

Podejście konwencjonalne do sterowania - oparte o teorię sterowania

oparte jest na modelach matematycznych, zwykle w postaci równań różniczkowych lub różnicowych

dla tych modeli opracowane zostały metody i procedury projektowania, analizy i weryfikacji

- ◆ podejście takie jest efektywne dla niezbyt szerokiej klasy modeli (liniowe modele i niektóre rodzaje modeli nieliniowych)
- ◆ nawet jeżeli uzyskanie modelu jest możliwe, brak jest czasem czasu i środków na realizację procedury jego budowania

Sterowanie inteligentne

Termin pojawił się około trzydzieści lat temu dla określenia paradygmatu sterowania stawiającego sobie bardziej ambitne cele niż sterowanie konwencjonalne:


- * osiągać określone cele sterowania nawet przy braku szczegółowej wiedzy o obiekcie/systemie sterowanym
- * radzić sobie w nieprzewidzianymi zmianami obiektu/systemu i jego otoczenia
- * pozyskiwać i organizować wiedzę o otoczeniu obiektu oraz przewidywać zachowanie tego otoczenia

.....

Dzisiaj najczęściej termin „inteligentny” używany jest dla łącznego określenia technik wywodzących się z dziedziny „sztucznej inteligencji”, których zamiarem jest replikacja pewnych kluczowych komponentów inteligencji jak np. uczenia się, wnioskowania,

Do technik tych zalicza się:

- * sztuczne sieci neuronowe
- * systemy rozmyte
- * algorytmy genetyczne
- * systemy ekspertowe
- * algorytmy rojowe
- *
- * różne połączenia wymienionych narzędzi




Geneza:

Sieci neuronowe powstały dzięki obserwacjom i próbom naśladowania przetwarzania informacji w centralnym systemie nerwowym organizmów żywych

Sieci neuronowe są prostymi modelami naśladowującymi funkcje biologicznego centralnego systemu nerwowego w zakresie przetwarzania informacji

Parametry: wagi powiązań pomiędzy neuronami, progi pobudzeń neuronów



Struktura: neurony, warstwy, powiązania

W sieci neuronowej sposób przetwarzania informacji jest „zakodowany” strukturą sieci i jej parametrami nazywanymi wagami i progami


Jakie mają cechy:

Sieci neuronowe nie wymagają posiadania „wyrazistej” wiedzy dla ich stosowania

Sieci neuronowe posiadają zdolność uczenia się złożonych zależności funkcyjnych z ograniczonej ilości danych uczących i następnie uogólniania dla danych innych niż dane uczące

Jak mogą być wykorzystane:

Sieci neuronowe mogą służyć jako modele „black box” systemów wielowymiarowych, nieliniowych, statycznych i dynamicznych uzyskiwane drogą uczenia w oparciu o dane z obserwacji wejścia – wyjścia systemu



Geneza:

Algorytmy genetyczne zawdzięczają swoje istnienie obserwacjom i próbom naśladowania naturalnych procesów ewolucji i związanej z nią selekcji występującej w populacjach żywych osobników żyjących w określonym otoczeniu

Czym są obecnie, jakie mają cechy:

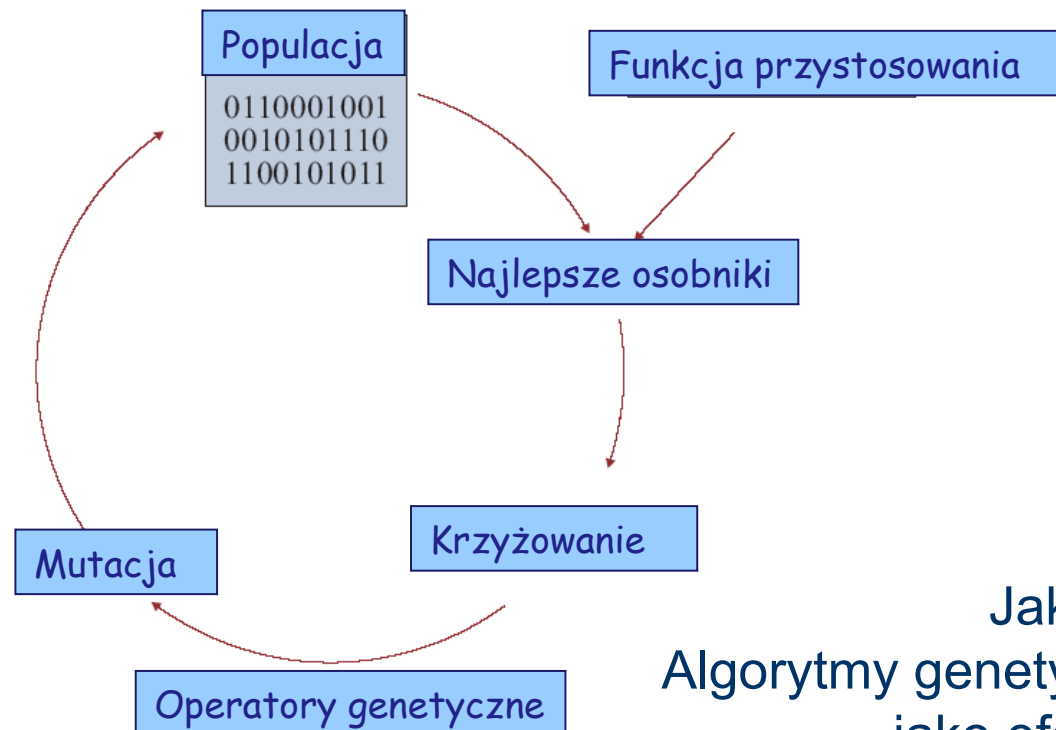
Algorytmy genetyczne są losową technologią optymalizacji naśladującą zasady ewolucji i przeżywania najlepiej dostosowanych osobników populacji

W algorytmie genetycznym kandydaci do rozwiązania rozważanego problemu (osobnicy populacji) są kodowani jako łańcuchy liczb binarnych lub rzeczywistych

W algorytmie genetycznym dostosowanie (dobroć osobnika populacji) poszczególnego rozwiązania jest oceniana za pomocą funkcji przystosowania, zadanej z otoczenia

W algorytmie genetycznym najlepiej dostosowane osobniki populacji są reprodukowane w wykorzystaniem operatorów genetycznych jak krzyżowanie, mutacja – uzyskiwana jest populacja kandydatów do rozwiązania (nowa populacja osobników) lepiej dostosowanych do wymagań określanych funkcją przystosowania niż populacja poprzednia

Czym są obecnie:




Jak mogą być wykorzystane:

Algorytmy genetyczne sprawdziły się
jako efektywne metody

poszukiwania dobrych rozwiązań w

przestrzeniach o dużych wymiarach i znalazły zastosowanie w wielu dziedzinach, np. optymalizacja struktury modeli i regulatorów, dobór wartości parametrów w modelach systemów nieliniowych



Geneza:


Systemy rozmyte rozwinęły się jako próba odwzorowania ludzkich sposobów komunikowania się i przekazywania informacji za pomocą mowy oraz ludzkich sposobów rozumowania

Czym są obecnie, jakie mają cechy:

Systemy rozmyte są modelami przetwarzającymi informację zapisaną za pomocą zbioru reguł rozmytych „jeżeli – to” i w oparciu o zasady wnioskowania rozmytego

Rozmytość jest sposobem reprezentowania niejednoznaczności (niepewności) w określeniach lingwistycznych (n.p. wysoka temperatura)


Rozmytość jest definiowana za pomocą zbiorów rozmytych, które są zbiorami o zachodzących na siebie granicach – jeden element może należeć do kilku zbiorów, ale stopień jego przynależności do tych zbiorów będzie zwykle różny



Jakie mają cechy:


Stopniowe przechodzenie od przynależności do nieprzynależności ułatwia uzyskanie „gładkiego” wyniku wnioskowania z rozmytymi regułami „jeżeli – to”, które stają się dzięki temu w istocie sposobem interpolacji odwzorowania typu wejście-wyjście

If x is *Medium* then y is *Large*



Jak mogą być wykorzystane:

Systemy rozmyte mogą służyć jako dogodne narzędzie reprezentacji wiedzy jakościowej dostarczanej przez eksperta dziedzinowego (zastosowanie - oparte na wiedzy sterowanie rozmyte) lub pozyskiwanej w sposób zautomatyzowany ze zbieranych danych (zastosowanie – indukowanie reguł, uczenie)



Celem sztucznej inteligencji, jako dziedziny badań i wiedzy, jest rozwijanie paradygmatów, metod i algorytmów, które wykorzystują komputery do realizacji zadań, rozwiązywanych przez człowieka lub inne żywe organizmy lub ich zbiorowości, i których realizacji przypisuje się konieczność występowania zdolności inteligentnych

Systemy sztucznej inteligencji muszą być zdolne wykonywać trzy rzeczy:

- przechowywać wiedzę
- wykorzystywać przechowywaną wiedzę do rozwiązywania problemów
- nabywać nową wiedzę drogą doświadczenia

System sztucznej inteligencji zawiera trzy kluczowe składniki:

reprezentację wiedzy

wnioskowanie w oparciu o wiedzę

uczenie się, zdobywanie wiedzy

Składnik	Sieci neuronowe	Algorytmy genetyczne	Systemy rozmyte
Reprezentacja	Architektura sieci i rozproszone wartości wag i progów	Populacja i cechy przeżywających osobników	Baza reguł
Wnioskowanie	Wykorzystanie wyników uczenia	Ocena przystosowania osobników i selekcja	Mechanizmy wnioskowania rozmytego
Uczenie się	Modyfikacja wag i progów	Mechanizmy mutacji i krzyżowania osobników	Wiedza ekspertów dziedzinowych

Czym jest sztuczna sieć neuronowa ?

