



Sztuczne sieci neuronowe

Krzysztof A. Cyran
POLITECHNIKA ŚLĄSKA
Instytut Informatyki, p. 311

Wykład 7



PLAN:

- Repetitio (brevis)
- Algorytmy miękkiej selekcji:
 - algorytmy ewolucyjne*
 - symulowane wyżarzanie*
- Opowieść o kangurach

Repetitio

- *W aspekcie architektury*: zajmowaliśmy się tylko sieciami typu *feed-forward*
- *W aspekcie działania pojedynczego neuronu*: rozważaliśmy tylko neurony sigmoidalne oraz radialne

Repetitio (cd.)

W aspekcie uczenia: szczegółowo przedstawiono tylko gradientowe algorytmy uczenia nadzorowanego:

- *backpropagation* (wraz z modyfikacjami inercyjnymi) (algorytm I rzędu)
- *metodę zmiennej metryki* (algorytm II rzędu)
- *metodę gradientów sprzężonych* (algorytm I rzędu)

Algorytmy miękkiej selekcji

Algorytmami miękkiej selekcji nazywamy algorytmy umożliwiające akceptowanie wzrostu minimalizowanej funkcji celu, po to by ewentualnie ominąć strefę przyciągania minimum lokalnego. Do najbardziej znanych należą metody bazujące na:

- Algorytmach ewolucyjnych (genetycznych)
- Symulowanym wyżarzaniu (odprężaniu)

Algorytmy ewolucyjne (AE)

- Pierwowzorem AE były algorytmy genetyczne (AG), które bazowały na zjawisku doboru naturalnego występującego w przyrodzie ożywionej
- Podstawowa struktura danych: chromosom (ciąg genów). Dla chromosomów haploidalnych pojedynczy chromosom jest równoważny genotypowi

Genotyp i fenotyp w AE

- W AE chromosom reprezentuje jedno potencjalne rozwiązanie
- Znaczenie tego rozwiązania, czyli fenotyp jest definiowane z zewnątrz przez użytkownika

AE w dziedzinie sieci neuronowych

- Fenotypami rozważanymi przez nas są sieci neuronowe
- Chromosomami zaś są pewne reprezentacje sieci neuronowych poddane przetwarzaniu w algorytmie ewolucyjnym

Podstawowe operatory genetyczne

- Selekcja (odpowiada za dobór naturalny fenotypów)
- Krzyżowanie lub rekombinacja (odpowiada wymianie fragmentów chromosomów)
- Mutacja (odpowiada przypadkowej zmienności genów w chromosomie)

Zadania operatorów genetycznych

- Zadaniem selekcji jest statystycznie bardziej prawdopodobny wybór tych fenotypów (a pośrednio tych chromosomów), których dopasowanie (czyli funkcja celu) jest większa od pozostałych fenotypów populacji
- Zadaniem krzyżowania i mutacji jest generowanie nowych potencjalnych rozwiązań.

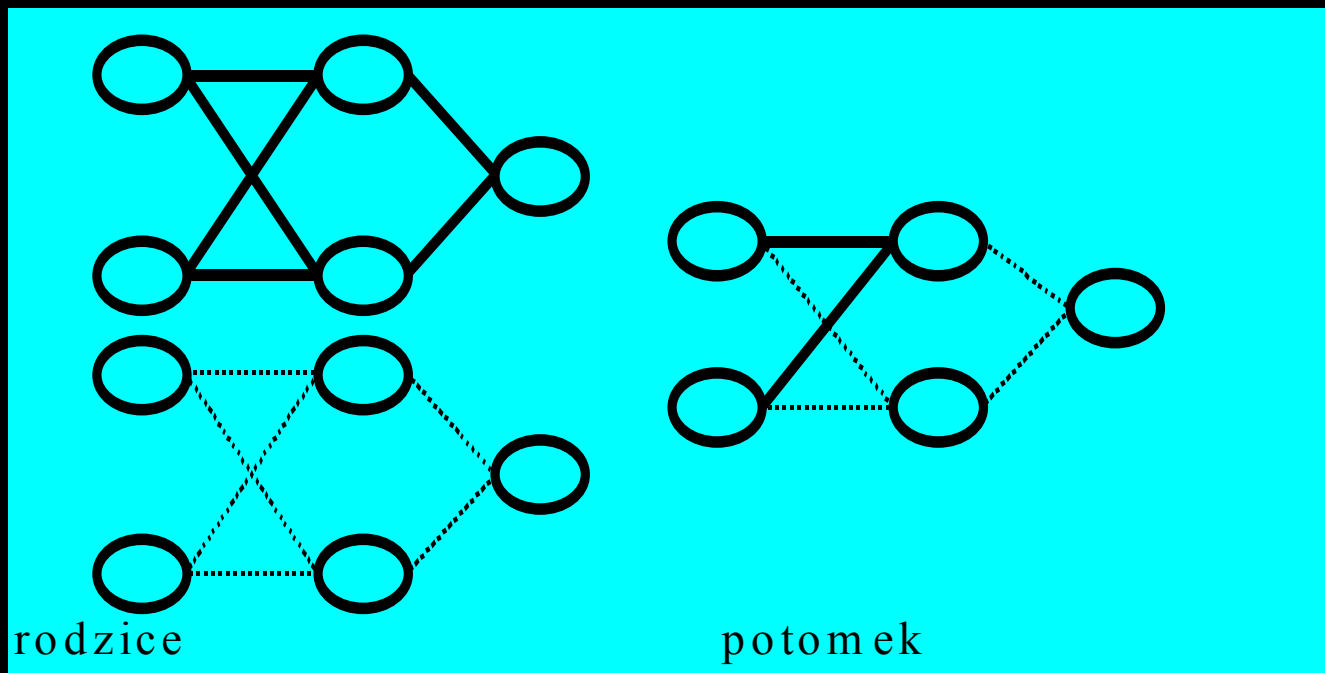
Algorytmy genetyczne vs algorytmy ewolucyjne

