



Algorytmy genetyczne – populacja

- [Wprowadzenie](#)
- [Przeczytaj](#)
- [Audiobook](#)
- [Sprawdź się](#)
- [Dla nauczyciela](#)



W biologii populacją nazywamy grupę osobników jednego gatunku zamieszkujących dany obszar w określonym czasie. W ramach danej populacji występują różne procesy i zdarzenia, które wpływają na jej strukturę oraz potomstwo.

Podobnie funkcjonuje populacja w algorytmach genetycznych. Poszczególne jej osobniki, które reprezentują najlepsze rozwiązanie, są selekcjonowane i na ich podstawie powstaje nowe pokolenie. Możemy wpływać na rezultat algorytmu poprzez używanie odpowiednich selekcji, krzyżowań i mutacji genów.

Więcej informacji o algorytmach genetycznych znajdziesz w pozostałych e-materiałach tej serii:

- [Algorytmy genetyczne,](#)
- [Algorytmy genetyczne – projektowanie,](#)
- [Algorytmy genetyczne – zastosowanie,](#)
- [Algorytmy genetyczne – przeszukiwanie dużych przestrzeni rozwiązań.](#)


Twoje cele

- Poznasz różne metody selekcji i krzyżowania osobników.
- Dowiesz się, na czym polega mutacja genu.
- Przeanalizujesz działanie algorytmu genetycznego na prostym przykładzie.

Przeczytaj

Schemat działania algorytmu genetycznego

Zanim przystąpimy do szczegółowego omówienia poszczególnych etapów algorytmu genetycznego, przypomnijmy sobie podstawowy schemat jego działania zaprezentowany na poprzedniej lekcji.



Źródło: Contentplus.pl Sp. z o.o., licencja: CC BY-SA 3.0.

Algorytm zaczyna swoje działanie od wygenerowania pierwszej populacji. Najczęściej jest to wykonywane w sposób losowy. Następnie za pomocą określonej **funkcji przystosowania** każdemu z osobników przypisywana jest wartość, która jest odwzorowaniem jego jakości z punktu widzenia rozwiązywanego problemu. Zależy nam, aby za pomocą odpowiedniej **metody selekcji** wybrać najbardziej interesujących nas osobników z danej populacji. Następnie są oni poddawani zmianom za pomocą **operatorów genetycznych** takich jak **operator krzyżowania** oraz **operator mutacji**. Następnie zgodnie z wybraną **metodą sukcesji** tworzymy nową populację, która ponownie może być poddana naszemu algorytmowi genetycznemu.

Metody selekcji


Wybór odpowiedniej metody selekcji podczas projektowania naszego algorytmu genetycznego ma bardzo duży wpływ na jego jakość. Oto najczęściej wykorzystywane metody:

- **metoda koła ruletki** – polega ona na przydzieleniu każdemu osobnikowi takiego wycinka koła ruletki, jaki odpowiada jego jakości przystosowania w stosunku do innych – im lepszy osobnik, tym większy wycinek koła zajmuje. Oznacza to, że rozkładamy prawdopodobieństwo wylosowania osobników w sposób proporcjonalny do ich jakości.
- **selekcja rankingowa** – polega na przydzieleniu każdemu osobnikowi pewnej rangi, bazując na wartości jego przystosowania. Dzięki temu porządkujemy danych osobników w kolejności od najlepszego do najgorszego. Następnie wybieramy pewną określoną liczbę najlepszych osobników, którzy wezmą udział w rozmnażaniu. Osobniki, które nie zostały wybrane, są usuwane z populacji.
- **metoda turniejowa** – metoda ta dzieli populację na grupy, a następnie pomiędzy osobnikami z danej grupy jest rozgrywany turniej. Polega on na wyborze najlepszego osobnika w sposób deterministyczny lub losowy. Kolejną populację tworzą zwycięzcy turnieju z każdej grupy. Rozmiar grup może być dowolny, jednak najczęściej składają się one z dwóch lub trzech osobników.

