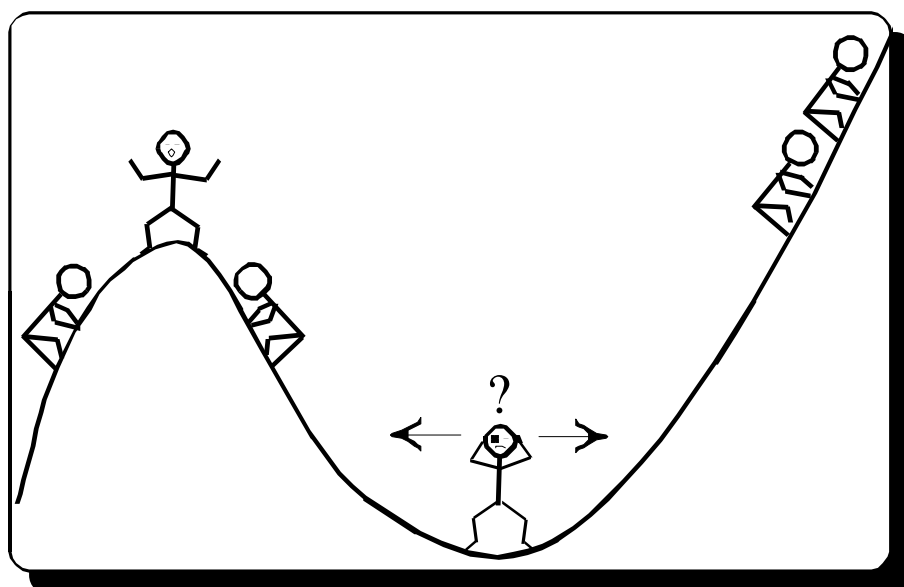


# OBLICZENIA EWOLUCYJNE W SZTUCZNEJ INTELIGENCJI



Halina Kwaśnicka

Oficyna Wydawnicza  
Politechniki Wrocławskiej

# SPIS RZECZY

Wstęp.....	5
1. Algorytmy ewolucyjne.....	11
1.1. Krótko o ewolucji.....	11
1.2. Algorytmy genetyczne.....	13
1.3. Inne techniki ewolucyjne.....	16
1.4. Równoległe przetwarzanie algorytmów genetycznych.....	19
2. Przykłady systemów z wbudowanymi EA.....	22
2.1. GA w systemach informacyjnych.....	22
2.2. Łączenie algorytmów genetycznych z logiką rozmytą.....	24
2.2.1. Systemy z logiką rozmytą – wprowadzenie.....	25
2.2.2. Połączenie GA i FLS.....	26
2.2.3. Projektowanie rozmytego systemu sterowania – przykład.....	27
2.3. Zastosowanie GAs do sieci neuronowych.....	31
2.3.1. Sieci neuronowe.....	31
2.3.2. Łączenie GAs i NNs.....	33
3. <i>K</i> -model – rozszerzony model ewolucyjny.....	41
3.1. Biologiczne inspiracje <i>K</i> -modelu.....	41
3.2. Rola plejotropowości i poligeniczności.....	44
3.2.1. Model Wersja_1: klasyczny algorytm genetyczny.....	45
3.2.2. Model Wersja_2: GA z minimalną plejotropowością i poligenicznością.....	46
3.2.3. Ewolucja bez poziomu genotypowego (Wersja_3).....	46
3.2.4. Badania symulacyjne.....	47
3.3. <i>K</i> -model.....	51
3.3.1. Formalny opis modelu.....	52
3.3.2. Werbalny opis modelu.....	55
3.3.3. Opis programu komputerowego <i>K</i> -model.....	57
4. Własności <i>K</i> -modelu – badania symulacyjne.....	61
4.1. Funkcje testowe.....	62
4.2. Rekombinacje i mutacje w ewolucji.....	70
4.2.1. Rola rekombinacji w <i>K</i> -modelu.....	71
4.2.2. Mutacje jako czynnik ewolucji.....	78
4.3. Makromutacje w poszukiwaniu optymalnego rozwiązania.....	90
4.3.1. Geny nadmiarowe.....	90
4.3.2. Rekrudescencja – radykalne zmiany u części populacji.....	92
4.3.3. Kryzys – reorganizacja wszystkich osobników.....	93
4.3.4. Łączny efekt nadmiarowości, rekrudescencji i kryzysu.....	94
4.4. Liczebność populacji i ewolucja w <i>K</i> -modelu.....	96
4.5. Inne parametry modelu.....	103
4.6. Podział populacji na prawie izolowane demy.....	112
4.6.1. Symulacja z <i>H</i> -modelem.....	112
4.6.2. Symulacja z <i>K</i> -modelem.....	113
4.6.3. Symulacja ze zmodyfikowanym <i>K</i> -modelem.....	115
5. Ewolucja z wielowymiarowymi i wielomodalnymi funkcjami.....	119
5.1. Plejotropowość i poligeniczność w ukierunkowywaniu ewolucji.....	119
5.2. Wzrost wymiaru funkcji a ewolucja.....	128
5.3. Ewolucja z funkcjami testowymi de Jonga.....	134
5.4. Szukanie optimów pozostałych funkcji testowych.....	140
6. Przykład aplikacji <i>K</i> -modelu – modelowanie ewolucyjne w ekonomii.....	144
6.1. Ewolucyjny model przemysłu (EMP).....	144
6.1.1. Reprezentacja firm w EMP.....	147

