

Dr inż. Radosław WINICZENKO
Katedra Podstaw Inżynierii, Wydział Inżynierii Produkcji, SGGW w Warszawie

ALGORYTMY GENETYCZNE I ICH ZASTOSOWANIA®

W artykule przedstawiono ogólną zasadę działania algorytmów genetycznych i ich zastosowanie w niektórych gałęziach inżynierii produkcji. Prostota działania algorytmów genetycznych i ich naturalność sprawiły, że stały się obiecującą metodą rozwiązań trudnych problemów technologicznych. Obecnie zastosowanie algorytmów genetycznych jest imponujące. Stosowane są one bowiem w szeregowaniu zadań, modelowaniu finansowym, optymalizacji czy harmonogramowaniu.

Algorytmy genetyczne zdobywają coraz szersze obszary zastosowań w środowiskach naukowych, inżynierskich i w kręgach biznesu. Przyczyna jest oczywista: algorytmy genetyczne stanowią nieskomplikowane, a przy tym potężne narzędzie poszukiwania lepszych rozwiązań.

WPROWADZENIE

Algorytmy genetyczne (z ang. Genetic Algorithms, GA) stanowią (naśladując naturalną ewolucję) metodę rozwiązywania problemów, głównie zadań optymalizacyjnych. Cechuje je duża uniwersalność oraz prostota procedur przeszukiwania najlepszych rozwiązań metodą stochastyczną. Algorytmy genetyczne są procedurami przeszukiwania opartymi na mechanizmach doboru naturalnego i dziedziczenia. Korzystają z ewolucyjnej zasady przeżycia osobników najlepiej przystosowanych. Od tradycyjnych metod optymalizacji różnią się kilkoma zasadniczymi elementami.

Algorytmy genetyczne:

- nie przetwarzają bezpośrednio parametrów zadania, lecz ich zakodowaną postać,
- prowadzą przeszukiwanie, wychodząc nie z pojedynczego punktu, lecz z pewnej ich populacji,
- korzystają tylko z funkcji celu, nie zaś z jej pochodnych lub innych pomocniczych informacji,
- stosują probabilistyczne, a nie deterministyczne reguły wyboru [16].

Celem pracy jest przedstawienie zasady działania algorytmów genetycznych jako doskonałego narzędzia optymalizacyjnego, które z powodzeniem może być zastosowane w przemyśle rolno-spożywczym.

HISTORIA ALGORYTMÓW GENETYCZNYCH

Za początek algorytmów genetycznych przyjmuje się prace biologów: Barricelliego oraz Frasera z początku lat sześćdziesiątych XX wieku. Symulowali oni procesy genetyczne przy pomocy komputerów. Chociaż nie myślano wtedy o zastosowaniu tych symulacji do rozwiązywania problemów matematycznych, nie były one zbyt odległe od współczesnego rozumienia algorytmów genetycznych. Podwaliny pod zastosowania algorytmów genetycznych w zagadnieniach sztucznej adaptacji położył John Holland podczas prac nad systemami adaptacyjnymi w roku 1962. Od tej pory zaczęto używać algorytmów genetycznych w coraz szerszej klasie zastosowań. W 1967r. Bagley opracował algorytm genetyczny grający w prostą grę logiczną. W 1970r. algorytmy zastosowano do systemu rozpoznającego postacie ludzkie (przykład problemu nierozwiązywalnego tradycyjnymi metodami). W 1971 pojawiła się pierwsza praca badająca skuteczność algorytmów genetycznych do optymalizacji funkcji (Hollstein).

PODSTAWOWE POJĘCIA GENETYCZNE

Algorytmy genetyczne swoje pojęcia zaczerpnęły wprost z genetyki. Do najczęściej używanych terminów należą: gen, chromosom, populacja, fenotyp. W literaturze możemy również spotkać pojęcia pochodzące ze słownictwa technicznego: łańcuch, ciąg binarny, struktura.

