

Literatura


1. Tadeusiewicz R.: **Sieci neuronowe**. Akademicka Oficyna Wydawnicza, Warszawa 1993
2. Osowski S.: **Sieci neuronowe w ujęciu algorytmicznym**. WNT, Warszawa 1996
3. Hertz J., Krogh A., Palmer R. G.: **Wstęp do teorii obliczeń neuronowych**. WNT, Warszawa 1993
4. Masters T.: **Sieci neuronowe w praktyce. Programowanie w C++**. WNT, Warszawa 1996
5. Piłot T., Gwiazda A.: **Zastosowania sztucznej inteligencji w inżynierii produkcji**. Pod Red. R. Knosali, WNT 2002

Sieci neuronowe

Sieć Kohonena

Copyright by dr inż. Tomasz Piłot

Schemat wyjściowej warstwy sieci o algorytmie uczenia o konkurencji ostrej



[wektor cech wejściowych x_j]

Algorytm uczenia Kohonena

Metoda uczenia konkurencyjnego

Modyfikacja wag połączeń sieci:

$$w_{i*j} = w_{i*j} + \eta(t) (x_j^\mu - w_{i*j}),$$

gdzie: $\eta(t)$ – współczynnik uczenia, t – numer iteracji, x_j^μ – wartość j -tej cechy μ -tego wzorca wejściowego, w_{ij} – wartość wagowa połączenia wejściowego węzła j z i -tym neuronem wyjściowym.

Wartość wyjściowa:

$$h_i^\mu = \sum_j w_{ij} x_j^\mu = \mathbf{w}_i \cdot \mathbf{x}^\mu$$

Dla miary Euklidesowej:

$$|\mathbf{w}_{i*} - \mathbf{x}^\mu| \leq \mathbf{w}_i \cdot \mathbf{x}^\mu$$

Dla innych miar:

$$d(\mathbf{x}^\mu, \mathbf{w}_{i*}) = \min d(\mathbf{x}, \mathbf{w}_i), \quad 0 \leq i \leq n$$

Algorytm uczenia Kohonena

Metoda uczenia konkurencyjnego

W przypadku odległości stosuje się różne miary:

- miara Euklidesa:

$$d(\mathbf{x}, \mathbf{w}_i) = \sqrt{\sum_{j=1}^N (x_j - w_{ij})^2}$$

- iloczyn skalarny:

$$d(\mathbf{x}, \mathbf{w}_i) = \sqrt{\sum_{j=1}^N (x_j - w_{ij})^2}$$

- miara według normy L_1 (Manhattan):

$$d(\mathbf{x}, \mathbf{w}_i) = \sqrt{\sum_{j=1}^N (x_j - w_{ij})^2}$$

- miara według normy L_∞ :

$$d(\mathbf{x}, \mathbf{w}_i) = \max_j (x_j - w_{ij})$$

Algorytm uczenia Kohonena

Normalizacja wektora wejściowego i wagowego

Sposoby normalizacji można przedstawić następująco:

- redefinicja składowych wektora wejściowego:

$$x_j \leftarrow \frac{x_j}{\sqrt{\sum_{j=1}^N x_j^2}}$$

- zwiększenie wymiaru przestrzeni wejściowej o jeden, tzn. z $\mathbb{R}^N \rightarrow \mathbb{R}^{N+1}$, gdzie:

$$\sum_{j=1}^{N+1} x_j^2 = 1$$

Algorytm uczenia Kohonena

Metoda uczenia konkurencyjnego z funkcją sąsiedztwa

Modyfikacja wag połączeń sieci:

$$w_{ij}(t) = w_{ij}(t-1) + \eta(t)\Lambda(i, i^*) (x_j - w_{ij}(t-1))$$

Określenie węzła o maksymalnej wartości wyjściowej, gdy $|w_i| = 1$:

$$|w_{i^*} - \mathbf{x}^\mu| \leq w_i \cdot \mathbf{x}^\mu$$

Obliczenie wartości funkcji w otoczeniu węzła „zwycięskiego”:

$$\Lambda(i, i^*) = \exp\left(-\frac{d^2(i, i^*)}{2\lambda(t)^2}\right)$$

Obliczenie nowych wartości funkcji promienia sąsiedztwa $\lambda(t)$ i współczynnika uczenia $\eta(t)$.