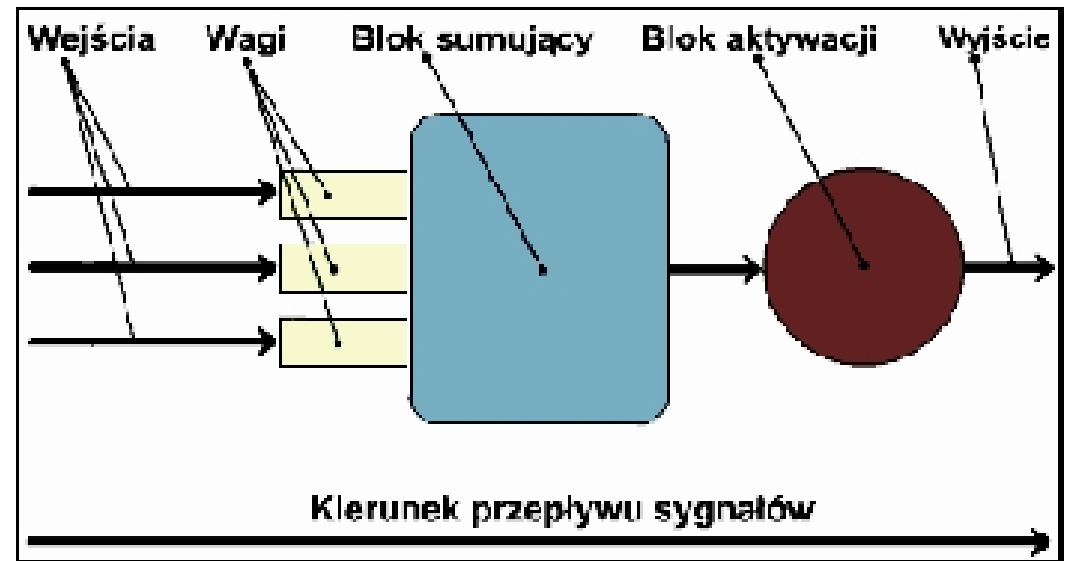

zbiór połączonych ze sobą układów scalonych zdolnych do przetwarzania danych i układów pamięci imitujących strukturę ludzkiego mózgu.

system symulujący działanie ludzkiego mózgu, który posiada zdolności rozpoznawania, kojarzenia i przewidywania, trudne do zrealizowania przy pomocy klasycznych algorytmów komputerowych.

uproszczony model biologicznego systemu nerwowego, dzięki któremu możemy próbować naśladować mózg, obserwować pewne jego zachowania i zasady działania, których nie jesteśmy w stanie wciąż zbadać w rzeczywistości.

Zastosowanie sztucznych sieci neuronowych

- w rozpoznawaniu dźwięków i obrazów (mowy i pisma);
- do prognozowania, klasyfikacji i rozpoznawania stanów obiektów ekonomicznych;
- do analizy, kojarzenia i optymalizacji w podsystemach doradczych w procesach zarządzania;
- przy sterowaniu robotami;
- do kompresji i kodowania danych.




Dendryt - „wejście” neuronu, biologiczne neurony mają ich tysiące.

Synapsa - „furtka” do neuronu (poprzedza dendryt). Może ona zmienić moc sygnału napływającego poprzez dendryt.

Jądro - „centrum obliczeniowe” neuronu.

Akson - „wyjście” neuronu. Za jego pośrednictwem neuron powiadamia świat zewnętrzny o swojej reakcji na dane wejściowe. Neuron ma tylko jeden akson.



Z czego składa się sztuczna sieć neuronowa ?


Sieci neuronowe zawdzięczają swoją nazwę m.in. faktowi, że neurony formują się w warstwy.

Neuron w warstwie zachowuje się dokładnie tak samo jak pojedynczy neuron.


W sieciach neuronowych wyróżniamy następujące warstwy:

- *wejściową*, która dostarcza danych wejściowych,
- *wyjściową*, zwracająca wynik działania sieci,
- pośrednie warstwy neuronów tzw. „*warstwy ukryte*” (zwane niejawnymi), które występują pomiędzy warstwą wejścia i wyjścia; przy wykorzystywaniu sieci do skomplikowanych obliczeń potrzebujemy czasami kilku takich warstw, aby zapewnić efektywniejsze działanie sieci.


Podział sztucznych sieci neuronowych



**Sieć wielowarstwowa
rekurencyjna**



Sieć jednowarstwowa



**Sieć
wielowarstwowa
jednokierunkowa**

Proces uczenia sztucznych sieci neuronowych

Metoda z nauczycielem

Nauczyciel podaje:

- wzorcowe obiekty na wejściu;
- oczekiwane wartości na wyjściu;

Sieć:

- uczy się wzorców „na pamięć” oraz nabywa zdolność uogólniania wiedzy (rozpoznawanie podobnych obiektów);
- zmienia wartości wag w celu dopasowania swojego działania do wzorców (nauczonych wyników).


Metoda samouczenia

- brak wzorcowych wag (sieć generuje je losowo);
- sieć odbiera sygnał wejściowy i na jego podstawie wyznacza swoje wyjście;
- sieć ocenia wartość na wyjściu każdego neuronu warstwy wyjściowej;
- wagi poszczególnych neuronów zmieniają się zgodnie z określonymi w danej metodzie zasadami.

Algorytmy genetyczne służą głównie do tego, żeby rozwiązywać zadania **optymalizacji**

Przykład: Problem Komiwojażera

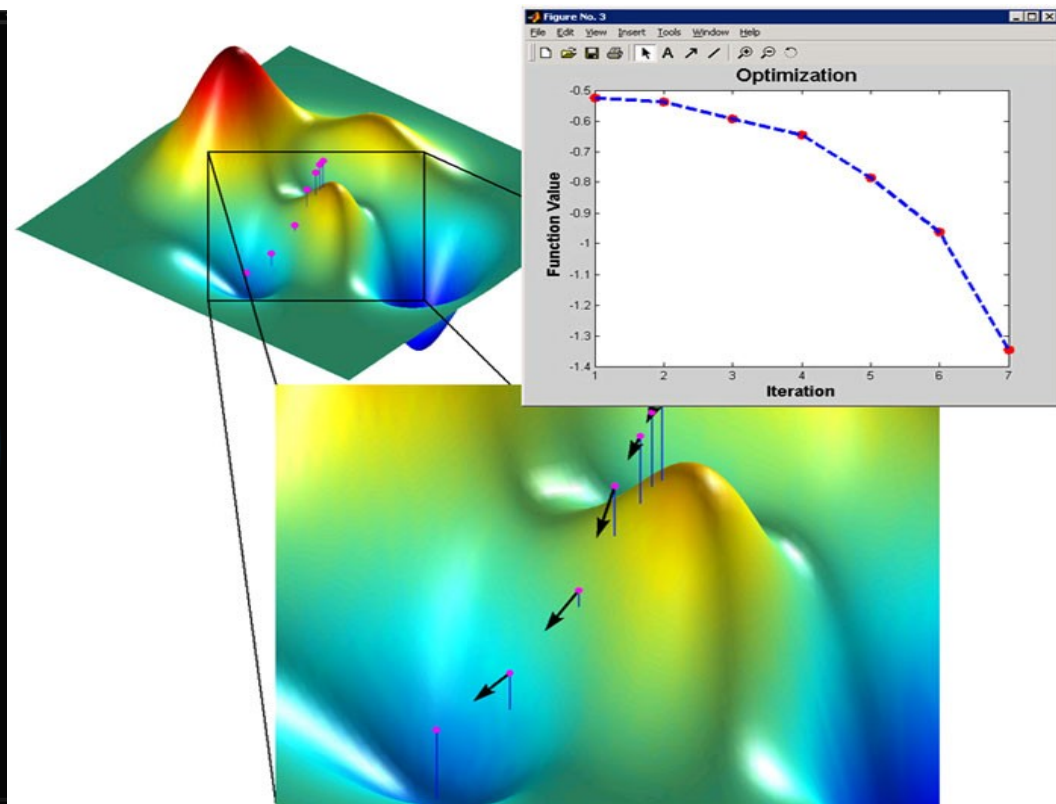

Czas potrzebny do rozwiązania problemu komiwojażera w zależności od ilości miast (przy założeniu, że komputer przetwarza **milion** instrukcji na sekundę)



