprawę działania systemów.

Dodatkowym rozwinięciem przedstawionych algorytmów może być ponadto ich uogólnienie na wielowymiarowe parametry oraz funkcje oceny. W szczególności skutecznym narzędziem może okazać się dołączenie funkcji kary, reagującej na zbyt długie błędnie bez znalezienia przedziału optymalnego.

Literatura

- [1] Arabas J.: *Wykłady z algorytmów ewolucyjnych*. Warszawa, WNT 2001
- [2] Luck M., McBurney P., Preist Ch.: *Agent technology: Enabling Next Generation Computing. A Roadmap*. AgentLink II, 2003, <http://www.agentlink.org/roadmap/roadmap.pdf>
- [3] Michalewicz Z.: *Algorytmy genetyczne + struktury danych = programy ewolucyjne*. Warszawa, WNT 1999
- [4] Ott E.: *Chaos w układach dynamicznych*. Warszawa, WNT 1997
- [5] Poskrobko J., Cader A.: *Experimental determination of chaotic behaviour of agent and multiagent system state*. Proc. of the 1st FCCS Conference, Bronisławów, Poland, 2005
- [6] Shuster H.G.: *Chaos deterministyczny*. Warszawa, WNT 1993
- [7] Wołoszyn P.: *System multiagentowy jako dyskretny system dynamiczny o skończonej przestrzeni stanów – ujęcie formalne*. Proc. „Przetwarzanie i analiza sygnałów w systemach wizji i sterowania”, Słok k/Bełchatowa, 2004