6.1.2. Decyzje firm.....	148
6.1.3. Zróźnicowanie produktów i konkurencja.....	150
6.2. Konkurencyjna gra ekonomiczna oparta na EMP .....	152
7. Uwagi końcowe.....	156
Literatura .....	164
Załącznik 1. Słownik ważniejszych terminów .....	172
Skorowidz.....	175

*Wiedza nigdy nie rozstrzygnie jednego problemu bez stworzenia dziesięciu innych.*

Bernard SHAW (1856–1950)

## WSTĘP

**Myślące maszyny** – marzenie czy rzeczywistość? Czy można jednoznacznie odpowiedzieć na tak postawione pytanie? Zarówno odpowiedź twierdząca, jak i przecząca ma swoich zwolenników jak i przeciwników<sup>1</sup>. Zaproponowany w 1950 roku przez A. Turinga (1912–1954) test, zwany *testem Turinga* nie rozwiązał istniejących kontrowersji. W zamierzeniu test ten miał udzielać odpowiedzi, czy dany program komputerowy jest inteligentny. Test polega na tym, że przy jednym komputerze jest osoba, która prowadzi dyskusję (na ogólny temat) z innym dyskutantem, tyle, że może nim być program komputerowy lub człowiek, zajmujący miejsce przy klawiaturze innego komputera. Jeśli osoba nie rozpozna, czy dialog prowadzi z programem czy z człowiekiem, program spełnia test, w przeciwnym razie – nie spełnia. Jest wiele programów komputerowych spełniających taki test, ale przy ograniczeniu dyskusji do wąskiej tematyki. Sformułowanie tego testu nie zakończyło dyskusji na temat „czy maszyna może myśleć?” W latach siedemdziesiątych H.L. Dreyfus opublikował krytyczną książkę, w której dowodzi nieadekwatności i niepowodzeń symulacji w stosunku do rzeczywistego intelektu<sup>2</sup>. Książka ta wywołała ożywioną polemikę wśród osób zajmujących się sztuczną inteligencją. Echo tych dyskusji widoczne jest również w literaturze polskojęzycznej (Tadeusiewicz 1995, Kloch 1996, Traczyk 1995).