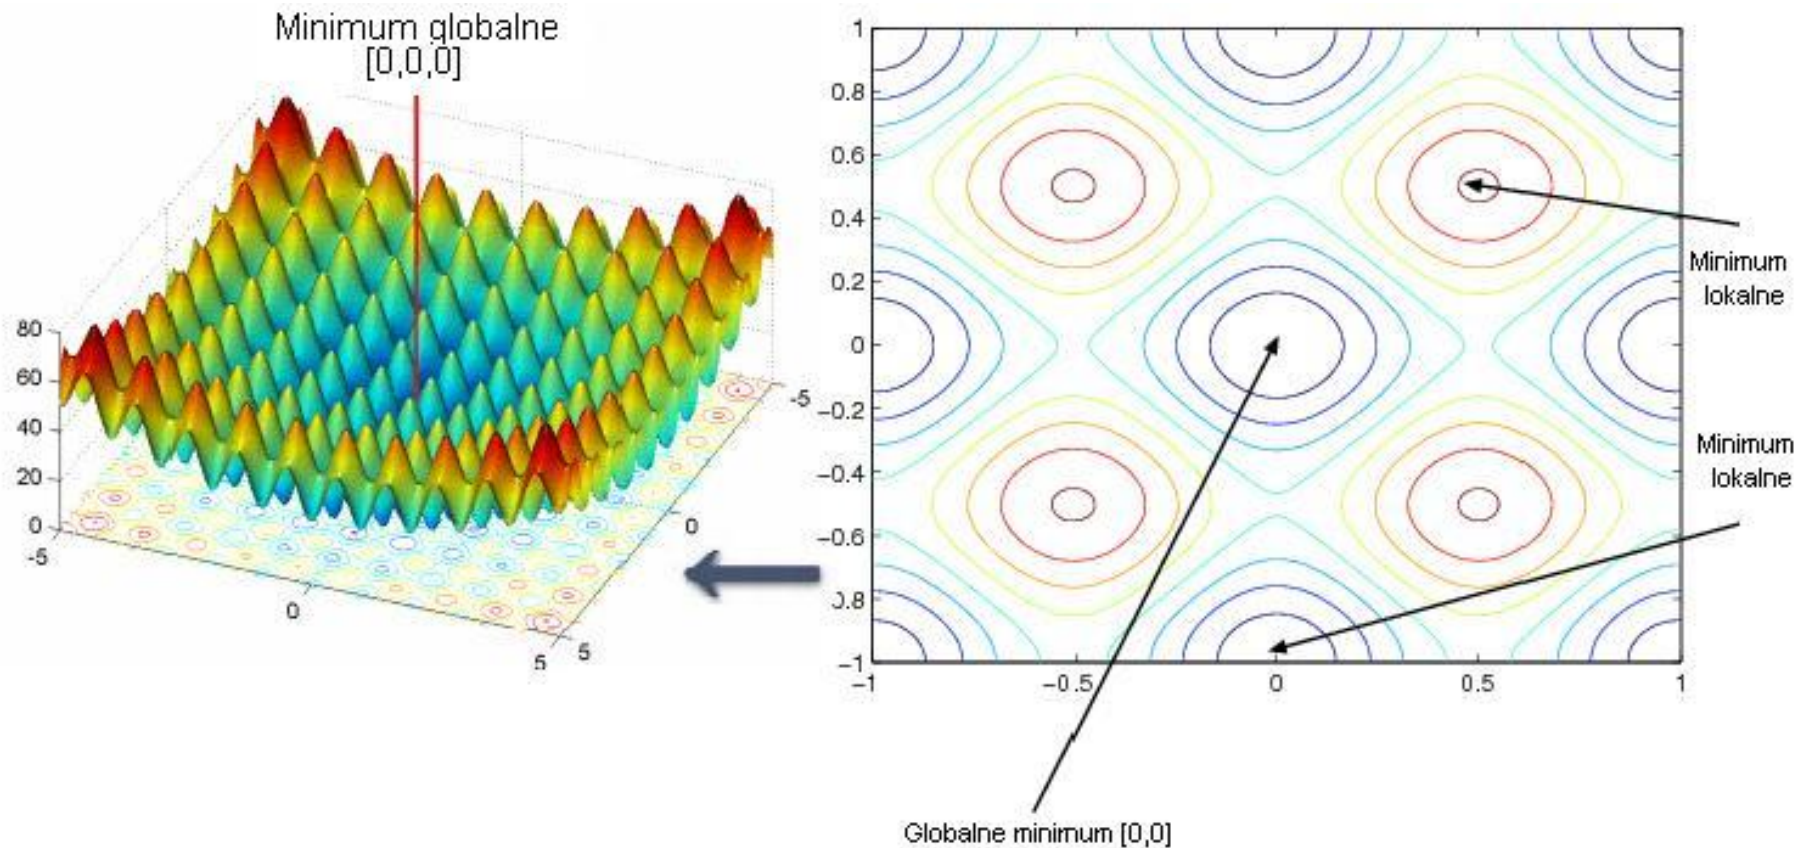
Ilość miast	10	50	100	300
Czas [mikrosekundy]	$\sim 3,6 * 10^6$	$\sim 10^{16}$	$\sim 10^{31}$	$\sim 10^{623}$

Dla porównania – liczba mikrosekund od wielkiego wybuchu, w którym narodził się nasz Wszechświat jest rzędu 10^{24} .

Poszukiwanie ukierunkowane zwykle oparte jest na jakiejś odmianie metody najszybszego spadku




