

## Instrukcja do laboratorium nr 3.

### Implementacja algorytmu gazu neuronowego.

(Metody Sztucznej Inteligencji)

W ramach laboratorium należy dokonać implementacji algorytmu gazu neuronowego oraz sprawdzić dla wybranych próbek. Dane można wygenerować losowo (należy pamiętać o ułożeniu próbek w klastry) lub skorzystać z danych z dowolnego repozytorium dostępnego w internecie (przykładowo *UCI* dane *iris* lub inne). Zakładamy, że analiza dotyczy problemu z minimum dwoma wejściami.

#### 1. Algorytm.

- (a) Inicjalizacja parametrów sieci. Współczynniki wagowe: dobrze jest inicjować losowymi wartościami, przy czym w celu zagwarantowania, w miarę, równomiernego „rozchodzenia” się neuronów w kierunku swoich klastrów można je zainicjować losowymi wartościami ze środkowego przedziału zmienności (przykładowo dla próbek znormalizowanych do przedziału  $\langle 0, 1 \rangle$  można przyjąć przedział  $\langle 0.35, 0.75 \rangle$ ). Natomiast dodatkowe parametry sieci ( $\lambda$ ,  $\eta$ ) omówione są w dalszej części instrukcji.
- (b) Podajemy do sieci losowo wybrany wektor z próbką wejściową. Obliczamy odległość euklidesową pomiędzy wektorem wejściowym a wektorami wagowymi (neuronami). Sortujemy wszystkie neurony wg. odległości do wektora  $x$ , w rosnącej kolejności.
- (c) Dokonujemy adaptacji współczynników wagowych wg standardowej procedury, stosowanej w algorytmach Kohonena:

$$w_i(k+1) = w_i(k) + \eta(k)G(i, x)[x - w_i(k)] \quad (1)$$

gdzie:  $G(i, x)$  jest funkcją sąsiedztwa  $i$ -tego neuronu.

$$G(i, x) = \exp\{-m(i)/\lambda(k)\} \quad (2)$$

gdzie:  $m(i)$  jest pozycją  $i$ -ego neuronu w szeregu sortowań, przy czym dla neuronu zwycięzcy  $m(c) = 0$ .

- (d)  $\lambda$ . Cytując za [1]: „ $\lambda$  jest parametrem analogicznym do promienia sąsiedztwa w algorytmie Kohonena, malejącym w funkcji czasu. Przy  $\lambda = 0$  tylko neuron zwycięzca podlega adaptacji i algorytm przekształca się w zwykły WTA, natomiast przy  $\lambda \neq 0$  adaptacji podlegają wagi wielu neuronów w stopniu zależnym od wartości funkcji  $G(i, x)$ .”  $\lambda$  zmienia się w czasie wg następującej zależności:

$$\lambda(k) = \lambda_{max} \left( \frac{\lambda_{min}}{\lambda_{max}} \right)^{k/k_{max}} \quad (3)$$

Można przyjąć  $\lambda_{min} = 0.01$ , natomiast  $\lambda_{max}$  zazwyczaj równa się połowie ilości wszystkich neuronów  $M/2$ .

- (e) Współczynnik uczenia:  $\mu$ . Podobnie jak  $\lambda$  powinien maleć w czasie. Dodatkowo jest parametrem indywidualnym dla każdego neuronu (poszczególne neurony dobrze jest zainicjować różnymi wartościami). W związku z tym współczynnik uczenia dla  $i$ -ego neuronu, w  $k$ -ej iteracji:

$$\eta_i(k) = \eta_i(0) \left( \frac{\eta_{min}}{\eta_i(0)} \right)^{k/k_{max}} \quad (4)$$

$\eta_i(0)$  odpowiada maksymalnej, czyli początkowej wartości współczynnika uczenia, przykładowo można przyjąć  $\eta_i(0) = 0.8$ . Natomiast  $\eta_{min} = 0.003$ .

- (f) Ilość iteracji jest zależna od ilości neuronów. Przykładowo można przyjąć 200 iteracji/neuron.

#### 2. Wymagania.

Należy dokonać implementacji przedstawionego wyżej algorytmu. Przedstawić próbki wraz ze wstępnie zainicjowanymi neuronami oraz przebieg procesu adaptacji neuronów (w „skończonym czasie”).

### 3. Zasady oceniania.

0.5 pkt. za poprawnie działający algorytm, powyżej za realizację dodatkowych eksperymentów.

### 4. Dodatkowe eksperymenty.

- Poniższe propozycje należy zrealizować dla tego samego ułożenia próbek.
  - (a) Sprawdzić jakość działania algorytmu przy różnych miarach odległości pomiędzy wektorami.
  - (b) Czy występują różnice w przypadku, gdy wystartujemy algorytm ze wspólnym współczynnikiem uczenia, a następnie zainicjujemy neurony różnymi wartościami?
  - (c) Wykonać analizę porównawczą algorytmów:
    - gazu neuronowego,
    - Kohonena typu WTA,
    - Kohonena z sąsiedztwem gaussowskim ( $G(i, x) = \exp\{-d^2(i, w)/(2 * \lambda^2)\}$ ).Wykonać wykres zależności wartości błędu klasyfikacji – dla wymienionych metod – od liczby epok strojenia.
- Jeżeli sieć została nastrojona na podstawie próbek ułożonych w „proste” klastry, można wygenerować bardziej skomplikowane ułożenie próbek (klastrow) i jeszcze raz przeprowadzić proces samoorganizacji sieci.

### 5. Pytania kontrolne.

- (a) Jaka jest różnica pomiędzy algorytmem gazu neuronowego a klasycznym algorytmem Kohonena?
- (b) Czy zmiana miary odległości pomiędzy neuronami (przykładowo na iloczyn skalarny) spowoduje zmiany w jakości działania algorytmu?
- (c) Czy indywidualizacja współczynnika uczenia względem neuronów przyniosła korzyści?

## Literatura

- [1] Osowski Stanisław, Sieci neuronowe w ujęciu algorytmicznym, Wydawnictwa Naukowo-Techniczne, Warszawa 1996.