Krzyżowanie osobników

Założmy, że w naszym algorytmie genetycznym osobnik jest reprezentowany przez 8-bitową liczbę całkowitą. Każdy z bitów to jego **gen**, czyli wartość odpowiadająca pewnej cesze.

Po wybraniu grupy interesujących nas osobników z danej populacji następuje ich krzyżowanie. Jest to proces wymiany części informacji genetycznej pomiędzy rodzicami. Chromosomy rodzicielskie rozcinane są na dwa lub więcej fragmentów, a następnie pewne dwa fragmenty są między nimi wymieniane. W ten sposób powstają nowe osobniki.




Przykład krzyżowania jednopunktowego

Źródło: Contentplus.pl Sp. z o.o., licencja: CC BY-SA 3.0.

Krzyżowanie nie zachodzi zawsze. Zazwyczaj w programie ustalamy pewne prawdopodobieństwo jego zajścia. Dodatkowo ze względu na liczbę punktów przecięć chromosomu wyróżniamy dwa rodzaje krzyżowań:

- **krzyżowanie jednopunktowe** – dwa rodzicielskie chromosomy przecinamy w jednym konkretnym punkcie, najczęściej jest to środek;
- **krzyżowanie wielopunktowe** – dwa rodzicielskie chromosomy przecinamy w dwóch lub więcej punktach.




Przykład krzyżowania wielopunktowego

Źródło: Contentplus.pl Sp. z o.o., licencja: CC BY-SA 3.0.

Mutacja genów

Osobniki powstałe w wyniku krzyżowania są następnie poddawane procesowi mutacji. Polega on na losowej zmianie wartości genów danego osobnika. Tak samo jak w przypadku krzyżowania, mutacja ma pewne określone prawdopodobieństwo zajścia. Najczęściej jest ono bardzo małe (w okolicy 1%), ponieważ w przeciwnym razie w wynikach pojawiłoby się za dużo losowości, a ewentualne korzystne zmiany nie będą miały szans na utrwalenie się w populacji.

Jeżeli nasz osobnik jest reprezentowany przez 8-bitową liczbę całkowitą, to mutacja polega na negacji konkretnego bitu. Przechodzimy po każdym genie każdego osobnika i losujemy zdarzenie zajścia mutacji.



Źródło: Contentplus.pl Sp. z o.o., licencja: CC BY-SA 3.0.

Zastosowanie mutacji w naszym algorytmie genetycznym jest kluczowe. Dzięki niej dodawana jest pewna losowość, która gra istotną rolę w procesie przeszukiwania przestrzeni możliwych rozwiązań.

Metody sukcesji

Po wykonaniu operacji krzyżowania oraz mutacji należy przeprowadzić proces [sukcesji](#). Wybór odpowiedniej metody sukcesji wpływa na szybkość znajdowania optymalnego rozwiązania, ale też może zwiększać ryzyko osiągnięcia lokalnych ekstremów lub przedwczesnej zbieżności. Oto najczęściej wykorzystywane metody sukcesji:

- **sukcesja z całkowitym zastępowaniem** – nową populacją bazową staje się populacja potomna. Oznacza to, że żaden osobnik z poprzedniej populacji nie zostaje przeniesiony do nowej. Metoda ta najwolniej prowadzi do optymalnego rozwiązania, ale jest najbardziej odporna na tendencję osiągnięcia ekstremów.
- **sukcesja z częściowym zastępowaniem** – w nowej populacji znajdują się osobniki z poprzedniej i potomnej populacji. Metoda ta prowadzi zwykle do stabilniejszej pracy

algorytmu ewolucyjnego, ale może spowodować tendencję do osiągnięcia ekstremów lokalnych.


- **sukcesja elitarna** – gwarantuje, że w nowej populacji znajduje się co najmniej jeden najlepszy osobnik z poprzedniej populacji. Może to przyspieszyć znalezienie optymalnego rozwiązania, ale tym samym zwiększa prawdopodobieństwo osiągnięcia ekstremów lokalnych.