Niezależnie od tych filozoficznych dyskusji, w ostatnich latach obserwuje się wzrost zastosowań takich systemów informatycznych, w których zawarta jest inteligencja wzorowana na inteligencji ludzkiej. W odróżnieniu od tej ostatniej, nazwano tę dziedzinę **sztuczną inteligencją (AI – Artificial Intelligence)** – obejmuje ona rozwiązywanie problemów sposobami wzorowanymi na naturalnych działaniach i procesach poznawczych człowieka, za pomocą symulujących je programów komputerowych (Schalkoff 1990). W ramach tej nowej dziedziny wiedzy możemy wyróżnić różne techniki rozwiązywania problemów:

**Systemy ekspertowe (ESs – Expert Systems)**, tzn. takie komputerowe programy konsultacyjne, które wspomagają decyzje i zastępują eksperta w danej, zazwyczaj wąskiej dziedzinie. System ekspertowy składa się z bazy wiedzy, modułu wnioskującego – do przetwarzania posiadanej wiedzy, modułu wyjaśniającego użytkownikowi sposób dochodzenia do konkluzji oraz modułu pozyskiwania wiedzy. Dobry interfejs oraz moduł wyjaśniający sposób dochodzenia do konkluzji są bardzo ważne, zwłaszcza z punktu widzenia testowania systemu, są też niezbędne do nabrania przez użytkownika (zwykle nie jest nim informatyk) zaufania do systemu. Ekspertyzy systemu powinny być co najmniej tak dobre, jak te, które dałby ekspert. Aby to było możliwe, musi być spełnionych kilka warunków, ale najważniejszym (i najtrudniejszym do spełnienia) jest jakość dostarczonej

---

<sup>1</sup> Patrz: J.R. Searle, *Umysł, mózg i nauka*, Warszawa, Wydawnictwo Naukowe PWN, 1995, czy *Trzecia kultura. Nauka u progu trzeciego tysiąclecia*, pod red. J. Brockmana, Warszawa, Wydawnictwo CIS, 1996.

<sup>2</sup> Dreyfus H.L., *What Computers Can't Do: The Limits of Artificial Intelligence*, wyd. II, New York, Harper and Row. Tematyka możliwości sztucznej inteligencji jest ciekawie przedstawiona w *Artificial Intelligence and Creativity*, T. Dartnall ed., ser. *Studies in Cognitive Systems*, Kluwer A. Publ., 1994.

systemowi wiedzy. System ekspertowy może być na tyle dobry, na ile dostarczymy mu dobrą wiedzę. „Dobra” to znaczy prawdziwa, wystarczająca dla danej klasy problemów, dobrze sformalizowana, niesprzeczna itp. Pożądana jest również umiejętność przetwarzania wiedzy niepełnej i niepewnej. Wprowadza się wnioskowanie z logiką rozmytą czy z czynnikiem pewności, określającym stopień zaufania do generowanej wiedzy. Pozyskanie wiedzy dla systemów ekspertowych jest „wąskim gardłem” ich rozwoju. Pojawiły się narzędzia do tworzenia systemów ekspertowych, ułatwiające pozyskiwanie wiedzy, kodowanie jej i przetwarzanie<sup>3</sup>. W krajach wysoko rozwiniętych systemy ekspertowe stosuje się w wielu dziedzinach, między innymi w medycynie, ubezpieczeniach, marketingu itp. (Mulawka 1996, Yager i Filev 1995, Traczyk 1995, Medsker 1995, Heider i in. 1994, Herrera i Lozano 1995, Kwaśnicka i Markowska-Kaczmar 1994, 1994a, Kwaśnicka 1996).

