

PRACE ORYGINALNE

Michał DOLECKI

ZASTOSOWANIE ALGORYTMÓW GENETYCZNYCH W TRENINGU POSTRZEGANIA I PAMIĘCI PILOTÓW STATKÓW POWIETRZNYCH

USE OF GENETIC ALGORITHMS IN THE TRAINING OF AIRCRAFT PILOTS PERCEPTION AND MEMORY

Katolicki Uniwersytet Lubelski Jana Pawła II, Lublin
Wydział Matematyczno-Przyrodniczy
Katedra Technologii Społeczeństwa Informacyjnego

The Pope John Paul II Catholic University, Lublin
Faculty of Mathematics and Natural Sciences
Department of Information Society Technology

STRESZCZENIE: ***Wstęp.** W pracy przedstawiono pożądane cechy charakteryzujące pilotów, którzy realizują zadania zwiadowcze i rozpoznawcze oraz desygnowanych do walki powietrznej. Zostały wskazane cechy związane z postrzeganiem i pamięcią, ze zwróceniem szczególnej uwagi na problem zapamiętywania cech obserwowanego terenu i odtwarzania ich z pamięci. Przedstawione zostały algorytmy genetyczne, które można użyć do wspomagania treningu postrzegania i pamięci pilotów. **Metoda.** Zastosowana została metoda symulacji komputerowej działania algorytmów genetycznych opartych na czterech różnych operatorach krzyżowania, w tym jednym nowym zaproponowanym w pracy. Do przeprowadzenia symulacji użyto autorskich programów komputerowych. Przeanalizowane zostały zadania polegające na odtworzeniu położenia obiektu na zadanym terenie oraz jego kształtu. **Wyniki.** W wyniku przeprowadzonych symulacji za każdym razem poprawnie odtworzono położenie obiektu oraz zadany kształt, co świadczy o możliwości zastosowania zaproponowanych algorytmów do stworzenia systemu komputerowego służącego do treningu pilotów oraz systemu wspomagającego realizację rzeczywistych zadań. W omówieniu*

Adres do korespondencji: mgr Michał Dolecki, Katedra Technologii Społeczeństwa Informacyjnego, Katolicki Uniwersytet Lubelski Jana Pawła II, 20-708 Lublin, ul. Konstantynów 1H, e-mail: michal.dolecki@kul.pl

przedstawiony został zarys takiego systemu. **Wnioski.** Otrzymane wyniki wskazują na celowość kontynuowania badań nad interakcją „człowiek – system” i odtwarzania bardziej skomplikowanych wzorców a także na sensowność dalszych prac nad nowym operatorem krzyżowania

SUMMARY: Objectives. Expected characteristics of pilots performing reconnaissance and reconnaissance flights, and pilots nominated for a fight are discussed. There were indicated characteristics associated with perception and memory, with particular attention to the problem of memorizing the characteristics of the observed area and restoring them from the memory. It have been presented genetic algorithms which can be used to support the training of perception and memory of the pilots. **Methods.** Method used in this paper is a computer simulation of genetic algorithms based on four different operators of crossover, including the one proposed in the work. To simulation were used computer programs created by an author of this paper. The following were analyzed: task of restoring the position of an object on a given area and restoring the shape of the observed object. **Results.** As a result of the simulation each time correctly reproduces the location of the object and the expected shape, which indicates the possibility of using proposed algorithms to create a computer system for pilots training and for support performing real tasks. **Conclusions.** The obtained results indicate necessity of continuing investigations on „man-system” interactions and recreation of more complicated patterns of such a system