Tu widać, jak trudne może być trafienie globalnego minimum

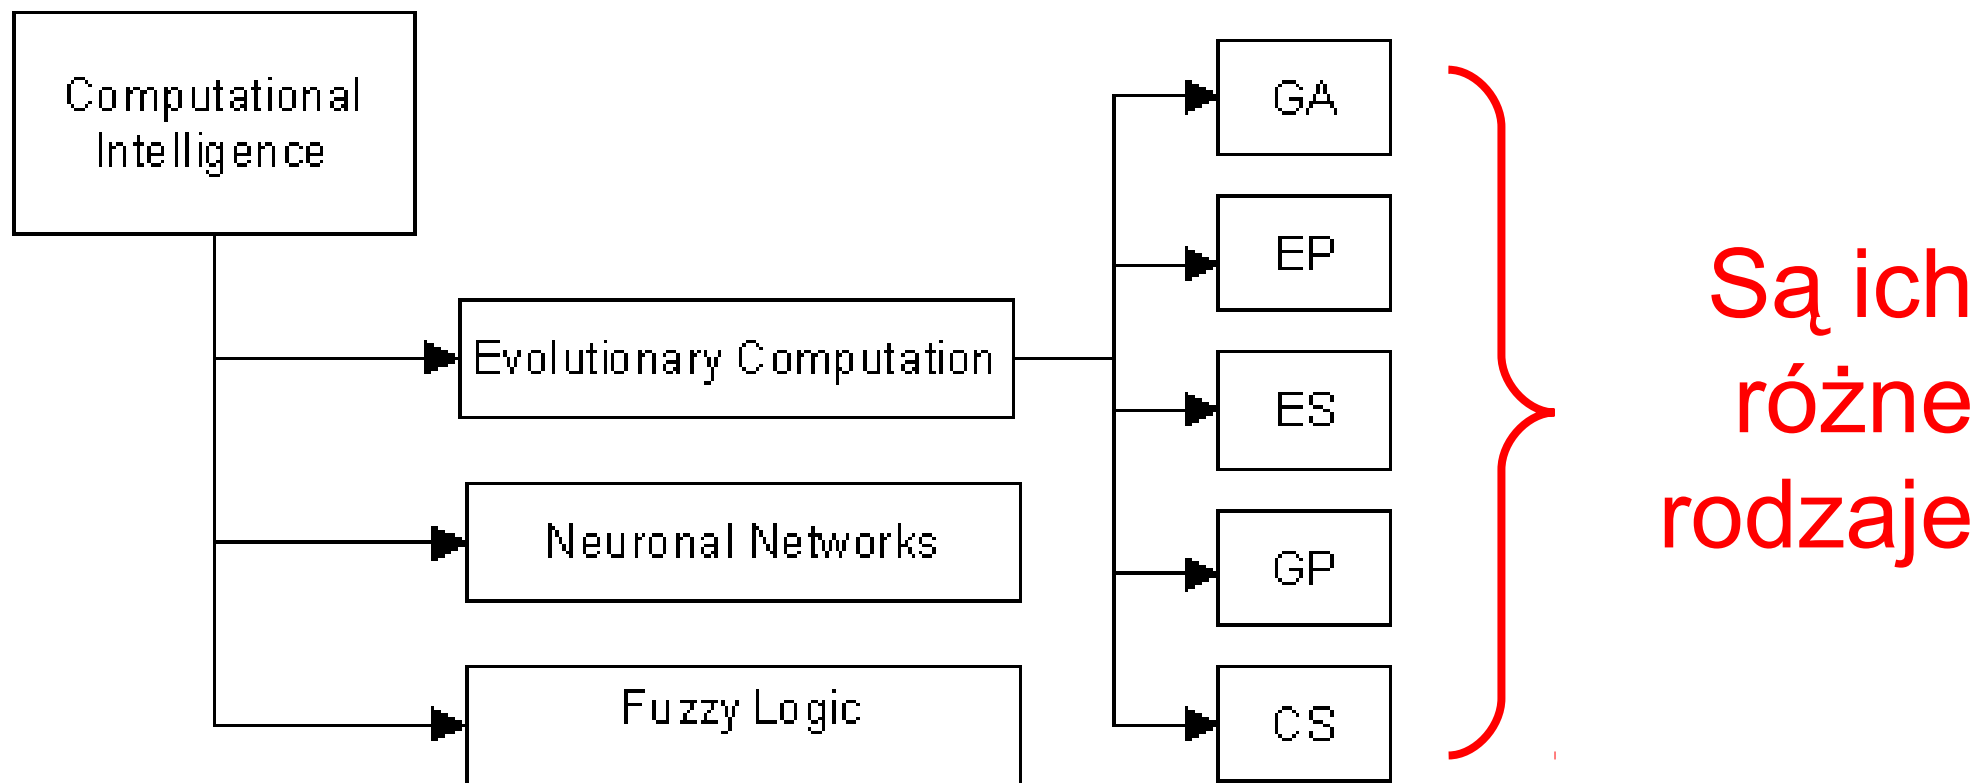


Przedstawiony na rysunku wykres tzw. funkcji Rastrigina obrazuje trudności jakie napotkać można przy poszukiwaniu optimum. Funkcja ta posiada wartość najmniejszą w punkcie $(0,0,0)$, jednak zanim algorytm przeszukiwania znajdzie to minimum globalne, może napotkać wiele minimów lokalnych.

