

LABORATORIUM METODY SZTUCZNEJ INTELIGENCJI

Laboratorium nr 1_2

Temat: **Funkcje aktywacji neuronów, analiza sieci jednowarstwowej i dwuwarstwowej**

Funkcje aktywacji neuronów, struktury sieci neuronowych

1. Cel ćwiczenia

Celem ćwiczenia jest zapoznanie się z podstawowymi funkcjami aktywacji neuronów oraz budową struktur sztucznych sieci neuronowych (SN). Przedstawione zostaną funkcje aktywacji neuronów; skokowe np. funkcja *sgn*, oraz ciągłe funkcje aktywacji np. funkcja *liniowa*, funkcja *sigmoidalna unipolarna* i *bipolarna*, funkcja *Gausa*. Z podanych funkcji aktywacji zostaną zbudowane przykładowe SN jedno- oraz dwuwarstwowe.

2. Funkcje aktywacji neuronów

W ogólnym przypadku funkcje aktywacji neuronów SN można podzielić na:

- a) liniowe,
- b) nieliniowe:
 - dyskretne:
 - unipolarne, $y \in \{0, 1\}$, np. funkcja *skokowa*,
 - bipolarne, $y \in \{-1, 1\}$, np. funkcja *sgn*,
 - ciągłe:
 - unipolarne, $y \in (0, 1)$, np. funkcja *sigmoidalna unipolarna*,
 - bipolarne, $y \in (-1, 1)$, np. funkcja *sigmoidalna bipolarna*, *tangens hiperboliczny*,
 - radialne, np. funkcja *Gausa*, funkcje *bicentralne*.

Innym podziałem, jaki można zastosować do funkcji aktywacji neuronów SN jest podział na:

- a) lokalne funkcje aktywacji, np. funkcja Gausa, funkcje bicentralne,
- b) nielokalne funkcje aktywacji, np. funkcje sigmoidalne.


Przykłady funkcji aktywacji neuronów SN:

- *Liniowe* funkcje aktywacji neuronów,

W ogólnym przypadku liniowe funkcje aktywacji neuronów można opisać zależnością

$$y = f(x) = x \tag{1}$$

Przykłady generowania liniowej funkcji aktywacji w Matlab-ie ($y = x$).




Rys. 1. Przykład generowania funkcji liniowej w Matlab-ie

- *Nieliniowe* funkcje aktywacji neuronów:

a) unipolarne

Przykłady unipolarnych funkcji aktywacji pokazano na rys. 2.



Rys. 2. Unipolarne funkcje aktywacji

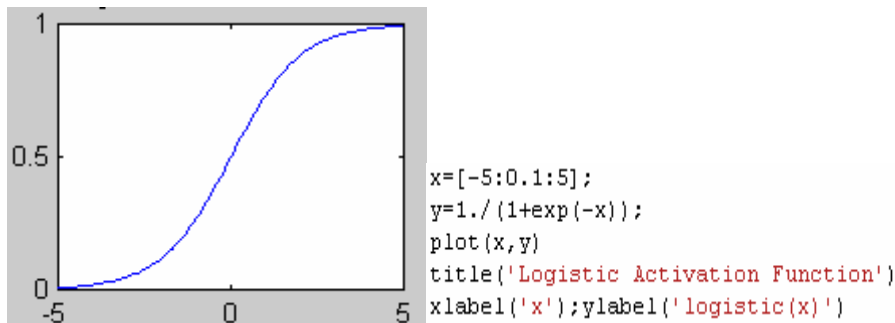
- dyskretna - *skok jednostkowy*:

$$f(x) = \begin{cases} 1 & \text{gd}y \ x > 0 \\ 0 & \text{gd}y \ x < 0 \end{cases} \quad (2)$$

- ciągła - *funkcja sigmoidalna unipolarna*:

$$f(x) = \frac{1}{1 + e^{-\beta x}}, \beta > 0, \quad (3)$$


Przykładową procedurę generującą w Matlab-ie funkcję sigmoidalną unipolarną dla współczynnika $\beta = 1$, przedstawiono na rys. 3.