Przykład algorytmu genetycznego

Do lepszego wyjaśnienia mechanizmów działania populacji, prześledzimy działanie jednej iteracji algorytmu genetycznego na przykładowym problemie. Będziemy dążyć do minimalizacji wartości funkcji na zbiorze liczb całkowitych z przedziału $[0, 31]$. Nasza funkcja jest dana następującym wzorem:

$$f(x) = x^3 - 24x^2 - 180x$$

Ponieważ poszukujemy najmniejszej wartości funkcji w przedziale $[0, 31]$, to osobnikiem w naszym algorytmie genetycznym będzie 5-bitowa liczba całkowita. Będzie to argument naszej funkcji zapisany w systemie dwójkowym.



Parametry i metody naszego algorytmu genetycznego:

- **metoda selekcji:** metoda koła ruletki,
- **krzyżowanie:** jednopunktowe,
- **prawdopodobieństwo krzyżowania:** 1,
- **prawdopodobieństwo mutacji:** 0,02,
- **metoda sukcesji:** sukcesja z całkowitym zastępowaniem.
- **rozmiar populacji:** 6

Pozostaje jeszcze kwestia wyboru populacji startowej algorytmu genetycznego. W tym przypadku została ona wygenerowana w sposób losowy. Przy użyciu generatora liczb pseudolosowych wylosowano sześć liczb całkowitych z przedziału $[0, 31]$.

Numer osobnika	Populacja początkowa	Wartość x	Wartość $f(x)$	Prawdopodobieństwo wylosowania osobnika	Liczba wylosowany kopii
1	00101	5	-1375	0,0856	0
2	10011	19	-5225	0,3253	2
3	00111	7	-2093	0,1304	1
4	01100	12	-3888	0,2421	2
5	11101	29	-1015	0,0632	0
6	01000	8	-2464	0,1534	1

Następnie po jednej iteracji algorytmu genetycznego otrzymujemy:

Pula rodzicielska	Wylosowany punkt krzyżowania	Populacja po krzyżowaniu	Populacja po mutacji	Wartość x	Wartość $f(x)$
10011	2	10100	10100	20	-5200
01100	2	01011	01011	11	-3553
10011	3	10000	10010	18	-5184
01000	3	01011	01011	11	-3553
01100	2	01111	01111	15	-4725
00111	2	00100	01100	12	-3888

Po jednej iteracji algorytmu najmniejszą wartością funkcji f jaką udało nam się uzyskać w nowym pokoleniu jest $f(20) = -5200$. Jest to wynik gorszy niż w poprzednim pokoleniu, który wynosił $f(19) = -5225$. Taka sytuacja może się wydarzyć ze względu na losowość naszego algorytmu genetycznego. Można temu zapobiec, stosując inną metodę selekcji lub sukcesji. Innym możliwym rozwiązaniem jest zwiększenie liczby iteracji i zapisywanie najlepszego wyniku spośród wszystkich dotychczasowych populacji.

Zastosowania algorytmów genetycznych

Algorytmy genetyczne są najczęściej wykorzystywane do rozwiązywania problemów optymalizacyjnych. Wykorzystując element losowości, są one w stanie lepiej przeszukiwać

duże przestrzenie rozwiązań w porównaniu do standardowych algorytmów deterministycznych.

Natomiast problemy optymalizacyjne można znaleźć w wielu różnych dziedzinach. Może to być problem zaprojektowania skrzydła samolotu o pewnej powierzchni i jak najmniejszej wadze. Projektując układy bramek logicznych w układzie elektronicznym, warto optymalizować jego koszt budowy przy zachowaniu pewnej funkcjonalności. Algorytmy genetyczne można także zastosować przy doborze liczby neuronów w warstwach ukrytych sieci neuronowych. Wtedy parametrem poddawany optymalizacji jest poprawność działania sieci.