**Sieci neuronowe (NNs – Neural Networks).** Próba zbudowania sztucznego mózgu to początek rozwoju tej gałęzi sztucznej inteligencji. NNs są wzorowane na sieci neuronów biologicznych w mózgu. Głównym podobieństwem biologicznej i sztucznej sieci neuronowej jest jej zdolność uczenia się odwzorowań zbiorów wejść na zbiór wyjść na podstawie uczących przykładów oraz jej zdolność uogólniania. W ostatnich latach rozwinięto nowe algorytmy uczenia sieci, głębiej poznano i sformułowano matematyczne podstawy sieci neuronowych, modele sieci zostały nauczone i zastosowane do rozwiązywania wielu problemów w różnych dziedzinach, np. do rozpoznawania podpisów w bankach, klasyfikacji, przewidywania kursów na giełdach itp. (Yager i Zadech 1994, Tadeusiewicz 1992, 1993, Korbicz i Obuchowicz 1994, Ossowski 1994, Medsker 1995, Kacprzak i Ślot 1995).

**Algorytmy genetyczne (GAs – Genetic Algorithms)** są wzorowane na ewolucji biologicznej, która jest bardzo skutecznym, naturalnym systemem adaptacyjnym (Holland 1975, Michalewicz 1996, Goldberg 1989, Gwiazda 1995, Kwaśnicka 1994, Kwaśnicka 1998). Główne różnice między GAs a konwencjonalnymi metodami optymalizacji to:

- GAs pracują z zakodowanymi parametrami w postaci genów stanowiących chromosom, najczęściej (choć niekoniecznie) parametry są kodowane w alfabecie binarnym, jako ciąg zer i jedynek, chromosom koduje punkt w przestrzeni poszukiwań (rozwiązań),
- poszukują rozwiązania, pracując jednocześnie z populacją punktów, a nie z pojedynczym punktem w przestrzeni parametrów,
- nie posługują się pochodnymi funkcji ani inną wiedzą o funkcji celu,
- stosują probabilistyczne reguły przeszukiwania przestrzeni parametrów optymalizowanej funkcji, wykorzystując obszary o wysokim stopniu przystosowania (dobre rozwiązania).

**Automatyczne uczenie się (ML – Machine Learning).** Dziedzina ta zajmuje się szukaniem odpowiedzi na pytanie, w jaki sposób konstruować programy komputerowe, które potrafią automatycznie polepszać swoje działanie w miarę zdobywania „doświadczenia”. Stosuje się tu pojęcia i wiedzę z różnych obszarów badań, np. statystyki, sztucznej inteligencji, filozofii, teorii informacji, biologii i in. Ludzkość od początków istnienia komputerów marzyła, by mogły się one uczyć, ale jak je zaprogramować, by to potrafiły? Satysfakcjonującej odpowiedzi na to pytanie nadal nie znamy, choć rozwijane są nowe algorytmy. Dobre sformułowanie problemu, wybór zbioru uczącego (doświadczeń) mają bardzo duże znaczenie dla zadania automatycznego uczenia się (Mitchell 1997, Hutchinson 1994, Kwaśnicka 1998b).

Wymienione techniki znajdują zastosowanie w różnych dziedzinach. Wymienienie ich wszystkich wydaje się niemożliwe. W literaturze przedmiotu wyróżnia się najczęściej następujące zadania (Schalkoff 1990):

- Robotyka – planowanie drogi ruchu robotów (*path and motion planning*), rozpoznawanie obrazów – dokładniej, rozpoznawanie wzorców (*pattern recognition* i *computer vision*), sterowanie, tworzenie harmonogramów i diagnostyka produkcji (*manufacturing control, diagnostic systems, scheduling*).

---

<sup>3</sup> Np. XpertRule, <http://www.attar.com>, EMYCIN (system ekspertowy MYCIN bez bazy wiedzy) itp.