Rys. 3. Przykład generowania funkcji sigmoidalnej w Matlab-ie

b) bipolarne

Przykłady bipolarnych funkcji aktywacji pokazano na rys. 4.

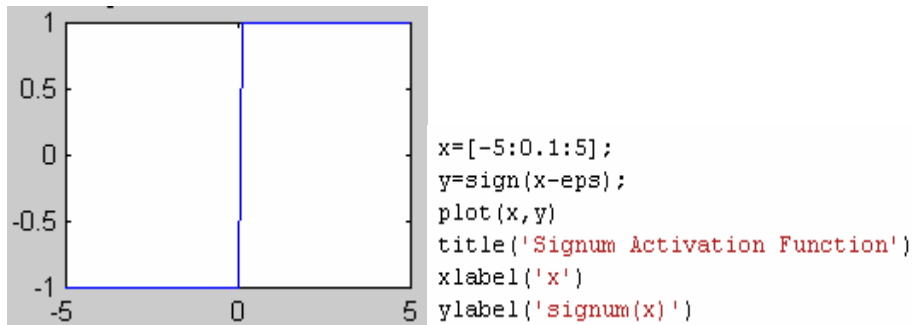


Rys. 4. Bipolarne funkcje aktywacji

- dyskretna - funkcja *sgn*:

$$f(x) = \text{sgn}(x) = \begin{cases} 1 & \text{gd}y \ x \geq 0 \\ -1 & \text{gd}y \ x < 0 \end{cases} \quad (4)$$

Przykładową procedurę generującą w Matlab-ie funkcję sgn przedstawiono na rys. 5.



Rys. 5. Przykład generowania funkcji sgn w Matlab-ie

- ciągła

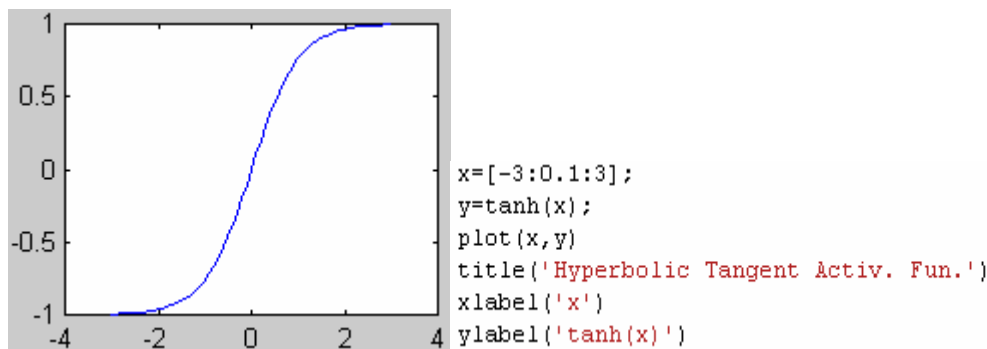
- funkcja *sigmoidalna bipolarna*:

$$f(x) = \frac{2}{1 + e^{-\beta x}} - 1, \beta > 0 \quad (5)$$

- funkcja *tangens hiperboliczny*:

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (6)$$

Przykładową procedurę generującą w Matlab-ie funkcję tangens hiperboliczny przedstawiono na rys. 6.