Stochastyczne poszukiwanie rozwiązań nie gwarantuje sukcesu

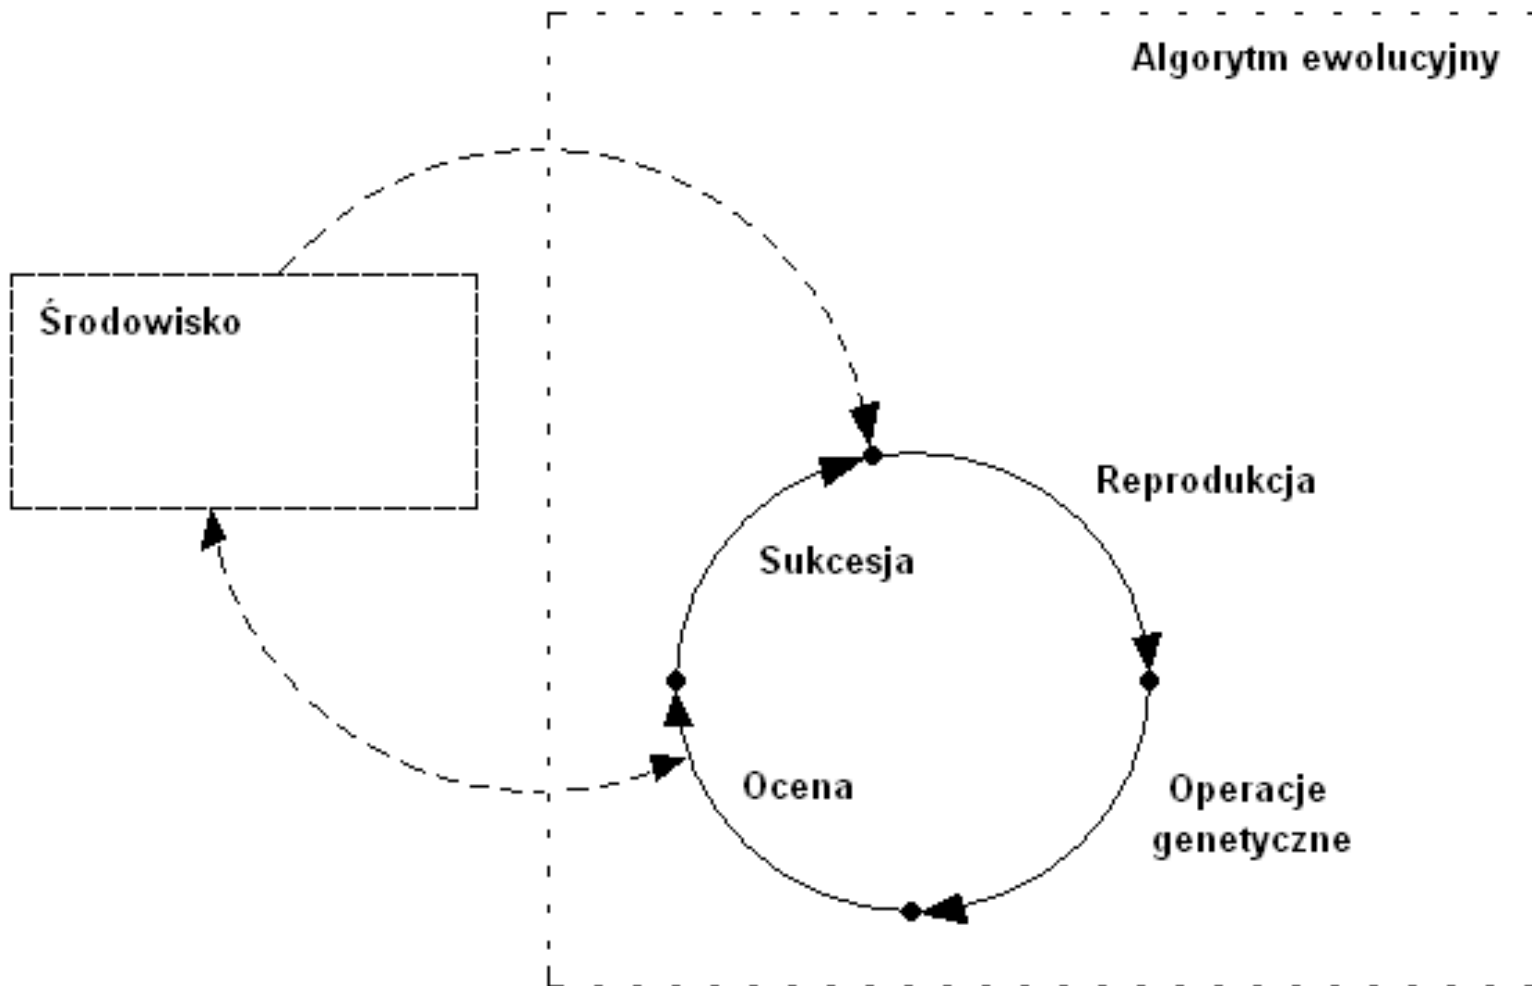


Obliczenia ewolucyjne są dziś ważną częścią sztucznej inteligencji

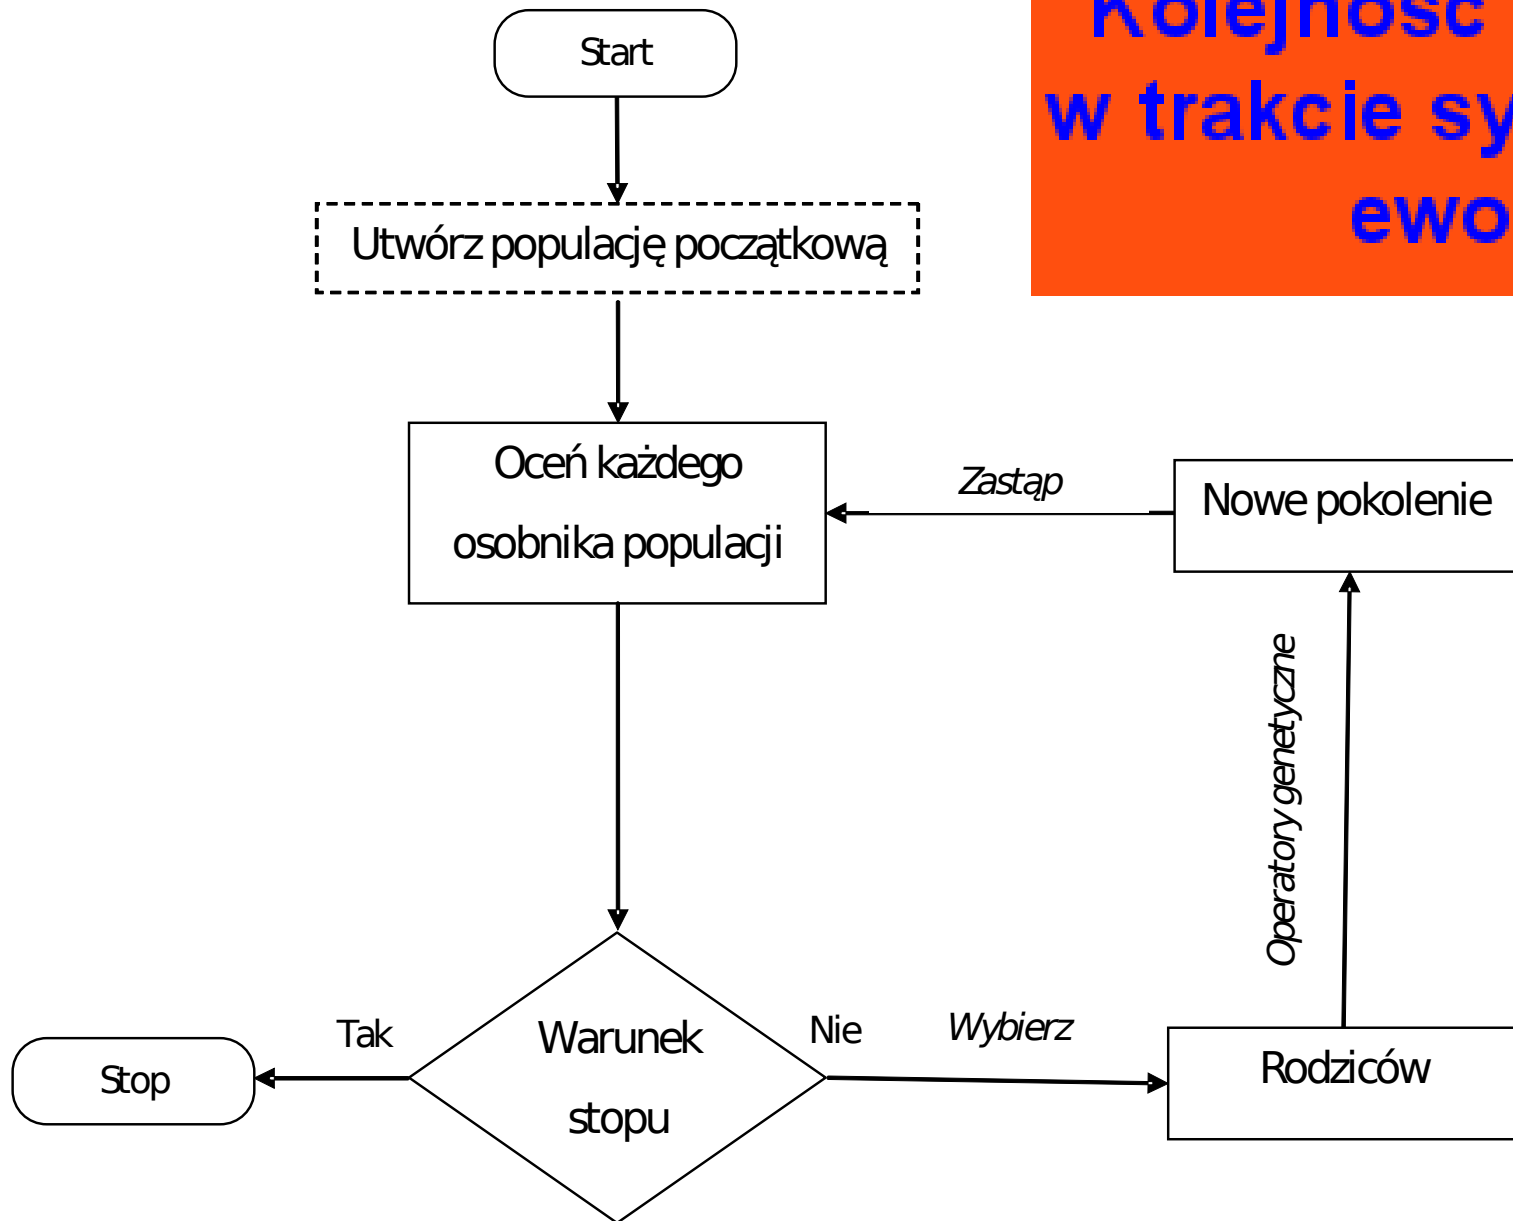


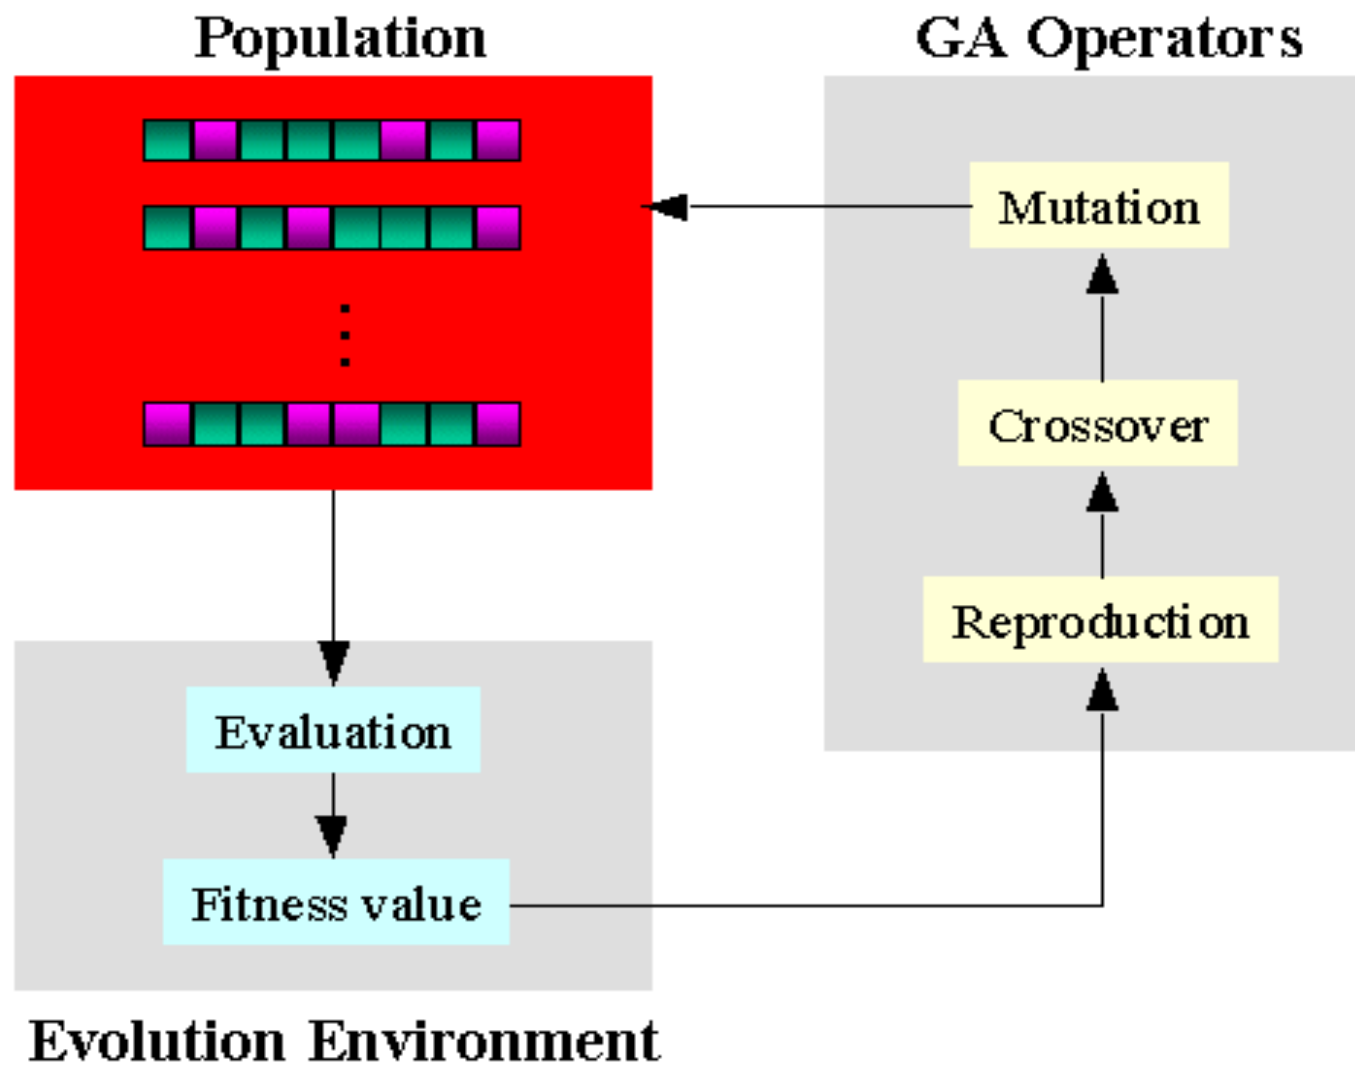
Metody ewolucyjne powstały
i zostały rozwinięte w tym celu, żeby znajdować
przybliżone rozwiązania problemów
optymalizacyjnych w taki sposób, by znajdować
wynik w miarę szybko
oraz uniknąć pułapek minimów lokalnych