- Systemy ekspertowe – diagnostyka medyczna, wojskowość, sterowanie podstacjami energetycznymi, geologia, projektowanie, konfiguracja komputerów.
- Gry – logiczne (najbardziej spektakularny sukces to Deep Blue, zwycięzca nad szachowym mistrzem świata A. Kasparowem, dobre osiągnięcia programu TD-GAMMON grającego w trik-traka (Mitchell 1997), menedżerskie i wojskowe.
- Rozumienie języka naturalnego (rozpoznawanie mowy, tłumaczenie tekstów).
- Automatyczne dowodzenie twierdzeń.
- Komputerowe wspomaganie nauczania(uczenia).
- Automatyczne podejmowanie decyzji.
- Automatyczne generowanie programów komputerowych.

Zaprezentowane wprowadzenie w problematykę sztucznej inteligencji, mimo iż bardzo krótkie, pokazuje jak szeroka i interdyscyplinarna jest ta dziedzina. Zgodnie z cytowaną już jej definicją, sztuczna inteligencja naśladuje zachowania, jakie są obserwowane u człowieka. Wydaje się jednak, że coraz bardziej upowszechnia się rozumienie sztucznej inteligencji w sposób sformułowany przez D.B. Fogla w przedmowie do jego książki zatytułowanej *Evolutionary Computation Toward a New Philosophy of Machine Intelligence* (Fogel 1995): sztuczna inteligencja to zdolność systemu do dostosowania swojego działania tak, aby osiągnąć założony cel w środowisku, w którym się znajduje. Inteligentne stworzenia powstały w wyniku ewolucji biologicznej. Obserwując i modelując ewolucję, możemy uzyskać wiele inteligentnych zachowań. Wszelkie metody symulacji ewolucji za pomocą komputera noszą nazwę **obliczeń ewolucyjnych (EC – Evolutionary Computation)**. Wszelkie algorytmy stosowane w takich symulacjach to **algorytmy ewolucyjne (EAs – Evolutionary Algorithms)**.

W ostatnich latach paradygmat obliczeń ewolucyjnych stał się bardzo popularny. Obserwowane jest zwiększenie liczby prac na ten temat, czasopism, konferencji, książek, powstają listy dyskusyjne, strony internetowe. Podobnie zwiększa się liczba różnych dziedzin, w których algorytmy ewolucyjne znajdują zastosowanie: od naturalnych dla nich zadań modelowania dynamiki populacji, przez zastosowania czysto techniczne (np. projektowanie samolotów, gazociągu), zadania szeregowania, gry logiczne, nauki chemiczne i fizyczne, po nauki ekonomiczne – popularny ostatnio paradygmat ekonomii ewolucyjnej.

Niniejsza praca dotyczy **obliczeń ewolucyjnych**, można powiedzieć – modnego ostatnio tematu. Intencją autorki jest, by przy okazji własnych prac pokazać, jak można wykorzystać podejście ewolucyjne do rozwiązywania różnych klas zadań – automatyczne generowanie reguł, projektowanie sieci neuronowych czy systemów z logiką rozmytą, modelowanie w ekonomii. Powinno to pomóc czytelnikowi w zdefiniowaniu własnego problemu w terminach algorytmów ewolucyjnych. Ten pierwszy etap ich stosowania jest zwykle bardzo trudny. Czasami nasze próby z **EA** kończą się fiaskiem, z braku „wyczucia” działania tych algorytmów, ich właściwości i wrażliwości na parametry, stosowane funkcje przystosowania itp. Autorka w tej pracy pominęła analizę matematyczną właściwości algorytmów ewolucyjnych; próby takich analiz są dostępne, głównie w czasopismach i materiałach konferencyjnych, można je znaleźć również w internecie<sup>4</sup>.

Początek pracy – rozdział pierwszy – to wprowadzenie do tematyki algorytmów ewolucyjnych. Odrobina informacji o teorii ewolucji, która była inspiracją rozwoju algorytmów genetycznych, ułatwi czytelnikowi zrozumienie ich idei (Gould 1991, Fogel 1992, Hoffman 1983, Dawkins 1995, 1996, Szarski 1986, Mayr 1982, 1991). Następnie omówiono działanie algorytmów genetycznych oraz krótko przedstawiono pozostałe, równie popularne klasy algorytmów ewolucyjnych, tzn. strategie ewolucyjne, programowanie ewolucyjne i programowanie genetyczne. W tej części znajduje się również krótki przegląd możliwych sposobów przetwarzania **EA** w środowisku rozproszonym i równoległym (Holland 1975, Goldberg 1989, Michalewicz 1996, Kwaśnicka 1998, Cantú-Paz 1977a, Seredyński 1998).