KEYWORDS: Genetic algorithms, training pilots, perception, memorizing

Wstęp

Dynamicznie rozwijające się technologie informacyjne pozwalają na tworzenie oraz wykorzystywanie coraz dokładniejszych narzędzi usprawniających prace pilotów oraz żołnierzy zwiadu, rozpoznania i naprowadzania lotnictwa. Pilot realizujący zadanie operacyjne – lot w celu rozpoznania sytuacji i charakterystycznych obiektów – musi wykazać się wyobraźnią, zdolnością dedukcji, spostrzegawczością i pamięcią oraz określić moment i tor podejścia do celu. Innym zadaniem jest desygnowanie do walki powietrznej (z manewrami przeciwrakietowymi) lub loty wsparcia operacji z powietrza. W takim przypadku najistotniejszymi cechami są szybkość reakcji, odwaga, przewidywanie manewru przeciwnika (predykcja) oraz zdolność do działania pod presją czasu i stresu, co wymaga również umiejętności szybkiego analizowania wskazań aparatury pomiarowej. Wśród pozytywnych cech pilota Wojtkowiak i Jasiński wymieniają między innymi prawidłowe funkcje poznawcze pamięci i uwagi oraz dobrą percepcję bodźców [1]. Zdjęcia satelitarne oraz wykonywane przez samoloty bezzałogowe czy takie systemy, jak GPS, ułatwiają wykonywanie zadań żołnierzom oraz zwiększają ich bezpieczeństwo. Wciąż istnieją jednak miejsca, których rozpoznanie muszą wykonać sami żołnierze odpowiedzialni za naprowadzanie lotnictwa. Oczywiście w zbieraniu materiału rozpoznawczego mogą użyć miniaturowych kamer i aparatów cyfrowych oraz innych

narzędzi, ale problematyczne są sytuacje, w których zwiadowca musi sam zapamiętać jak najwięcej szczegółów obserwowanego miejsca, po czym odtworzyć z pamięci układ dostrzeżonych obiektów. Może to dotyczyć zarówno misji w miejscach niewidocznych dla zwiadu z powietrza, takich jak gęste lasy czy jaskinie górskie, jak i wywiadowczych, w miejscach gdzie nie ma możliwości wprowadzenia nowoczesnych aparatów i wszystkie szczegóły musi zapamiętać żołnierz. Pilot realizujący zadanie walki powietrznej musi pod presją czasu przeanalizować wskazania przyrządów pomiarowych, odtwarzając zapamiętane poprawne wskazania, natomiast pilot zwiadowca oraz żołnierz naprowadzania muszą umieć odtworzyć rozpoznaną sytuację oraz charakterystyczne obiekty. Bez względu więc na typ realizowanego zadania, spostrzeganie i zapamiętywanie są istotnymi umiejętnościami pilotów statków powietrznych i innych żołnierzy, dla których charakter wykonywanej misji odpowiada modelowi obserwatora.

Jak wiadomo, człowiekowi dużo łatwiej jest określić podobieństwa i różnice między rzeczą, którą już widział, a pokazanym mu obiektem, niż odtworzyć obraz zaobserwowanego przedmiotu bezpośrednio z pamięci. Aby umożliwić właśnie taki sposób odtwarzania zapamiętanych obiektów oraz usprawnić takie zadanie jako narzędzia wspomagające użyto tzw. algorytmów genetycznych.

Algorytmy genetyczne zostały opracowane przez J. Hollanda w latach 70. XX wieku [2]. Podstawą do zastosowania tego typu algorytmów stało się poznanie mechanizmów ewolucji organizmów, krzyżowania genów oraz mutacji i pomysł użycia ich w programach komputerowych do rozwiązywania problemów, dla których nie ma określonego lub nie jest znany sposób rozwiązania, ale dany jest sposób oceny jakości tego rozwiązania za pomocą pewnej funkcji, zwanej funkcją przystosowania. Algorytmy genetyczne są jedną z losowych metod optymalizacji [3], w której analizuje się punkty z przestrzeni dopuszczalnych rozwiązań w poszukiwaniu ekstremum (maksimum albo minimum) zadanej funkcji przystosowania, a dobór punktów do analizy w kolejnym kroku jest wynikiem zastosowania operacji krzyżowania i mutacji na punktach już przeanalizowanych. Losowa metoda optymalizacji funkcji polega na wylosowaniu określonej liczby punktów będących hipotetycznymi rozwiązaniami i obliczeniu wartości optymalizowanej funkcji tylko w tych punktach. W następnym kroku generuje się kolejny zbiór punktów, korzystając z tych punktów z poprzedniego kroku, dla których zadana funkcja przyjęła najwyższe wartości, przy poszukiwaniu maksimum albo najniższe wartości, przy poszukiwaniu minimum. Obliczanie wartości funkcji przystosowania i generowanie kolejnych punktów powtarza się do osiągnięcia satysfakcjonującego rezultatu albo przez określoną liczbę kroków. Operacja krzyżowania w algorytmie genetycznym polega na wybraniu pary punktów, które są przechowywane w pamięci komputera za pomocą ciągów zer i jedynek – bitów, następnie fragmenty tych ciągów wymienia się między punktami, tworząc w ten sposób nowe punkty [4,5]. Natomiast operacja mutacji polega na zamianie wartości losowo wybranego bitu na przeciwny.