Rys. 6. Przykład generowania funkcji tangens hiperboliczny w Matlab-ie

c) radialne

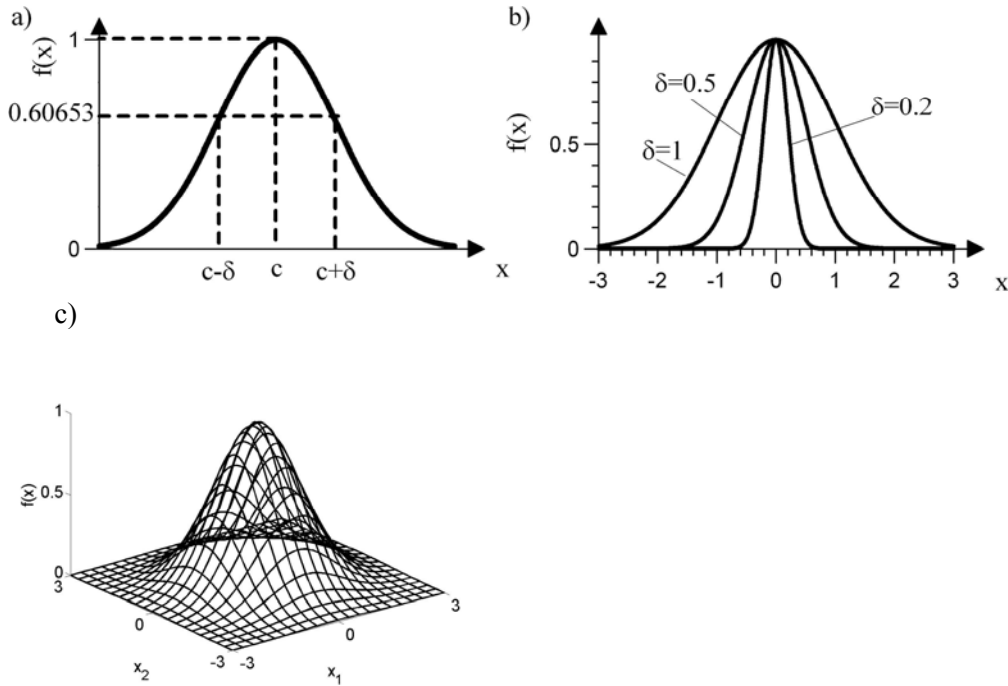
Specjalną odmianę sieci stanowią sieci o radialnej funkcji aktywacji neuronów, w której neuron ukryty realizuje funkcję zmieniającą się radialnie wokół wybranego centrum \mathbf{b} . Funkcje takie, oznaczane ogólnie w postaci $\varphi(\|\mathbf{x} - \mathbf{b}\|)$, są nazywane radialnymi funkcjami aktywacji neuronów. Szczególnym przypadkiem funkcji radialnej jest symetryczna funkcja Gaussa (pokazana na rys. 7.), wyrażona wzorem:

$$f(\mathbf{x}) = \exp\left(-\sum_{i=1}^p (x_i - b_i)^2 / 2\delta_i^2\right), \quad (7)$$

gdzie: $\mathbf{x} = [x_1, \dots, x_p]^T$ - wektor wejściowy,

$\mathbf{b} = [b_1, \dots, b_p]^T$ - wektor współrzędnych położenia centrum,

$\boldsymbol{\delta} = [\delta_1, \dots, \delta_p]^T$ - wektor wariancji (odchyień) wzdłuż poszczególnych osi zmiennych x_i .



Rys. 7. Funkcje Gaussa: a) parametry funkcji Gaussa, b) funkcje Gaussa dla wybranych wartości współczynnika δ , c) dwuwymiarowa funkcja Gaussa

3. Struktury sieci neuronowych

Istnieją różne kryteria podziału sieci neuronowych, jednym z najczęściej stosowanych jest kryterium dotyczące ilości warstw adaptowanych wag sieci, względem którego można wyróżnić sieci:

- jednowarstwowe, z uczoną warstwą wag wejściowych do sieci, lub wyjściowych z sieci, np. sieci *RVFL*, *RBF*,
- sieci dwuwarstwowe,
- sieci wielowarstwowe.