---

<sup>4</sup> Biblioteka prowadzonego przez D.E. Goldberga laboratorium *Illinois Genetic Algorithms Laboratory*, University of Illinois at Urbana-Champaign jest ogólnie dostępna w internecie pod adresem <http://GAL4.GE.UIUC.EDU/illigal.home.html>. Są też inne strony zawierające zarówno artykuły, jak i kody programów (patrz odsyłacze na stronie internetowej autorki: <http://www.ci.pwr.wroc.pl/~kwasnick>).

W rozdziale drugim pokazano wybrane przykłady zastosowań algorytmów ewolucyjnych w hybrydowych systemach inteligentnych. Skupiono się głównie na pracach wykonanych przy współudziale autorki<sup>5</sup>. Włączenie **EA** w systemy wyszukiwania informacji może przyspieszyć działanie takich systemów. Wyniki naszej pracy zdają się potwierdzać opłacalność takiego podejścia. Bardzo użyteczne są algorytmy genetyczne zastosowane do projektowania systemów z logiką rozmytą. Ten sposób łączenia technik **AE** i **FL** wydaje się najciekawszy, choć nie jest jedyny. Poświęcono temu jeden z podrozdziałów. Pokazano, w jaki sposób definiować problem i jakie uzyskano przykładowe wyniki. Ostatnia część rozdziału to omówienie zastosowania **EA** do uczenia i projektowania topologii sieci neuronowych (Medsker 1995, Kwaśnicka i Nowostawski 1997, Heider i in. 1994, Heider i Drabe 1997, Herrera i Lozano 1996, Rutkowska i in. 1997, Montana i Devis 1989, Schafer i in. 1992, Porto i in. 1995, Kwaśnicka i in. 1998, Kwaśnicka i Szerszon 1997, Kwaśnicka 1997).

**Kolejne trzy rozdziały pracy to oryginalny dorobek autorki.** Na podstawie analogii biologicznych zaproponowano algorytm ewolucyjny, nazwany **K-modelem**. W *K*-modelu uwzględniono dodatkowe mechanizmy genetyczne, między innymi ułatwiające modelowanie znanych z biologii makromutacji. Uwzględnienie w reprezentacji osobnika genów nadmiarowych oraz efektów plejotropowego i poligenicznego istotnie wyróżnia zaproponowany model od innych algorytmów ewolucyjnych. Macierz plejotropowości, określająca zależności wartości fenów osobników od jego genów, pozwala zwiększyć efektywność algorytmu. Pierwotnym celem budowy tego modelu była chęć modelowania dynamiki populacji, analiza tempa i charakteru ewolucji. W trakcie doświadczeń z różnymi algorytmami ewolucyjnymi nabrano przekonania, że *K*-model ma duże możliwości optymalizacyjne i może być użyteczny do innych zadań.

Omówienie zaproponowanego *K*-modelu zawarte w rozdziale trzecim poprzedzono krótkim przedstawieniem jego przesłanek biologicznych. Wykonane badania symulacyjne, mające na celu sprawdzenie, czy model z plejotropowością jest efektywny, wskazują, że warto wykorzystać ten *pomysł* natury. Przedstawiono sposób reprezentacji osobnika i stosowane operatory, w tym zaproponowane operatory nazwane tranzycją, transpozycją, rekrudescencją i kryzysem.