Analizując działanie algorytmu genetycznego można zauważyć, że nie sprawdzamy wartości funkcji przystosowania dla każdego punktu z przestrzeni dopuszczalnych rozwiązań, ale dla jakiegoś jej podzbioru, dlatego rozważany problem nie jest problemem optymalizacji, ale tzw. „problemem zaspokojenia”. Otrzymany

punkt jest więc supremum (infimum), ale w istocie może nie być punktem maksimum (minimum) funkcji przystosowania w całej jej dziedzinie.

Duża różnorodność problemów rozwiązywanych za pomocą algorytmów genetycznych doprowadziła do powstania wielu ich wariantów. T. Gwiazda podaje wybór ponad 180 różnych operatorów krzyżowania [6] i ponad 140 mutacji [7]. Opis ciekawych zastosowań tych algorytmów można znaleźć w pracy Michalczewskiego [5].

Cel pracy

Prawidłowe przygotowanie kandydata na pilota oraz utrzymanie wysokiego poziomu predyspozycji pilota wymagają ciągłego treningu, zwłaszcza kluczowych cech, z których do rozważań tej pracy zostały wybrane pamięć i postrzeganie. Obecnie dostępne technologie pozwalają na przeprowadzenie tego skutecznego treningu w coraz przystępniejszy dla pilota sposób. W pracy zostały zaprezentowane możliwości wykorzystania algorytmów genetycznych w treningu postrzegania i pamięci pilotów dla zadania odtworzenia z pamięci położenia obiektu na zadanym terenie oraz odtworzenia kształtu zaobserwowanego obiektu. Zaproponowano koncepcję systemu informatycznego wspomagającego szkolenie pilotów, który korzysta z opisanych algorytmów. Dodatkowo zaprezentowany został autorski operator krzyżowania, którego sposób działania zależy od jakości populacji na której działa.

Metody

Zastosowanie algorytmów genetycznych w treningu postrzegania i pamięci pilotów zostało przedstawione za pomocą symulacji komputerowych. Pilot albo żołnierz naprowadzający samoloty na cel ma w pamięci obraz obserwowanego terenu, ale nie odtwarza go z pamięci, tylko otrzymuje zbiór losowo wygenerowanych modeli tego terenu. W symulacjach tworzono zbiory złożone z 64 elementów. Obserwator musi jedynie wskazać te modele, które najbardziej przypominają zapamiętany przez niego obraz, dokonuje w ten sposób oceny elementów. Symulacje były prowadzone bez interakcji z człowiekiem w związku z czym ocena dokonywana była przez obliczanie odległości punktów modelu od wzorca zapisanego w pamięci komputera. Zastosowanie tych metod w interakcji z człowiekiem będzie tematem dalszych badań autora. Najwyżej ocenione przez obserwatora elementy mają największe prawdopodobieństwo wylosowania ich do krzyżowania i w ten sposób do przekazania swoich właściwości do nowego zbioru modeli. Wybieranie elementów do krzyżowania w przeprowadzonej symulacji polegało na losowaniu 32 par modeli ze zwracaniem, tak więc element najwyżej oceniony statystycznie jest wybierany najczęściej, a dzięki zwracaniu może wielokrotnie wchodzić w parę do krzyżowania z innymi elementami w jednym kroku algorytmu. Umożliwia to utworzenie kolejnego zbioru 64 elementów zawierającego cechy modeli najwyżej ocenionych przez obserwatora. Istotą algorytmu genetycznego jest potraktowanie binarnego zapisu liczby tak, jakby łańcuch ten był chromosomem, a każdy bit pojedynczym genem, natomiast operacja krzyżowania dwóch