- W AG chromosomy są zdefiniowane jako łańcuchy bitów. Transformacją takich chromosomów do przestrzeni zadania zajmowały się skomplikowane funkcje dekodujące
- W AE postuluje się zejście z reprezentacją chromosomów tak blisko rozwiązywanego zadania, jak to jest możliwe. Reprezentacje chromosomów ulegają więc znacznemu poszerzeniu. Najczęściej jednak stosuje się reprezentacje zmiennopozycyjne, w których chromosom to prosty ciąg liczb rzeczywistych

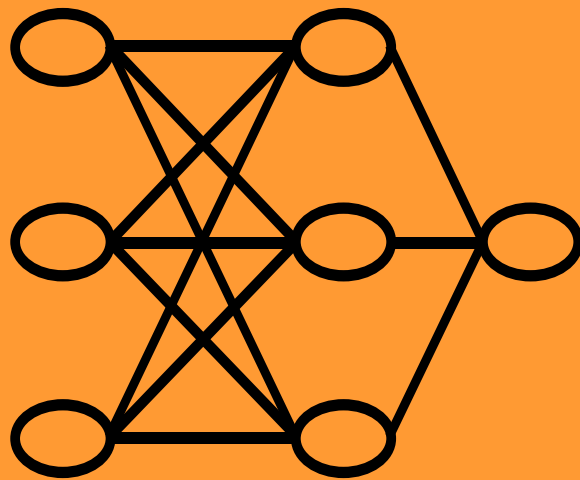
Typowy algorytm ewolucyjny

```
Inicjalizacja sztucznego świata; // małe creatio ex nihilo
Pokolenie = 1; //Adam i Ewa
Oblicz dopasowanie;
while (not warunek_zakończenia) do
    Selekcja; // homo homini lupus est
    Krzyżowanie; // troszkę przyjemności z wymiany genów
    Mutacja; // tak zapewne powstały krasnoludki
    Inc (Pokolenie);
    Oblicz dopasowanie;
end while;
Mamy Pokolenie NADKRASNALI; // Pora się obudzić
```


Operator krzyżowania sieci neuronowych



Operator mutacji sieci neuronowej



rodzic



potomek

Cele stosowania AE w dziedzinie sieci neuronowych

- Uczenie sieci: dopasowanie określa się jako

$$f = 1 - E_{znormalizowane}$$

- Poszukiwanie optymalnej struktury sieci: problem naukowo otwarty:
 - nietrywialne definicje operatorów genetycznych,
 - tzw. problem permutacji: wiele różnych strukturalnie sieci jest identyczna funkcjonalnie)

Symulowane wyżarzanie – pochodzenie metody

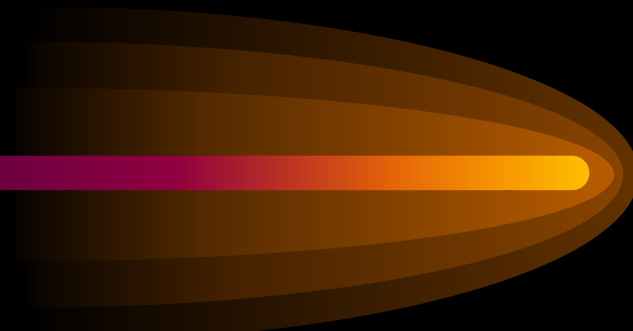
- Bazę stanowi analogia (znana fizyce statystycznej) tworzenia kryształu ciała stałego poprzez powolne wymrażanie
- Minimalny stan energetyczny odpowiadający kryształowi osiąga się tylko poprzez powolne obniżanie temperatury, tak by w każdej temperaturze dochodziło do spełnienia równowagi termicznej

Symulowane wyżarzanie – jak stosować algorytm dla SN

- Przypisać funkcji energetycznej wartość minimalizowanej funkcji błędu SN
- Wyrażając temperaturę w jednostkach energii można przedstawić uczenie sieci neuronowej jak na następnym slajdzie.

Symulowane wyżarzanie - algorytm

```
S = S0; // rozwiązanie początkowe
T = T0 // temperatura początkowa
while (not warunek_końca) do
    while (not stan_równowagi) do
        S' = losowo_generowane_sąsiednie_rozwiazanie;
        ΔE = E (S') – E (S);
        if (ΔE < 0) or (RND < exp (- ΔE/T)) then
            S = S';
        end if;
    end while;
    Aktualizacja T;
end while;
S – znalezione rozwiązanie
```



Dobór temperatury w algorytmie symulowanego wyżarzania

Dobór temperatury może być dokonywany według wzoru:

$$T(t_n) = \frac{T_0}{1 + \ln t_n}$$

gdzie: t_n jest kolejnym cyklem przetwarzania

Opowieść o kangurach

- Tresowany kangur posuwa się tylko do góry. Wchodzi na szczyt dowolnie wybranej góry i ma nadzieję, że wejdzie na Mont Everest (algorytm gradientowy)
- Tresowany kangur jest pijany, chodzi tu i tam. W końcu powoli trzeźwieje i stara się iść w górę w nadziei, że zdobywa Mont Everest (symulowane wyżarzanie)
- W Himalajach puszczono stado nie tresowanych kangurów, które nie mają pojęcia co mają robić. Skaczą tu i tam. Jednak co pewien zabija się kangury lubiące skakanie w dolinach w nadziei, że po wielu takich polowaniach, któryś z kangurów lubiących szczyty dotrze w pobliże szczytu Mont Everest (algorytmy ewolucyjne)