Słownik

sukcesja

proces zastępowania osobników ze starej populacji

inicjalizacja heurystyczna populacji

metoda wyboru populacji startowej algorytmu genetycznego polegająca na doborze konkretnej puli osobników, zazwyczaj mało różnorodnej

Polecenie 1

Przesłuchaj audiobook, a następnie zastanów się, jak dużą rolę pełni populacja w algorytmach genetycznych.

Audiobook można wysłuchać pod adresem: <https://zpe.gov.pl/b/PuUOddMvA>

Populacja w algorytmach genetycznych

Poznaliśmy już najważniejsze etapy funkcjonowania algorytmów genetycznych, a także przeanalizowaliśmy dokładnie, jak działają operatory krzyżowania oraz mutacji. Przyjrzyjmy się teraz bliżej samemu doborowi początkowej puli populacji. Jest to pierwszy, a zarazem dość istotny krok w przebiegu całego algorytmu i może wpłynąć między innymi na jakość finalnych rezultatów.

Zazwyczaj wybór populacji początkowej jest całkowicie losowy. Jednak bywają sytuacje, gdy wykorzystujemy inicjalizację heurystyczną. Polega ona na doborze konkretnej puli populacji, zazwyczaj mało różnorodnej. Tego typu rozwiązanie wykorzystuje się najczęściej, gdy wiemy, w jakich obszarach pragniemy szukać rozwiązań naszego problemu. Jednocześnie gwarantuje ono znacznie większą szybkość i niezawodność przeprowadzanych operacji.

Należy pamiętać jednak, że mniejsza różnorodność wiąże się również z uzyskaniem nieoptymalnego rozwiązania. Co ciekawe, istnieje możliwość połączenia obu typów inicjalizacji. Wybieramy gotową populację, a następnie dodajemy do niej grupę losowych rozwiązań. W ten sposób możemy zapewnić większą różnorodność w populacji niż w przypadku podejścia heurystycznego oraz większą szybkość i niezawodność przeprowadzanych operacji niż w przypadku inicjalizacji losowej. Teoretycznie można byłoby nazwać to rozwiązanie złotym środkiem, jednak należy pamiętać, że typ doboru początkowej populacji powinien być dostosowany do sytuacji.

Gdy wiemy już, jak wygląda wstępna inicjalizacja, warto poruszyć temat modeli populacji. Różne modele umożliwiają większe lub mniejsze dostosowanie przebiegu wykonywania algorytmu do naszych potrzeb i oczekiwań. Istnieje szereg różnych klasyfikacji modeli, jednakże my skupimy się na ich podziale na lokalne, regionalne i globalne. Podział ten bazuje na strategii wyboru rodziców, a także doboru obszaru

selekcji. W przypadku modelu globalnego proces selekcji odbywa się na całej populacji, nie ograniczając w żaden sposób doboru rodziców. Jest to wręcz klasyczny wariant algorytmu genetycznego.

Model regionalny bazuje na podziale pełnej populacji na określoną ilość podgrup zwanych subpopulacjami. Rodziców możemy dobrać tylko z obszaru tej samej subpopulacji. Po pewnym czasie nastąpić może proces migracji, w ramach którego część rozwiązań jest przenoszona do innych grup. Ma on na celu zwiększenie różnorodności pomiędzy osobnikami w tej samej populacji. Dużym plusem modelu regionalnego jest znaczne przyspieszenie czasu przeprowadzania obliczeń.

Ostatnim rozpatrywanym modelem będzie model lokalny. Ogranicza on wybór rodziców jedynie do sąsiadujących ze sobą rozwiązań. W ten sposób wraz z każdym kolejnym pokoleniem następować będzie przekazanie części genów przodków do coraz dalej ulokowanych osobników.

Podsumowując, zarówno dobór początkowej populacji, jak i obrany jej model w znaczny sposób wpłynąć mogą na sam przebieg wykonywania naszego algorytmu oraz jego rezultat. Szereg przedstawionych możliwości pozwala nam uzyskiwać ciekawe wyniki oraz testować algorytmy genetyczne pod przeróżnymi kątami. Warto o tym pamiętać, nawet jeżeli zazwyczaj korzystać będziemy z klasycznej inicjalizacji losowej i modelu globalnego.