punktów polega na wymianie między tymi punktami fragmentów ciągów bitów, które są zapisem tych punktów w pamięci komputera. Jako obserwowany teren w symulacji został przyjęty kwadrat o boku długości 1023 jednostek. Przestrzenią dopuszczalnych rozwiązań jest więc obszar $[0,1023]_x \times [0,1023]$, dowolny punkt należący do tego obszaru ma dwie współrzędne (x,y) . Z ograniczeń obszaru dopuszczalnych decyzji wynika, że do reprezentacji współrzędnych punktu a potrzeba dwóch łańcuchów bitowych po 10 bitów każdy, gdyż na 10 bitach można uzyskać $2^{10}=1024$ stanów, a więc można w ten sposób zakodować liczby z przedziału $[0,1023]$. Zostały przeprowadzone symulacje działania trzech podstawowych operatorów krzyżowania (jednopunktowe, dwupunktowe i losowe) oraz zaproponowanego w tej pracy autorskiego operatora. Krzyżowanie realizowane było zgodnie ze schematem 2×2 , czyli z dwóch punktów generowano nowe dwa punkty, bity wymieniane były między punktami z zachowaniem porządku współrzędnych (osobno pierwsze i drugie współrzędne punktów).

- Krzyżowanie jednopunktowe polega na podzieleniu ciągu bitów w jednym miejscu na dwa podciągi i wymianie między krzyżowanymi punktami powstałych podciągów. W symulacji ciąg dziesięcioelementowy dzielony był w połowie na dwa pięcioelementowe podciągi.
- Krzyżowanie dwupunktowe polega na podzieleniu ciągu bitów w dwóch miejscach na trzy podciągi i wymianie środkowego podciągu. W symulacji ciągi miały kolejno trzy, pięć i dwa elementy, wymieniany między punktami był podciąg pięcioelementowy.
- Krzyżowanie losowe polega na losowym wybraniu elementów ciągu do wymiany, przy czym prawdopodobieństwo wybrania jest takie samo dla każdego elementu (rozkład jednostajny). W symulacji losowano pięć elementów do krzyżowania.
- Autorska metoda krzyżowania polega na uzależnieniu sposobu wybierania genów do zamiany od różnorodności elementów zbioru, z którego pochodzą punkty do krzyżowania. Pierwszym krokiem tej metody jest określenie istotności każdego bitu dla przystosowania osobnika. W analizowanym przypadku, gdy bity pochodzą z kodów służących do przedstawienia liczb, największy wpływ na wartość funkcji przystosowania mają najwyższe bity. Do oceny różnorodności populacji została obliczona wariancja z ocen punktów, po czym została ona wyrażona procentowo w odniesieniu do wartości przystosowania najlepszego osobnika. Na początku ewolucji populacji punktów, kiedy wariancja przystosowań jest duża, podczas krzyżowania wymieniane są najważniejsze bity, a w miarę jak punkty zbioru stają się coraz bardziej podobne do siebie, w krzyżowaniu wymieniane są bity mające coraz mniejszy wpływ na ocenę punktów. Algorytm ten nazwany jest w dalszej części pracy adaptacyjnym, ponieważ w metodzie tej sposób wyboru bitów do wymiany dopasowuje się do stanu populacji.


Krzyżowanie między punktami zachodzi z pewnym prawdopodobieństwem określonym przez wartość p_k (w symulacji $p_k = 0,9$). W klasycznym algorytmie genetycznym stosuje się $0,5 \leq p_k \leq 1$, jak opisano w [4]. Mutacja polega na losowaniu dla każdego bitu punktów otrzymanych po krzyżowaniu liczby $p \in [0;1]$ i jeżeli jest ona mniejsza od zadanego prawdopodobieństwa mutacji $p_m = 0,005$ (zwykle stosuje się prawdopodobieństwo mutacji spełniające warunek $0 \leq p_m \leq 0,1$ [4]),

zmieniano ten gen w chromosomie na przeciwny. Prawdopodobieństwa krzyżowania i mutacji zostały dobrane eksperymentalnie tak, aby zapewnić jak najlepsze działanie zaprezentowanych algorytmów. Po wygenerowaniu nowych punktów następowała pełna zamiana punktów w zbiorze. Jeden cykl oceny punktów, krzyżowania i mutacji oraz zamiany punktów nazywa się epoką.

Symulacja trwała 1000 pokoleń i powtórzono ją po 10 razy dla każdego operatora krzyżowania dla tej samej populacji początkowej. Otrzymane wyniki zostały uśrednione. W trakcie symulacji zapisywano wartość przystosowania najlepszego i najgorszego osobnika, średnie przystosowanie dla całej populacji oraz odchylenie standardowe dla funkcji przystosowania.