Osobniki są zakodowane w postaci chromosomów rozwiązania, określone jako punkty przestrzeni poszukiwań (z ang. *search points*).

Populacja jest zbiorem osobników o określonej liczebności.

Chromosomy, czyli łańcuchy stanowią uporządkowane ciągi genów. Długość chromosomów będzie uzależniona od warunków zadania. Warto podkreślić, że w organizmach żywych długość chromosomów może wynosić nawet do tysięcy genów.

Osobnik, który posiada parę chromosomów nazywa się osobnikiem diploidalnym, zaś osobnik z pojedynczym chromosomem nazywa się osobnikiem haploidalnym.

Gen, jak wiadomo z genetyki, jest podstawową materialną jednostką dziedziczenia, która jest związana z przekazywaniem poszczególnych cech dziedziczenia organizmu. Gen to pojedynczy element genotypu, w szczególności chromosomu. Gen może być również nazwany cechą, znakiem bądź detektorem.

Genotyp, czyli struktura jest zespołem chromosomów danego osobnika. W genetyce genotyp oznacza skład osobnika, w którym może występować więcej niż jeden chromosom. Komórki człowieka zawierają 46 chromosomów, natomiast w algorytmach genetycznych z reguły przyjmuje się, że genotyp składa się z jednego chromosomu, który jest traktowany jako osobnik populacji.


Fenotyp jest rozwiązaniem (zdekodowaną strukturą), punktem przestrzeni poszukiwań. Fenotyp jest zestawem wartości odpowiadających danemu genotypowi.

Allel to wartość danego genu. Może być również określaną jako wartość cechy.

Locus jest pozycją danego genu w chromosomie. Wskazuje na miejsce położenia danego genu w łańcuchu.

ZASADA DZIAŁANIA ALGORYTMU GENETYCZNEGO

Klasyczny algorytm genetyczny przebiega wg schematu przedstawionego na rysunku 1.



Rys. 1. Schemat blokowy działania klasycznego algorytmu genetycznego [16].

Na początku odbywa się *losowy wybór osobników* (chromosomów) do populacji początkowej. Chromosomy są reprezentowane przez ciągi binarne o określonej długości. Następnie dokonuje się *oceny przystosowania osobnika* w populacji na podstawie obliczonej funkcji przystosowania. Jeśli spełniony jest warunek końcowy (zatrzymania), następuje zapamiętanie najlepszego chromosomu. Jeśli nie, to następnym krokiem jest *selekcja osobników*.

W *selekcji osobników* naśladuje się mechanizm przeżycia w naturze. Oczekujemy, że osobnik o najwyższym stopniu przystosowania uzyska liczne potomstwo, tj pomnoży swój materiał genetyczny do następnego pokolenia. Natomiast osobniki o najniższym stopniu przystosowania powinny być wyeliminowane z procesu prokreacji. Najbardziej popularnymi metodami selekcji są: *metoda ruletki*, *turniejowa* czy *metoda rankingowa*.

Kolejnym ważnym etapem działania algorytmu genetycznego jest zastosowanie *operatorów genetycznych*. W klasycznym algorytmie genetycznym występują dwa podstawowe operatory genetyczne: *operator krzyżowania* (ang. *crossover*) oraz *operator mutacji* (ang. *mutation*). Krzyżowanie polega na wymianie fragmentu genotypu pomiędzy dwoma osobnikami. Proces ten odbywa się z założonym wcześniej prawdopodobieństwem p_k . Mutacja polega na zmianie wartości pojedynczego genu na przeciwny z prawdopodobieństwem p_m . Osobniki (chromosomy) otrzymane w wyniku działania operatorów genetycznych wchodzi w skład *nowej populacji*, która automatycznie staje się populacją bieżącą dla danej iteracji. Dla każdej następnej iteracji oblicza się wartość funkcji przystosowania i sprawdza się warunek zatrzymania. Jeśli warunek zatrzymania nie jest spełniony dalej przechodzi się do selekcji i kolejnych etapów algorytmu. Jeśli warunek jest spełniony wyprowadza się wynik w postaci chromosomu o największej wartości funkcji przystosowania.