Algorytm uczenia Kohonena

Funkcje sąsiedztwa – funkcje promienia sąsiedztwa

Jako funkcje promienia sąsiedztwa $\lambda(t)$ stosuje się zwykle następujące:

- funkcję liniową $\lambda_1(t)$:

$$\lambda_1(t) = \lambda_0 \left(1 - \frac{t}{T_1} \right) + 1$$

gdzie: T_1 określa maksymalny okres,
 t określa numer iteracji,
 λ_0 wartość początkowa promienia sąsiedztwa.

- funkcję wykładniczą:

$$\lambda_2(t) = \lambda_0 \left(\frac{\lambda_{\min}}{\lambda_0} \right)^{\frac{t}{T_{\max}}}$$

- gdzie: T_{\max} - parametr określający maksymalną wartość iteracji,
 λ_{\min} - wartość przejściowa promienia sąsiedztwa, przy którym funkcja ta przechodzi przez punkt o współrzędnych $(T_{\max}, \lambda_{\min})$.

Algorytm uczenia Kohonena

Funkcja celu Rittera i Schultena

$$E\{\mathbf{w}_{ij}\} = \frac{1}{2} \sum_{ijk} M_i^\mu \Lambda(i, k) (\mathbf{x}_j - \mathbf{w}_{ij})^2 = \frac{1}{2} \sum_{\mu} \Lambda(i, i^*) \|\mathbf{x}^\mu - \mathbf{w}_{i^*}\|^2$$

Funkcje współczynnika uczenia:

- funkcja liniowa

$$\eta(t) = \eta_0 \left(1 - \frac{t}{T_1}\right)$$

- funkcja potęgowa

$$\eta(t) = \eta_0 \alpha t^{-\alpha}$$

- funkcja wykładnicza

$$\eta_2(t) = \eta_0 \left(\frac{\eta_{\min}}{\eta_0}\right)^{\frac{t}{T_{\max}}}$$

Algorytm „gazu neuronowego” cz.I

1. Sortowanie węzłów wyjściowych ze względu na odległość wzorca wejściowego, w mierze Euklidesa, od macierzy wag, związanej z danym węzłem:

$$d_0 < d_1 < \dots < d_{n-1}$$

gdzie:

n – liczba neuronów wyjściowych,

$m=0,1,\dots,n-1$ – określa pozycję węzła i -tego w wektorze odległości,

d_m – oznacza odległość na m -tej pozycji i -tego węzła wyjściowego w uporządkowanym wektorze odległości, która wyraża się zależnością:

$$d_m = |\mathbf{x} - \mathbf{w}_i|$$

gdzie:

\mathbf{x} - macierz wzorca wejściowego,

\mathbf{w}_i - macierz wag połączeń i -tego węzła wyjściowego i macierzy wejściowej \mathbf{x} .

Algorytm „gazu neuronowego” cz.II

2. Określenie wartości funkcji sąsiedztwa na węzłach uporządkowanych wg odległości d_m :

$$\Lambda(i, i^*) = e^{-\frac{\lambda(t)}{d_m^2}}$$

gdzie $\lambda(t)$ jest funkcją promienia sąsiedztwa.

Funkcje celu stowarzyszona z funkcją sąsiedztwa charakteryzuje się, przy wartościach $\lambda \rightarrow 0$, przejściem w algorytm uczenia konkurencji ostrej. Postać funkcji przybiera kształt paraboli. W przypadku jednak, gdy $\lambda \rightarrow \infty$, wtedy przy wolnej zmianie λ dostajemy funkcję wielomodalną, o wielu minimach lokalnych. W tym momencie funkcja ta zapewnia dojście procesu uczenia do globalnego minimum. Wskutek tego algorytm ten jest określany jako najbardziej skuteczny wśród takich algorytmów jak mapa Kohonena czy k-uśrednień.