Wyniki

Najprostszym przykładem problemu wymagającego postrzegania i zapamiętywania, który został rozwiązany za pomocą algorytmów genetycznych, jest zadanie, w którym obserwator musi odtworzyć wzorec złożony tylko z jednego punktu a_0 leżącego na danym terenie. Nie umniejszając ogólności rozważań przyjęto, że poszukiwany punkt wzorec a_0 ma współrzędne $(511;511)$, czyli leży w centrum obserwanego terenu. Symulację rozpoczęto od losowego wygenerowania populacji startowej złożonej z 64 elementów. Fragment tej populacji przedstawia ryc. 1.




Ryc. 1. Fragment populacji początkowej (rozmieszczenie obiektów).

Fig.1. Fragment of initial population (location of the objects).

Jako funkcję przystosowania osobnika użyto odległości od punktu ze wzorca określonej w standardowej metryce euklidesowej. Pozostawiając funkcję przystosowania w tej formie, za najlepszy element uznano by punkt, którego odległość od a_0 jest jak najbliższa zero, czyli należałoby dążyć do minimalizacji funkcji przystosowania. Aby zmienić typ optymalizacji na jej maksymalizację odjęto tą odległość od liczby 1023. W ten sposób punkt znajdujący się blisko a_0 ma odległość bliską zero, natomiast wyliczoną wartość funkcji przystosowania bliską 1023.


Sprawdzono również możliwość zastosowania tych metod przy bardziej złożonych wzorcach. Przyjęto jako wzorec trójkąt o najdłuższym obwodzie, również mieszczący się w obszarze $[0;1023] \times [0;1023]$. Ponownie analizowana była populacja złożona z 64 osobników, będących losowo wygenerowanymi trójkątami z badanego obszaru. Fragment początkowej populacji przedstawia ryc. 2.



Ryc. 2. Fragment populacji początkowej (kształt obiektów).
 Fig. 2. Fragment of initial population (shape of the objects).

Ponieważ współrzędne wierzchołków w populacji początkowej były wybrane losowo, konieczne było uporządkowanie ich tak, aby krzyżowane ze sobą były we właściwej kolejności. W tym celu zastosowano następującą procedurę: dokonano translacji każdego punktu o wektor $(-511, -511)$. Następnie przeliczono współrzędne punktów z kartezjańskich na biegunowe $(x', y') \rightarrow (r, \varphi)$ i posortowano punkty według kąta φ . Ponadto, takie sortowanie zostało zastosowane do punktów w każdej epoce w celu zachowania kolejności krzyżowania punktów.

Rozwiązując pierwsze zagadnienie polegające na odtworzeniu położenia punktu, każdy z zastosowanych algorytmów okazał się efektywny i doprowadził w konsekwencji do odtworzenia zadanego wzorca. Fragment populacji po 1000 epokach przedstawia ryc. 3.




Ryc. 3. Fragment populacji końcowej (rozmieszczenie obiektów).
 Fig. 3. Fragment of final population (location of the objects).



Ryc. 4. Wykres przedstawiający średnie dopasowanie osobników (rozmieszczenie obiektów).
 Fig. 4. Diagram showing mean match of individuals (location of the objects).

Został on celowo wybrany tak, aby zawierał osobnika zmienionego przez mutację. Na poniższych wykresach zostały zaprezentowane przebiegi procesu ewolucji badanej populacji dla różnych operacji krzyżowania.

Na rycinie 4 pokazano jak zmieniało się średnie przystosowanie punktów populacji w trakcie trwania ewolucji, natomiast wykres na ryc. 5 pokazuje zmiany przystosowania najlepszego punktu w populacji. Na wykresach zostało przedstawione 200 pierwszych epok ewolucji, gdyż tyle epok wystarczyło na wygenerowanie dobrze przystosowanych punktów. Jak widać na ryc. 5, po 150 epoce ewolucji najlepsze punkty w każdej kolejnej populacji były wystarczająco dobrze dopasowane do wzorca. Przystosowanie najlepszych punktów przekraczało 1000 jednostek, co oznacza, że ich odległość od punktu wzorcowego nie przekraczała 23 jednostek, a więc błąd lekko przekraczał 2%, co stanowi zadowalającą dokładność.