Sprawdź się

Pokaż ćwiczenia:   

Ćwiczenie 1



Wskaż, na czym polega sukcesja elitarna.

☐

Polega ona na tym, że nową populacją bazową staje się w całości populacja potomna.

☐

Gwarantuje ona, że w nowej populacji znajdzie się co najmniej jeden najlepszy osobnik z poprzedniej populacji.

☐

Gwarantuje ona, że w nowej populacji znajdzie się co najmniej jeden najgorszy osobnik z poprzedniej populacji.

Ćwiczenie 2



Wskaż, na czym nie polega proces krzyżowania.

☐

Na wyborze najlepiej przystosowanych osobników w danej populacji.

☐

Na wymianie części informacji genetycznej pomiędzy rodzicami.

☐

Na losowej zmianie wartości genów danego osobnika.

Ćwiczenie 3



Wskaż operację, która zachodzi jako pierwsza w danej iteracji algorytmu genetycznego.

☐

sukcesja

☐

selekcja

☐

mutacja

☐

krzyżowanie

Ćwiczenie 4



Wskaż, na co wpływa wybór odpowiedniej metody sukcesji.

- ☐ Na ryzyko osiągnięcia lokalnych ekstremów.
- ☐ Na ryzyko osiągnięcia przedwczesnej zbieżności.
- ☐ Na szybkość działania algorytmów.
- ☐ Na ryzyko wyginięcia populacji.
- ☐ Na szybkość znajdowania optymalnego rozwiązania.

Ćwiczenie 5



Oceń prawdziwość stwierdzenia: „sukcesja z całkowitym zastępowaniem najszybciej prowadzi do rozwiązania optymalnego”.

- ☐ prawda
- ☐ fałsz

Ćwiczenie 6



Zaznacz wszystkie najczęściej wykorzystywane metody sukcesji.

- ☐ sukcesja z nadzorem
- ☐ sukcesja z całkowitym zastępowaniem
- ☐ sukcesja z częściowym zastępowaniem
- ☐ sukcesja elitarna
- ☐ sukcesja militarna

Ćwiczenie 7



Wstaw brakujące wyrażenia tak, aby treść poniższego tekstu była prawdziwa.

Osobniki powstałe w wyniku krzyżowania są następnie poddawane procesowi .

Polega on na losowej zmianie wartości danego osobnika. Prawdopodobieństwo jej zajścia zazwyczaj wynosi około , ponieważ w przeciwnym razie w wynikach pojawiłoby się za losowości. Mutacja jest kluczowa do odpowiedniego przeszukiwania przestrzeni możliwych rozwiązań.

Ćwiczenie 8



Połącz w pary metody selekcji z ich opisami.

selekcja rankingowa

polega na przydzieleniu każdemu osobnikowi prawdopodobieństwa wylosowania w sposób proporcjonalny do ich jakości

metoda turniejowa

po przydzieleniu każdemu osobnikowi pewnej rangi bazując na ich przystosowaniu, wybieramy pewną ilość najlepszych spośród nich

metoda koła ruletki

dzielimy osobniki populacji na podgrupy, a następnie wybieramy z każdej z nich osobnika o najlepszym przystosowaniu

Dla nauczyciela

Autor: Bartosz Zadrozny

Przedmiot: Informatyka

Temat: Algorytmy genetyczne – populacja

Grupa docelowa:

Szkoła ponadpodstawowa, liceum ogólnokształcące, technikum, zakres rozszerzony

Podstawa programowa:

Cele kształcenia – wymagania ogólne

I. Rozumienie, analizowanie i rozwiązywanie problemów na bazie logicznego i abstrakcyjnego myślenia, myślenia algorytmicznego i sposobów reprezentowania informacji.