FUNKCJA PRZYSTOSOWANIA

Funkcja przystosowania (z ang. *fitness function*) jest bardzo istotnym pojęciem w algorytmach genetycznych, ponieważ od jej poprawnego sformułowania zależy ocena chromosomów podczas ewolucji. Nazwana również *funkcją dopasowania* lub *funkcją oceny* jest miarą przystosowania (dopasowania) danego osobnika w populacji. Na jej podstawie oceniamy stopień przystosowania danego osobnika w populacji i wybieramy osobnika o największej wartości funkcji przystosowania. W zagadnieniach optymalizacyjnych funkcją przystosowania jest funkcja maksymalizowana. W zagadnieniach minimalizacji przekształca się funkcję celu, sprowadzając problem do zagadnienia maksymalizacji. W teorii sterowania, funkcja przystosowania może być *funkcją błędu*, a w teorii gier *funkcją kosztu* [16].

ZASTOSOWANIA ALGORYTMÓW GENETYCZNYCH

Algorytmy genetyczne mogą być użyte do rozwiązywania problemów, w których inne metody są nieskuteczne i mało efektywne. Często są to problemy nieliniowe, nieciągłe, źle uwarunkowane lub trudne do matematycznego sformułowania.

Algorytmy genetyczne stosuje się jako doskonałe narzędzie do poprawienia efektywności innych metod optymalizacji poprzez wskazanie dobrych punktów startowych dla tych metod [6].

Dzięki swojej wydajności i prostocie implementacji AG znalazły szerokie zastosowanie w rozwiązywaniu problemów takich jak: szeregowanie zadań, konstrukcja strategii inwestycyjnych, modelowanie finansowe, optymalizacja funkcji, podejmowanie decyzji oraz minimalizacja kosztów czy harmonogramowanie pracy itp. [19].

W zarządzaniu produkcją, algorytmy genetyczne zastosowano do znalezienia optymalnych wartości wielu parametrów, które reprezentują wagi pewnych kryteriów. Celem pracy [8] był dobór odpowiednich wag dla każdego z surowców, których ilość jest wyrażona w różnych jednostkach. W tym przypadku zajmowano się harmonogramowaniem czterech maszyn, przy założeniu, że dana operacja wykonana jest za pomocą jednej maszyny a maszyny pracują w trybie sekwencyjnym.

W dalszych pracach zajmowano się udoskonaleniem przepływu podzespołów przez gniazdo wytwórcze [8,13] lub minimalizacją kosztów transportu, czasu pracy maszyny i czasu jej przygotowania do pracy. Wystąpił również problem harmonogramowania pracy elastycznego gniazda produkcyjnego oraz zapewnienie minimalnego czasu procesu produkcyjnego w otwartym (z ang. *open shop*) systemie produkcyjnym.

Za pomocą algorytmu genetycznego prognozowano popyt na określone produkty w celu ustalenia wielkości produkcji w danym okresie planistycznym [17].

W budowie maszyn wykorzystano algorytmy genetyczne do zaprojektowania odpowiednich cech sieci przemysłowej płynów. Często wykorzystuje się tę metodę do optymalizacji kształtu poprzez zminimalizowanie masy własnej z uwzględnieniem zachowania odpowiednich właściwości wytrzymałościowych.

W niektórych pracach algorytmy użyto do optymalizacji parametrów technologicznych niektórych metod spajania materiałów czy optymalizacji kosztów całego procesu technologicznego [4].

W przemyśle lotniczym zastosowano wielokryterialną optymalizację konstrukcji skrzydła samolotu poprzez minimalizację jego ciężaru, minimalizację oporu aerodynamicznego, indukowanego czy falowego czy nawet maksymalizację ilości paliwa magazynowanego w skrzydle [15].