Ryc. 5. Wykres przedstawiający dopasowanie najlepszego osobnika (rozmięszczenie obiektów).
 Fig. 5. Diagram showing match of the best individual (location of the objects).


Analizując zaproponowaną metodę krzyżowania adaptacyjnego ze względu na najlepiej przystosowanego osobnika widać, że pozwoliła ona na osiągnięcie najlepszych rezultatów na początku procesu ewolucji (podobnie jak krzyżowanie losowe), a w dalszym toku ewolucji dawała rezultaty porównywalne ze wszystkimi pozostałymi metodami. Widać także ciekawą prawidłowość, że o ile krzyżowanie losowe i adaptacyjne w początkowych 50 epokach pozwalają na otrzymanie dobrze dopasowanego najlepszego elementu, to średnie przystosowanie elementów populacji jest przy zastosowaniu tych metod najniższe. Na ryc. 5 można zauważyć, że przystosowanie najlepszego elementu w populacji może również w niektórych przedziałach maleć, co jest konsekwencją pełnej wymiany populacji po krzyżowaniu i mutacji. Opracowywana jest nowa wersja algorytmów z częściową wymianą punktów zbioru, co powinno rozwiązać ten problem. Ponadto, fakt przyznania najlepiej przystosowanemu elementowi największego prawdopodobieństwa wzięcia udziału w krzyżowaniu nie daje pewności, że element ten zostanie wylosowany oraz nie kontrolujemy przystosowania drugiego punktu, z którym będzie wymieniać bity. Może się więc okazać, że bardzo dobre punkty zostaną skrzyżowane z punktami słabymi, co doprowadzi do powstania punktu o mniejszym przystosowaniu.

Również drugie zadanie zostało z sukcesem rozwiązane z wykorzystaniem każdego z opisanych algorytmów genetycznych. Za każdym razem została wygenerowana populacja złożona niemal w całości z trójkątów o wierzchołkach w narożnikach badanego obszaru, a taki właśnie trójkąt posiada największy obwód.


Na rycinie 6 przedstawiono fragment populacji końcowej uzyskanej po 1000 epok ewolucji, ponownie został wybrany fragment zawierający elementy znacząco zmienione przez operator mutacji.



Ryc. 6. Fragment populacji końcowej (kształt obiektów).
Fig. 6. Fragment of final population (shape of the objects).



Ryc. 7. Wykres przedstawiający średnie dopasowanie osobników (kształt obiektów).
Fig. 7. Diagram showing mean match of individuals (shape of the objects).



Ryc. 8. Wykres przedstawiający dopasowanie najlepszego osobnika (kształt obiektów).
Fig. 8. Diagram showing match of the best individual (shape of the objects).

Przedstawione na ryc. 7 i 8 wykresy obrazują zmiany średniego przystosowania populacji i przystosowania najlepszego elementu w 200 początkowych epokach ewolucji. Jak widać na ryc. 8, przystosowanie najlepszego osobnika dla przeanalizowanych metod wynosiło w przybliżeniu 3350 jednostek, z wyjątkiem krzyżowania jednopunktowego, które przy zadanych parametrach pozwalało na uzyskanie osobnika o przystosowaniu od 3250 do nawet 3400 jednostek. Długość

obwodu trójkąta o wierzchołkach w narożnikach badanego obszaru wynosi w zaokrągleniu do liczby całkowitej 3493. Zatem błąd krzyżowania adaptacyjnego oraz krzyżowania dwupunktowego i losowego wynosił tylko 4%, natomiast błąd dla krzyżowania jednopunktowego na koniec procesu ewolucji wyniósł prawie 7%, chociaż za pomocą tej metody można było uzyskać osobniki o błędzie poniżej 2%, to ze względu na pełną wymianę populacji ten najlepszy osobnik został utracony.