Schemat algorytmu ewolucyjnego



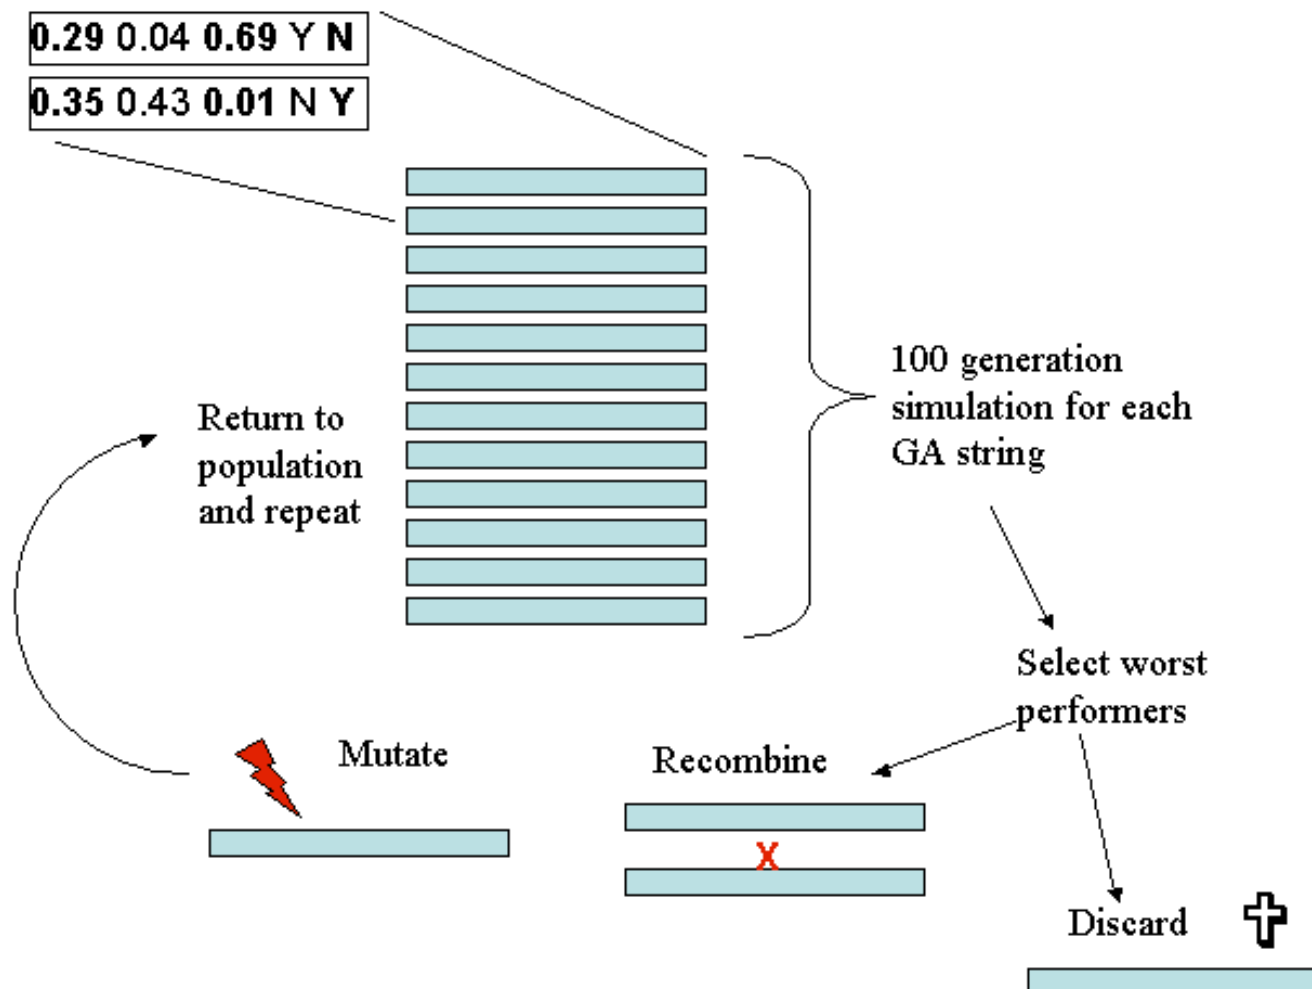
Kolejność czynności w trakcie symulowanej ewolucji






Genetic Algorithm Evolution Flow

Populacja rozwiązań rozwija się poprzez mutacje, krzyżowania oraz „wymieranie” mniej udanych osobników



Porównanie skutków krzyżowania i mutacji



Przykładowy sposób zastosowania operatora krzyżowania:

Osobniki rodzicielskie:

0	0	1	0	1	1	1	0
---	---	---	---	---	---	---	---



1	0	0	1	1	0	0	1
---	---	---	---	---	---	---	---




Osobniki potomne:

0	0	1	0	1	0	0	1
---	---	---	---	---	---	---	---

1	0	0	1	1	1	1	0
---	---	---	---	---	---	---	---

Działanie operatora krzyżowania:


- a) krzyżowanie jednopunktowe (*one-point crossover*),
- b) krzyżowanie dwupunktowe (*two-point crossover*).




Działanie operatora mutacji




Mutacje mogą także przyjmować bardziej skomplikowane formy:




(a) Replacement




(b) Random swap




(c) Adjacent swap



(d) End-for-end swap




(e) Inversion

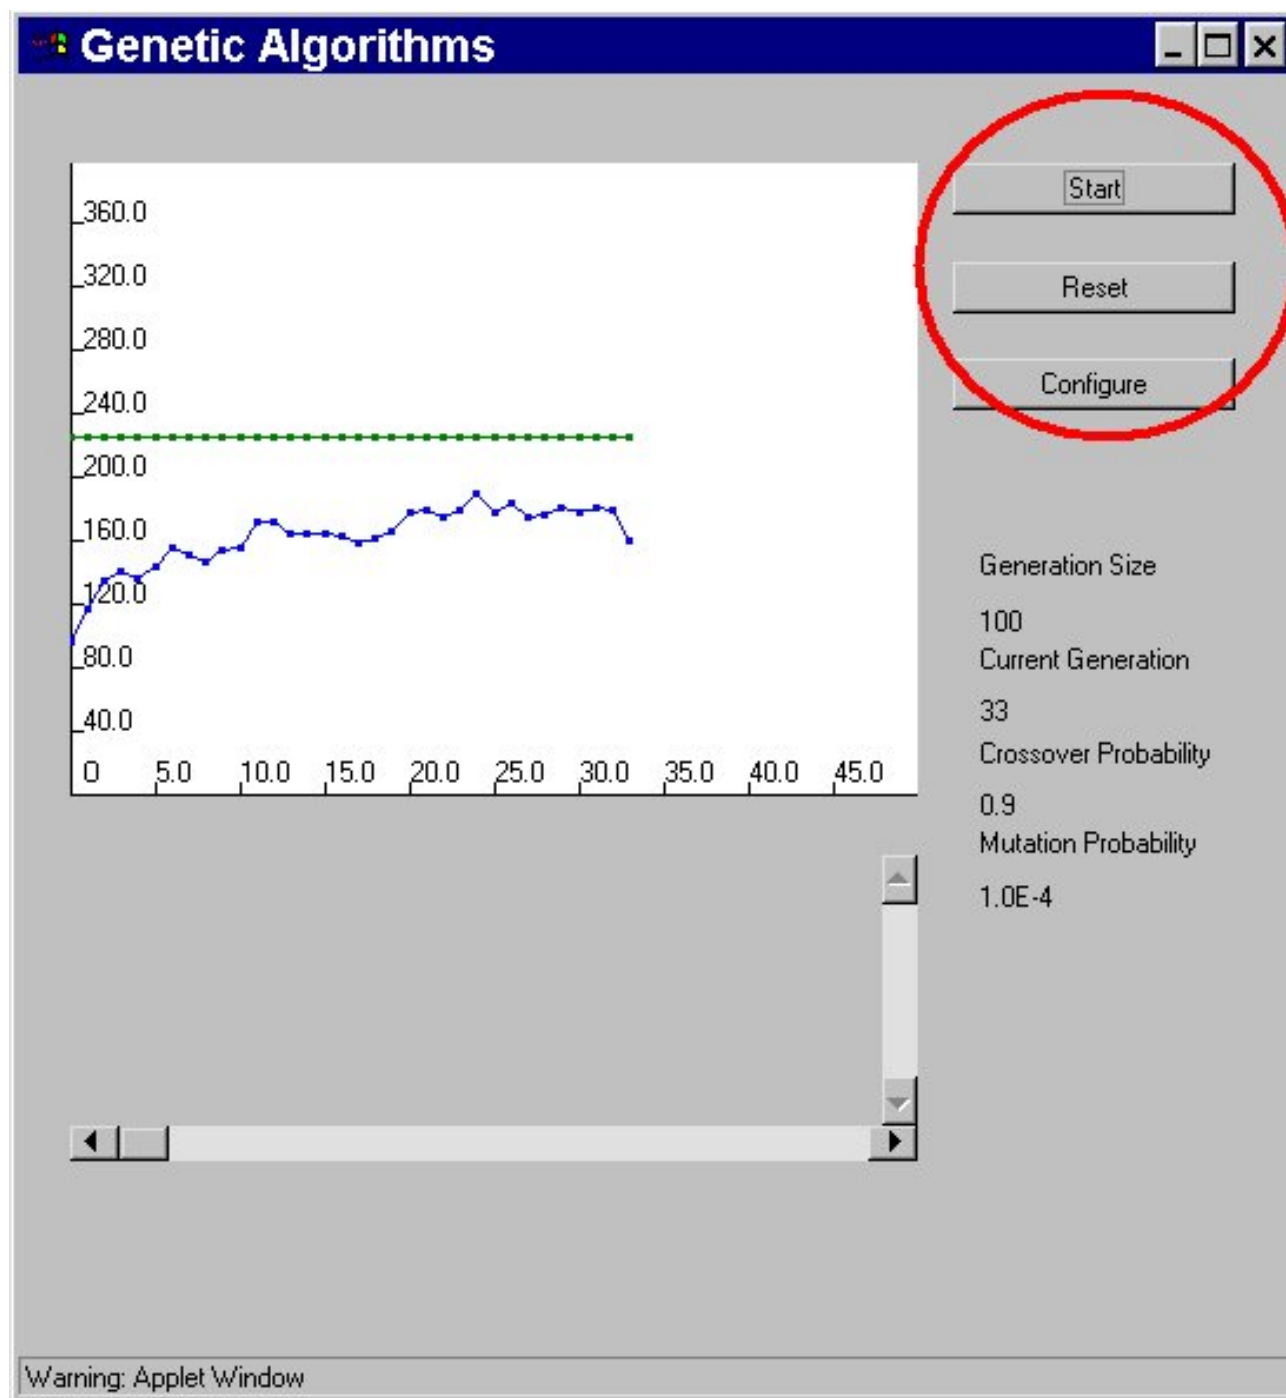


(f) Deletion

Zaletą algorytmów genetycznych jest to, że jeśli rozważany problem ma **kilka rozwiązań** to zostaną one wszystkie znalezione



Do realizacji
obliczeń zgodnie
z zasadami
algorytmów
genetycznych
dostępnych jest
wiele gotowych
programów



Systemy rozmyte są modelami przetwarzającymi informację za pomocą zbioru reguł rozmytych „jeżeli – to”

Rozmytość jest sposobem reprezentowania niejednoznaczności (niepewności) określeń lingwistycznych (n.p. wysoka temperatura)

Najczęściej stosowane w sterowaniu i podejmowaniu decyzji:

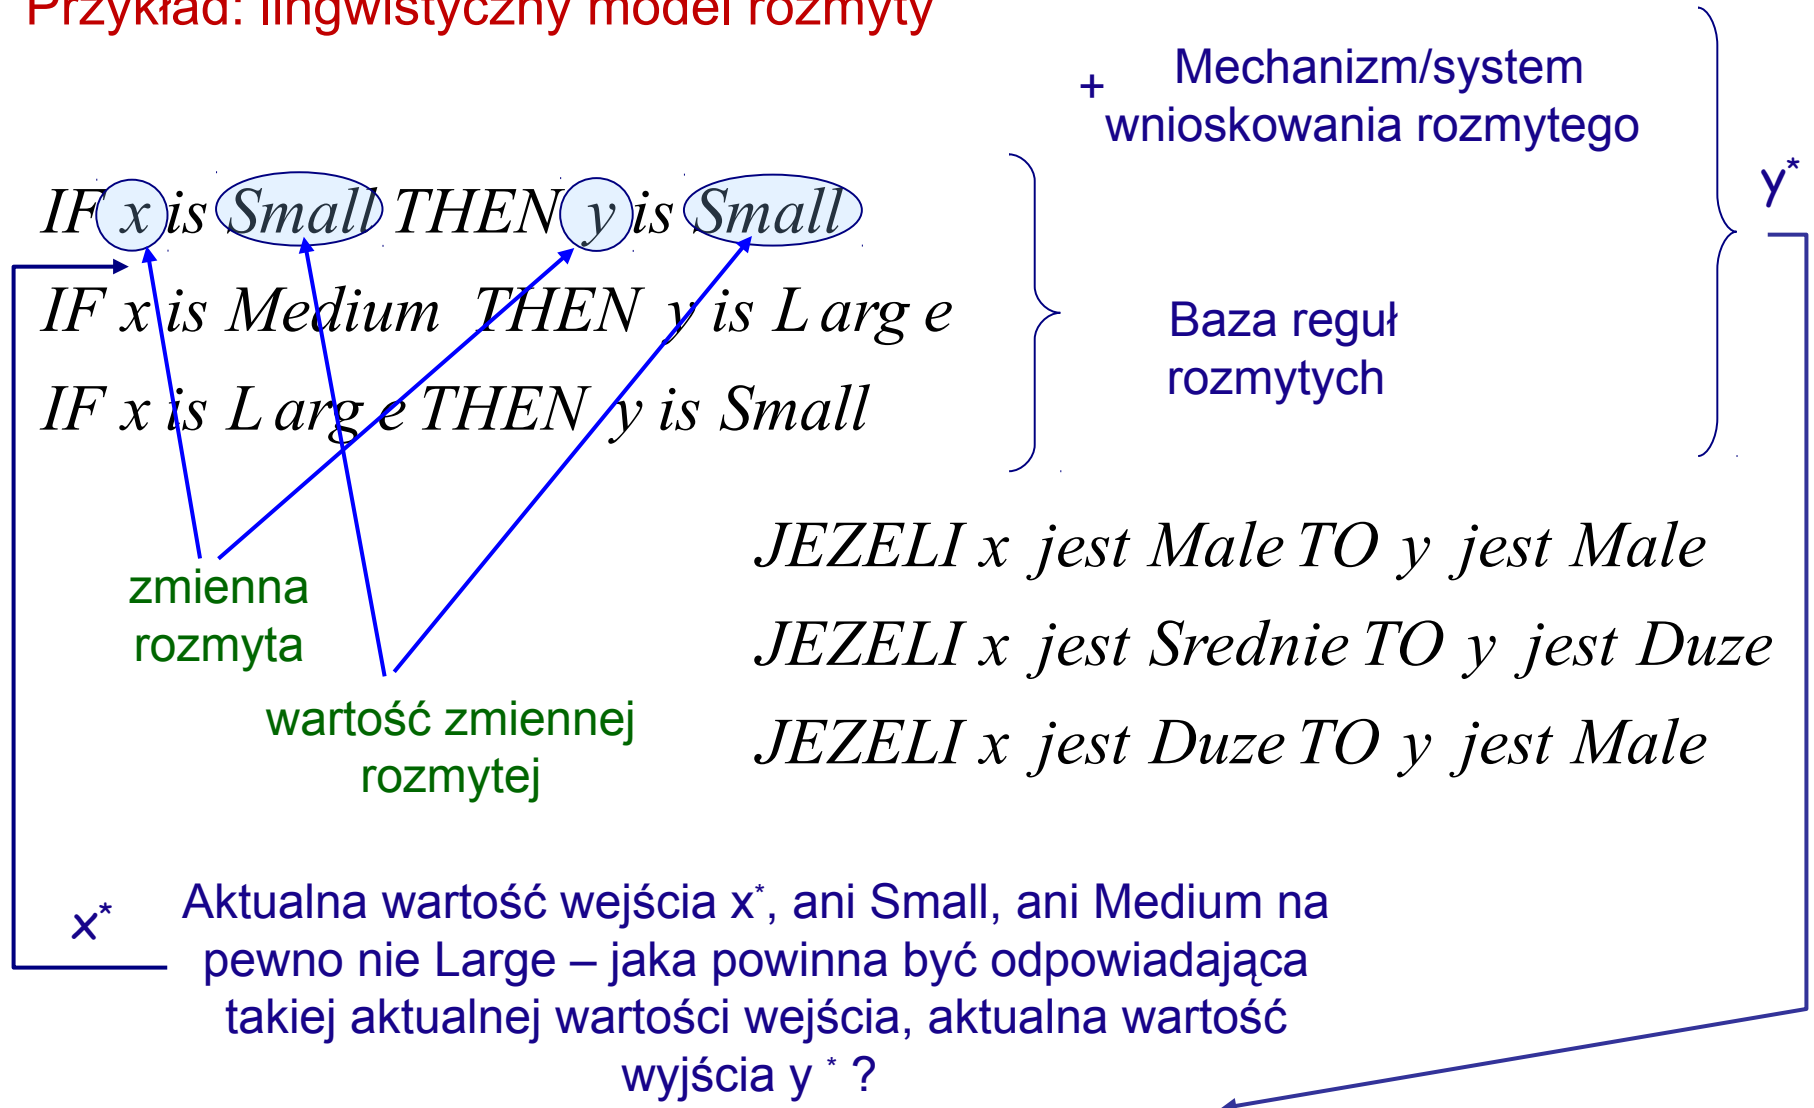
Lingwistyczny model rozmyty (Mamdani'ego, Larsen'a)

Takagi-Sugeno model rozmyty (TS)

Tsukamoto model rozmyty

Jak wygląda model rozmyty i jak działa?