Treści nauczania – wymagania szczegółowe

I. Rozumienie, analizowanie i rozwiązywanie problemów.

Zakres rozszerzony. Uczeń spełnia wymagania określone dla zakresu podstawowego, a ponadto:

8) dyskutuje na temat roli myślenia komputacyjnego i jego metod, takich jak: abstrakcja, reprezentacja danych, dekompozycja problemu, redukcja, myślenie rekurencyjne, podejście heurystyczne w rozwiązywaniu problemów z różnych dziedzin.

III. Posługiwanie się komputerem, urządzeniami cyfrowymi i sieciami komputerowymi.

Zakres rozszerzony. Uczeń spełnia wymagania określone dla zakresu podstawowego, a ponadto:

2) dokonuje kompresji informacji, objaśnia różnice między kompresją stratną i bezstratną tekstów, obrazów, dźwięków, filmów;

Kształtowane kompetencje kluczowe:

- kompetencje cyfrowe;
- kompetencje osobiste, społeczne i w zakresie umiejętności uczenia się;
- kompetencje matematyczne oraz kompetencje w zakresie nauk przyrodniczych, technologii i inżynierii.

Cele operacyjne (językiem ucznia):

- Poznasz różne metody selekcji i krzyżowania osobników.
- Dowiesz się, na czym polega mutacja genu.
- Przeanalizujesz działanie algorytmu genetycznego na prostym przykładzie.

Strategie nauczania:

- konstruktywizm;
- konektywizm.

Metody i techniki nauczania:

- dyskusja;
- rozmowa nauczająca z wykorzystaniem multimediu i ćwiczeń interaktywnych;
- metody aktywizujące.

Formy pracy:

- praca indywidualna;
- praca w parach;
- praca w grupach;
- praca całego zespołu klasowego.

Środki dydaktyczne:

- komputery z głośnikami, słuchawkami i dostępem do internetu;
- zasoby multimedialne zawarte w e-materiale;
- tablica interaktywna/tablica, pisak/kreda;
- telefony z dostępem do internetu.

Przebieg lekcji

Przed lekcją:

1. **Przygotowanie do zajęć.** Nauczyciel loguje się na platformie i udostępnia e-materiał: „Algorytmy genetyczne – populacja”. Nauczyciel prosi uczniów o zapoznanie się z treściami w sekcji „Przeczytaj”.

Faza wstępna:

1. Nauczyciel wyświetla i odczytuje temat lekcji oraz cele zajęć. Prosi uczniów o sformułowanie kryteriów sukcesu.
2. **Rozpoznanie wiedzy uczniów.** Uczniowie tworzą pytania dotyczące tematu zajęć, na które odpowiedzą w trakcie lekcji.

Faza realizacyjna:

1. **Praca z tekstem.** Jeżeli przygotowanie uczniów do lekcji jest niewystarczające, nauczyciel prosi o indywidualne zapoznanie się z treścią zawartą w sekcji „Przeczytaj”. Każdy uczestnik zajęć podczas cichego czytania wynotowuje najważniejsze kwestie poruszane w tekście.
2. **Praca z multimediami.** Uczniowie pracują w parach. Słuchają audiobooka, a następnie zastanawiają się jak dużą rolę pełni populacja w algorytmach genetycznych. Wspólnie z nauczycielem omawiają wnioski.
3. **Ćwiczenie umiejętności.** Uczniowie wykonują indywidualnie ćwiczenia nr 1-8. Po wykonaniu każdego z nich następuje omówienie rozwiązania przez nauczyciela.

Faza podsumowująca:

1. Nauczyciel ponownie wyświetla na tablicy temat i cele lekcji zawarte w sekcji „Wprowadzenie”. W kontekście ich realizacji następuje omówienie ewentualnych problemów z rozwiązaniem ćwiczeń z sekcji „Sprawdź się”.

Praca domowa:

1. Uczniowie opracowują FAQ (minimum 3 pytania i odpowiedzi) do tematu lekcji („Algorytmy genetyczne – populacja”).

Wskazówki metodyczne:

- Treści w sekcji „Audiobook” można wykorzystać jako materiał służący powtórzeniu materiału.