Omówienie

Zaprezentowane powyżej sposoby zastosowania algorytmów genetycznych mogą posłużyć jako baza do stworzenia systemu informatycznego służącego do treningu pilotów statków latających. System taki powinien zawierać moduły odpowiedzialne za prezentację wizualną obserwowanego terenu, odtworzenie zaobserwowanych obiektów klasycznymi metodami, odtworzenie ich z wykorzystaniem algorytmów genetycznych oraz moduł oceniający poprawność wykonania zadania przez pilota. Pierwszy komponent wizualizacyjny powinien umożliwiać wyświetlenie zarówno statycznego obrazu terenu na wzór zdjęcia lotniczego albo satelitarnego, jak i dynamicznej animacji przelotu nad danym terenem. Powinna także istnieć możliwość prezentacji wzorców o różnym stopniu złożoności np. skomplikowana linia umocnień czy nietypowa zabudowa oraz możliwość utrudnienia zadania przez umieszczanie na wyświetlanym modelu dodatkowych neutralnych obiektów. Te dodatkowe obiekty mogą wyrobić u trenowanego umiejętność selekcjonowania otrzymywanych informacji pod kątem ich istotności dla realizowanego zadania. Moduł wspomagający odtworzenie modelu klasycznymi metodami służyłby pilotowi do przedstawienia zapamiętanych elementów terenu z wykorzystaniem tabletu albo przez rozmieszczenie na mapie terenu graficznych symboli obiektów. Moduł wykorzystujący algorytmy genetyczne musiałby wygenerować zbiór losowych rozlokowań obiektów na zadanym terenie, a następnie wyświetlić je trenowanemu pilotowi z prośbą o wskazanie tych rozmieszczeń, które są najbliższe zapamiętanemu przez niego wzorcowi. Następnie korzystając z operatorów genetycznych utworzony zostałby kolejny zbiór modeli terenu, spośród których pilot ponownie dokonałby selekcji najlepszych rozmieszczeń obiektów. Proces ten powinien być kontynuowany do wygenerowania modelu satysfakcjonującego trenowanego albo przez określony czas. Trening powinien być oceniany, za co będzie odpowiedzialny moduł oceniający poprawność wykonania zadania. Ocenie powinna podlegać zgodność zaproponowanego modelu z modelem wzorcowym oraz czas poświęcony na odtworzenie wzorca. System taki dawałby możliwość prowadzenia wielu wariantów treningu postrzegania i zapamiętywania.

Podsumowanie

Pokazano, że algorytmy genetyczne mogą być zastosowane podczas treningu pilotów. Ponadto zaproponowana przez autora metoda krzyżowania (podobnie jak podstawowe metody krzyżowania) pozwala na uzyskanie satysfakcjonującego rozwiązania. Symulacja rozwiązania postawionych problemów mogła być przeprowadzona dzięki podaniu jawnej postaci funkcji przystosowania punktów, czyli

funkcji celu, którą zmaksymalizowano. Wyniki uzyskane przy symulacji z zastosowaniem jawnych postaci funkcji przystosowania są motywacją do dalszych prac, zwłaszcza w kierunku odtwarzania bardziej złożonych wzorców oraz przetestowania zaproponowanych metod w interakcji z człowiekiem. Wskazano też na pewne cechy zaproponowanej metody w odniesieniu do trzech podstawowych operatorów genetycznych, co może być punktem wyjścia do dalszych badań nad nowymi operatorami, które będą wolne od dostrzeżonych problemów lub dadzą lepszą zbieżność zaprezentowanych metod.

Podziękowanie. Pragnę podziękować prof. A. Janickiemu i prof. M. Wojtkowiakowi za pomoc i cenne wskazówki przy pisaniu niniejszej pracy.

Piśmiennictwo

1. Wojtkowiak M., Jasiński T.: Niezawodność człowieka a wypadki lotnicze. *Przegl. Wojsk Lotn. Obrony Powietrz.* 1997, 4, 28-35.
2. Holland J.: *Adaptation in natural and artificial systems*. The University of Michigan Press, Ann Arbor 1975.
3. Goldberg D.: *Algorytmy genetyczne i ich zastosowania*. WNT, Warszawa 1998.
4. Rutkowski L.: *Metody i techniki sztucznej inteligencji*. PWN, Warszawa 2006.
5. Michalewicz Z.: *Algorytmy genetyczne + struktury danych = programy ewolucyjne*. PWN, Warszawa 1999.
6. Gwiazda T.: *Algorytmy genetyczne – kompendium*. (t. I). PWN, Warszawa 2007.
7. Gwiazda T.: *Algorytmy genetyczne – kompendium*. (t. II). PWN, Warszawa 2007.

Nadesłano: 5.12.2010 r.

Zaakceptowano do publikacji: 21.03.2011 r.