W eksploatacji maszyn algorytmy genetyczne znalazły zastosowanie do kontroli sposobu wytwarzania energii elektrycznej z zastosowaniem kilku jej źródeł jak również do rozwiązania odwrotnego zadania przepływu ciepła. Kolejnymi przykładami tej metody poszukiwań są optymalizacje sieci komputerowej, projektowanie laminatów czy poszukiwanie strategii rozwiązania pewnych problemów sterowania.

Podstawowym celem pracy [1] była optymalizacja sieci komputerowej poprzez zapewnienie jej sprawnego i efektywnego funkcjonowania. Autorzy tej publikacji zastosowali zmodyfikowany algorytm genetyczny, wykorzystujący sterownik rozmyty oceniający poszczególnych osobników w danej populacji.

Badania nad tymi metodami heurystycznymi dotyczyły również różnych zagadnień z zarządzania, takich jak: identyfikacja reguł do prognozowania rentowności przedsiębiorstwa, ustalanie preferencji konsumenta, prognozowanie na rynku finansowym, analiza bankructwa, klasyfikacja ryzyka kredytowego, zarządzanie łańcuchem dostaw [10], ustalanie optymalnego czasu reklamowego w telewizji, zadania transportowe a także optymalizacja sieci dystrybucyjnej [11].

PODSUMOWANIE

Algorytmy genetyczne mogą być doskonałym narzędziem optymalizacyjnym, które z powodzeniem może być zastosowane w przemyśle rolno-spożywczym.

Zakłady produkcyjne w przemyśle spożywczym wyposażone są w liczne linie technologiczne do wytwarzania żywności. Maszyny i urządzenia, które stanowią elementy składowe tych linii produkcyjnych wymagają ciągłej optymalizacji. Optymalizacja może dotyczyć parametrów procesów technologicznych jak temperatura czy ciśnienie oraz parametrów procesu takich jak zapotrzebowanie mocy czy wydajność. Istnieje również duże zróżnicowanie w konstrukcjach i parametrach pracy tych maszyn i urządzeń, która wynika z różnorodności przetwarzanych surowców, wytwarzanych produktów i zmienności ich właściwości [12]. Algorytmy genetyczne mogą również służyć do optymalizacji systemów sterujących procesami technologiczno-transportowymi. Duże znaczenie i udział w logistyce przemysłu rolno-spożywczego mają maszyny i urządzenia transportowe, które gwarantują przepływ masy towarowej przychodzącej i wychodzącej w obrębie wydziałów produkcyjnych i poszczególnych stanowisk. Istotną rolę odgrywa tu specjalistyczny transport żywności, zbóż, mleka, owoców i warzyw, mięsa czy innych surowców, który wymaga wyposażenia w systemy sterujące procesami technologicznymi. Systemy te mogą być wspomagane procedurami poszukiwań lepszych rozwiązań za pomocą metod sztucznej inteligencji.

Jednak nie należy się spodziewać, że rozwiązanie znalezione przez algorytm genetyczny będzie rozwiązaniem optymalnym, najlepszym z możliwych. Nie jest to oczywiście wykluczone, lecz na ogół otrzymane rozwiązanie znajduje się w sąsiedztwie rozwiązania optymalnego, co w znakomitej większości problemów jest satysfakcjonujące na tyle, że nie ma potrzeby dalszego poszukiwania rozwiązania optymalnego [6].

Według autora [14] algorytmy genetyczne nadają się do skomplikowanych zadań optymalizacji kombinatorycznej o dużej skali i zadań inżynierskich z wieloma ograniczeniami. Różnią się one znacznie od algorytmów czysto losowych, gdyż łączą elementy przeszukiwania bezpośredniego i stochastycznego, z tego powodu algorytmy genetyczne są bardziej niezawodne niż istniejące algorytmy bezpośredniego przeszukiwania. Drugą ważną cechą metod opartych na przeszukiwaniach genetycznych jest fakt, że zachowują one całe populacje potencjalnych rozwiązań, gdy tymczasem inne metody przetwarzają tylko jeden punkt przeszukiwań przestrzeni.