Przykład: lingwistyczny model rozmyty



Model rozmyty - zapis wiedzy w postaci reguł rozmytych

Budujemy system sterowania temperaturą

Źródło ciepła: piec opalany gazem dopływającym ze stałym natężeniem, zmieniamy natężenie dopływu tlenu O_2



Wejście – x , natężenie dopływu tlenu O_2

Piec

Wyjście – y , moc grzejna

Wartości lingwistyczne wejścia – $T(x) = \{\text{Niskie, OK, Wysokie}\}$

Wartości lingwistyczne wyjścia – $T(y) = \{\text{Niska, Wysoka}\}$




Działanie obiektu – model rozmyty obiektu:

R1: JEŻELI *Natężenie dopływu O_2* = *Niskie* TO *Moc cieplna* = *Niska*

R2: JEŻELI *Natężenie dopływu O_2* = *OK* TO *Moc cieplna* = *Wysoka*

R3: JEŻELI *Natężenie dopływu O_2* = *Wysokie* TO *Moc cieplna* = *Niska*



Dla podjęcia decyzji niezbędny jest **mechanizm wnioskowania**

Wnioskowanie w systemach rozmytych **Uogólniony Modus Ponens:**

Przesłanka 1 (fakt)

$$x = A'$$

Przesłanka 2 (reguła rozmyta)

$$\text{JEŻELI } x = A \text{ TO } y = B$$

Wniosek

$$y = B'$$

gdzie: A' , B' oznacza „bliski A ”, „bliski B ” odpowiednio

A , A' , B , B' , - wartości lingwistyczne - zbiory
rozmyte

x , y – zmienne lingwistyczne


Mechanizm wnioskowania – podejście Mamdaniego



Ebrahim MAMDANI




Imperial College of Science, Technology and
Medicine, University of London

Jak wygląda model rozmyty i jak działa?



Przykład: wnioskowanie Mamdani'ego

Mechanizm wnioskowania – podejście Mamdaniego



$$A' = x = 1.25$$

$$[\text{m}^3/\text{h}]$$

Krok 1: Rozmywanie


Określić w jakim stopniu „ostra” wartość wejścia (zbiór A') należy do zbioru rozmytego przesłanki (zbiory A_i) - spełnia przesłankę reguły

Krok 2: Ocena działania poszczególnych reguł

Określić wartości wyjścia dla każdej reguły (zbiory rozmyte B'_i)


Krok 3: Agregacja działania reguł

Określ sumę wartości wyjść z poszczególnych reguł (zbiór B')



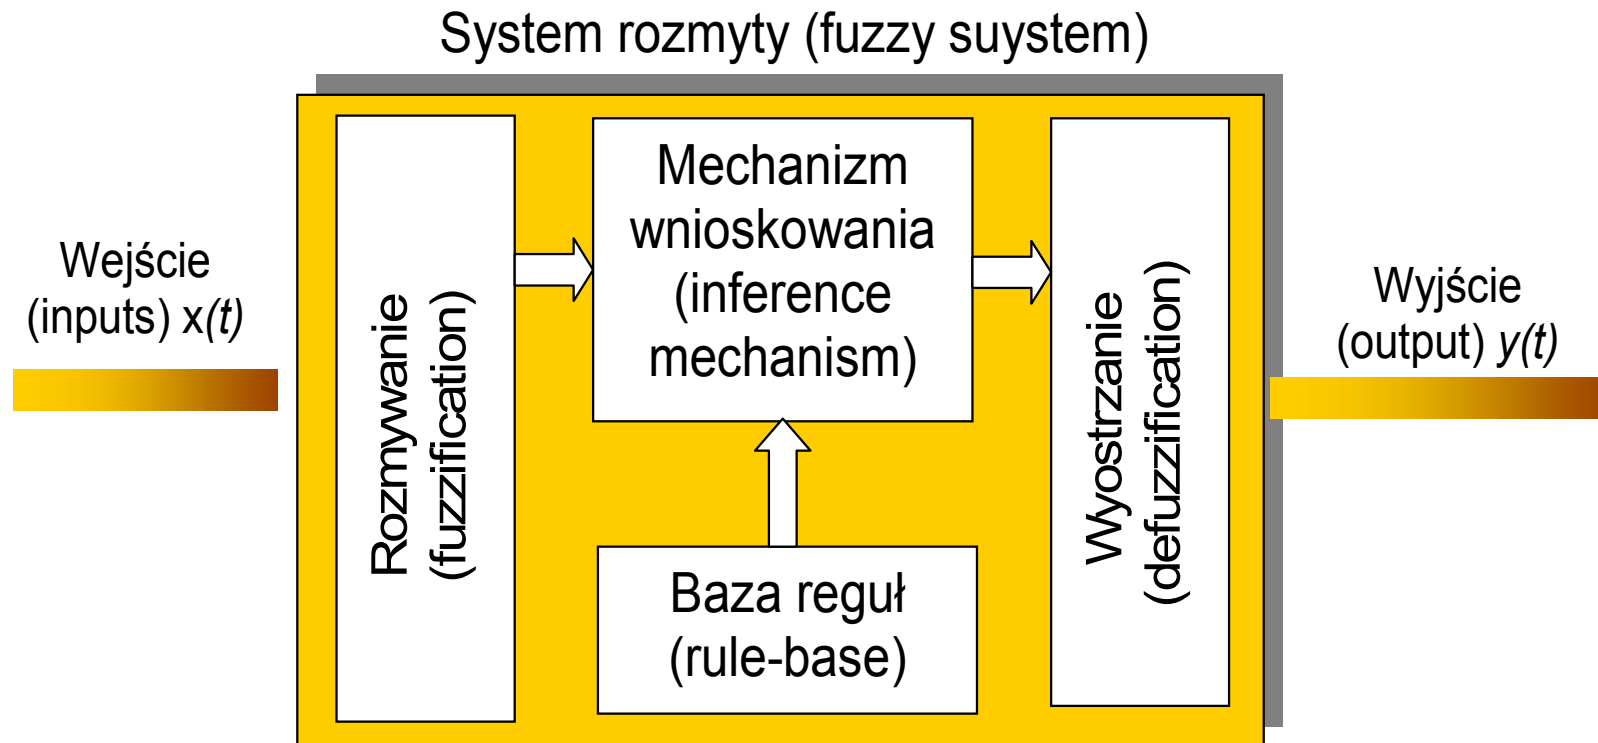
Krok 4: Wyostrzanie wyjścia

Np. metoda środka ciężkości



System rozmyty:


Zbiór reguł wyposażony w odpowiedni system wnioskowania i stosowne do systemu wnioskowania systemy wejścia i wyjścia




Przykład zbiorów rozmytych:


- zbiory rozmyte dla sterowania wahadłem odwróconym

Obiekt



Struktura systemu sterowania





Wyjście regulatora:

Siła przyłożona do wózka – $u(t)$

Wejścia regulatora:

$$1) \quad e(t) = r(t) - y(t)$$

Odchylenie
od położenia
pożądanego

Położenie
pożądane

Położenie
aktualne

$$2) \quad \frac{d}{dt} e(t)$$

Zmiana
odchylenia
od położenia
pożądanego

Zmienne lingwistyczne:

„Odchylenie” - $e(t)$

„Zmiana odchylenia” - $\frac{d}{dt}e(t)$

„Siła” - $u(t)$

Pożądane położenie:


$$r(t) = 0$$

Zależności:

$$e(t) = -y(t); \quad \frac{d}{dt}e(t) = -\frac{d}{dt}y(t)$$

Konwencja:

Położenie $\rightarrow + \Rightarrow$ Odchylenie - ; Położenie $\leftarrow - \Rightarrow$ Odchylenie +



Zmiana położenia $\rightarrow + \Rightarrow$ Zmiana odchylenia - ;


Zmiana położenia $\leftarrow - \Rightarrow$ Zmiana odchylenia +

Siła $\rightarrow +$




Wartości lingwistyczne (dla wszystkich zmiennych):

- . ujemna, duża co do wartości – „neglarge”
- . ujemna, mała co do wartości – „negsmall”
- . zero – „zero”
- . dodatnia, mała co do wartości – „possmall”
- . dodatnia, duża co do wartości – „poslarge”

Wahadło odwrócone w różnych pozycjach



Zdefiniowanie wartości rozmytych dla poszczególnych zmiennych rozmytych



Koniec