Rozdział czwarty to seria eksperymentów z *K*-modelem, mająca na celu pokazanie właściwości zaproponowanego algorytmu. Ciekawe wyniki odnoszą się do charakteru i tempa ewolucji populacji liczących niewiele (dziesięciu) osobników w porównaniu do ewolucji dużo większych populacji (100 i 1000 osobników), dla funkcji o różnym wymiarze. Okazuje się, że jeśli nasze zadanie polega na szybkim znalezieniu akceptowalnego rozwiązania, a nie na wysokim średnim przystosowaniu całej populacji, to małe populacje są znacznie efektywniejsze, zwłaszcza dla funkcji o niewielkiej liczbie wymiarów. Interesujące wyniki uzyskano dzięki analizie wpływu podziału ewoluującej populacji na podpopulacje (demy) na tempo i charakter ewolucji. Wydaje się możliwe znalezienie optymalnego podziału: jeden dem większy i kilka małych.

W rozdziale piątym przedstawiono dalsze badania symulacyjne tego samego modelu. Skupiono się tu nie tyle na badaniach samego modelu, co na sprawdzaniu, czy model radzi sobie dobrze w przypadku funkcji wielomodalnych i wielowymiarowych, w tym dla funkcji testowych de Jonga. Testowano przy okazji, jak na efektywność algorytmu wpływa dobór macierzy plejotropowości.

W rozdziale szóstym pokazano możliwe i przetestowane zastosowanie zaproponowanego *K*-modelu. Z zastosowaniem ewolucyjnego modelu rozwoju firm (Kwaśnicki 1996) podjęto próbę wykonania gry menedżerskiej. Wyniki są bardzo obiecujące, z całą pewnością kierunek ten wart jest kontynuacji (Nowicki 1992, Kot 1997, Kwaśnicka 1998).

W rozdziale końcowym pracy podsumowano uzyskane wyniki oraz omówiono aktualne i planowane prace w tej dziedzinie. Jeden z głównych kierunków zainteresowań to stworzenie w miarę uniwersalnego narzędzia optymalizującego. Ambicją autorki jest, by był to algorytm ewolucyjny, działający w środowisku rozproszonym, inteligentnie zarządzany. Dokładne wycucie wrażliwości algorytmów na parametry, oraz ich naturalnych predyspozycji (w zależności od parametrów, sposobu kodowania itp.) pozwoli sformułować moduł sterujący całością algorytmu. Pierwsza próba – dwa kooperujące algorytmy genetyczne, z których jeden jest ukierunkowany na przeszukiwanie

---

<sup>5</sup> Dokładniejsze omówienie zastosowań algorytmów ewolucyjnych, w tym w systemach hybrydowych, jest zawarte w przygotowywanej do druku pracy *Naśladowanie natury w sztucznej inteligencji*.

przestrzeni, a drugi na zastosowanie znalezionych dobrych obszarów – wskazuje, że warto jest realizować ten cel. Prace nad tym tematem są rozpoczęte. Drugi nurt zainteresowań to projektowanie sztucznych sieci neuronowych z wykorzystaniem algorytmów ewolucyjnych. W tej dziedzinie mamy spore doświadczenia i będziemy kontynuować prace. Obecnie podejmowane są próby włączenia pewnych elementów *K*-modelu do tego zadania. Opracowanie dydaktycznej gry menedżerskiej, z zastosowaniem paradygmatu ekonomii ewolucyjnej (i *K*-modelu jako podstawy), nadającej się do celów dydaktycznych i badawczych, to również jeden z planowanych kierunków pracy autorki.

Dotychczasowe prace wykazały zalety i użyteczność proponowanego w *K*-modelu podejścia. Jest to algorytm ewolucyjny z zaimplementowanymi genami nadmiarowymi, plejotropowością i poligenicznością oraz mechanizmami rekrudescencji i kryzysu. Kontynuacja badań w wymienionych kierunkach pozwoli zweryfikować walory aplikacyjne modelu.