LITERATURA

- [1] Akbulut O., Osman O., Ucan O.: Computer Network optimization using genetic algorithm, *Journal of Electrical & Electronics Engineering*, Volume 6, No.2, 2006.
- [2] Arabas J.: Wykłady z algorytmów ewolucyjnych, WNT, Warszawa, 2001.
- [3] Biethahn J., Nissen V.: *Evolutionary Algorithms in Management Applications*, Springer-Verlag, Berlin, Heidelberg 1995.
- [4] Correia D., Ferraresi V.: Welding process selection through a double criteria: Operational cost and non-quality costs, *Journal of Materials Processing Technology*, 184, 2007.
- [5] Cytowski J.: Algorytmy genetyczne: podstawy i zastosowania, PLJ, Warszawa 1996.
- [6] Goldberg D.E.: Algorytmy genetyczne i ich zastosowanie, Wydawnictwo Naukowo-Techniczne, Warszawa 1998.
- [7] Guvenir H.A., Vel E.: Multicriteria Inventory Classification using Genetic Algorithm, *EJOR* 1998.
- [8] Hang Q., Fan Z.: A genetic algorithm for Job-Shop Multiobjective Scheduling on Multiple Machines, *Modeling Management and Control MIM* 1997, Vienna.
- [9] Knosala R.: Zastosowanie metod sztucznej inteligencji w inżynierii produkcji, Wydawnictwo Naukowo-Techniczne, Warszawa 2002.
- [10] Lee H., Kim S.: Integration of process planning and scheduling using simulation based genetic algorithms, *Int. J. Adv. Manuf. Technology*, 2001.
- [11] Lee SG., Khoo LP., Yin XF.: Optimising an assembly line through simulation augmented by genetic algorithms, *Int. J. Adv. Manuf. Technol.*, 2000.
- [12] Lenart A.: *Maszynoznawstwo przemysłu spożywczego*, Wydawnictwo SGGW, 2003.
- [13] Maturami F., Gu P., Naumann A.: Object-Oriented Job-Shop Scheduling Using Genetic Algorithm, *Computers in Industry* 1997.

- [14] Michalewicz Z.: Algorytmy genetyczne + Struktura danych = Programy ewolucyjne, Wydawnictwo Naukowo-Techniczne, Warszawa 1999.
- [15] Obayashi S.: Pareto Genetic Algorithm for Aerodynamic Design Using the Navier–Stokes Equation,” Genetic Algorithms in Engineering, John & Willey & Sons, 1998.
- [16] Rutkowska D., Piliński M., Rutkowski L.: Sieci neuronowe, algorytmy genetyczne i systemy rozmyte, Wydawnictwo Naukowe PWN, Warszawa 1999.
- [17] Stockton and L. Quinn.: Aggregate production planning using genetic algorithms, Journal of engineering Manufacture, 1995.
- [18] Vose M.D.: The simple genetic algorithm, Foundations and Theory”, MIT Press, Cambridge, Massachusetts, 1999.
- [19] Zieliński J.S.: Inteligentne systemy w zarządzaniu, Teoria i Praktyka, PWN, Warszawa 2000.

GENETIC ALGORITHMS AND THEIR APPLICATIONS

SUMMARY

The paper presents a general principle of genetic algorithms operation and their application in production. The genetic algorithms have more and more applications in scientific, engineering and management fields. The reason of this popularity is quite obvious: the genetic algorithms are simple, but also powerful tool for searching of better results.

GA are biologically inspired search procedures that have been used to solve different NP-hard problems. They try to extract ideas from a natural system, in particular the natural evolution, in order to develop computational tools for solving engineering problems.