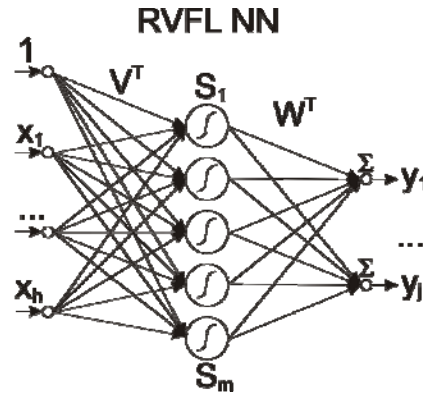
3.1. Sieci jednowarstwowe na przykładzie sieci *RVFL*

Sieć neuronowa typu *RVFL* jest siecią z losowym doбором wag warstwy wejściowej do sieci, z sigmoidalnymi funkcjami aktywacji neuronów. Wartość wyjścia z SN można opisać zależnością

$$y = \hat{f}(\mathbf{x}) = \mathbf{W}^T \mathbf{S}(\mathbf{V}^T \mathbf{x}_v) \quad (8)$$

gdzie $y = \hat{f}(\mathbf{x})$ wartość wyjścia z SN (estymata funkcji $f(\mathbf{x})$), \mathbf{V} to macierz stałych wag warstwy wejściowej, $\mathbf{x}_v = [1, \mathbf{x}^T]^T$ to wektor zmiennych wejściowych do sieci *RVFL*, \mathbf{W} to wektor wag warstwy wyjściowej (w przypadku SN o wielu wyjściach \mathbf{W} jest macierzą).

Taka sieć jest liniowa ze względu na wagi i jest uniwersalnym aproksymatorem. W sieciach jednowarstwowych uczeniu podlegają jedynie wagi warstwy wyjściowej \mathbf{W} . Schemat sieci neuronowej *MIMO* (ang. *Multi Input Multi Output*) *RVFL* o h wejściach, j wyjściach, oraz m neuronach w warstwie ukrytej przedstawiono na rys. 8.



Rys. 8. Schemat SN typu *RVFL*

Funkcje aktywacji neuronów dla sieci *RVFL* są wybierane jako funkcje sigmoidalne:

- unipolarne:

$$S(x_v) = \frac{1}{1 + \exp(-\beta V^T x_v)}, \quad (9)$$

- bipolarne:

$$S(x_v) = \frac{2}{1 + \exp(-\beta V^T x_v)} - 1, \quad (10)$$

gdzie β jest współczynnikiem, który determinuje nachylenie funkcji sigmoidalnej w punkcie przegięcia. Ze wzrostem tego współczynnika nachylenie funkcji zwiększa się i przy $\beta = 10$ funkcja sigmoidalna unipolarna ma charakter prawie skokowy.


W celu uniknięcia pracy sieci w obszarze nasycenia funkcji sigmoidalnych zaleca się losowanie wag macierzy V z przedziału $V_{hm} \in \langle -0.5; 0.5 \rangle$.

Założenie ciągłej funkcji aktywacji umożliwia zastosowanie w uczeniu metody gradientowej. Zwykle przyjmuje się metodę największego spadku, zgodnie z którą aktualizacja wag odbywa się w kierunku ujemnego gradientu funkcji energetycznej.

Przykład 1. Obliczanie wartości wyjścia z SN *RVFL*

Zajmiemy się teraz wyznaczeniem wartości wyjścia \hat{y} z SN *RVFL* opisaną zależnością (8), dla SN zbudowanej z $m=1$ neuronu o sigmoidalnej bipolarnej funkcji aktywacji (10), wagach warstwy wejściowej V dobranych losowo w procesie inicjalizacji SN oraz stałej wartości wagi warstwy wyjściowej W (przypadek sieci statycznej z wyuczonymi wagami). Schematycznie proces obliczania wartości wyjścia z SN *SISO (Single Input Single Output) RVFL* przedstawiono na rys. 9. Sigmoidalne bipolarne funkcje aktywacji neuronu S_1 realizuje obliczenia

$$S_1(x_v) = \frac{2}{1 + \exp\left(-1 \cdot \left(\begin{bmatrix} 0.27, -0.11 \end{bmatrix} \begin{bmatrix} 1 \\ x_{SN} \end{bmatrix} \right)\right)} - 1. \quad (11)$$

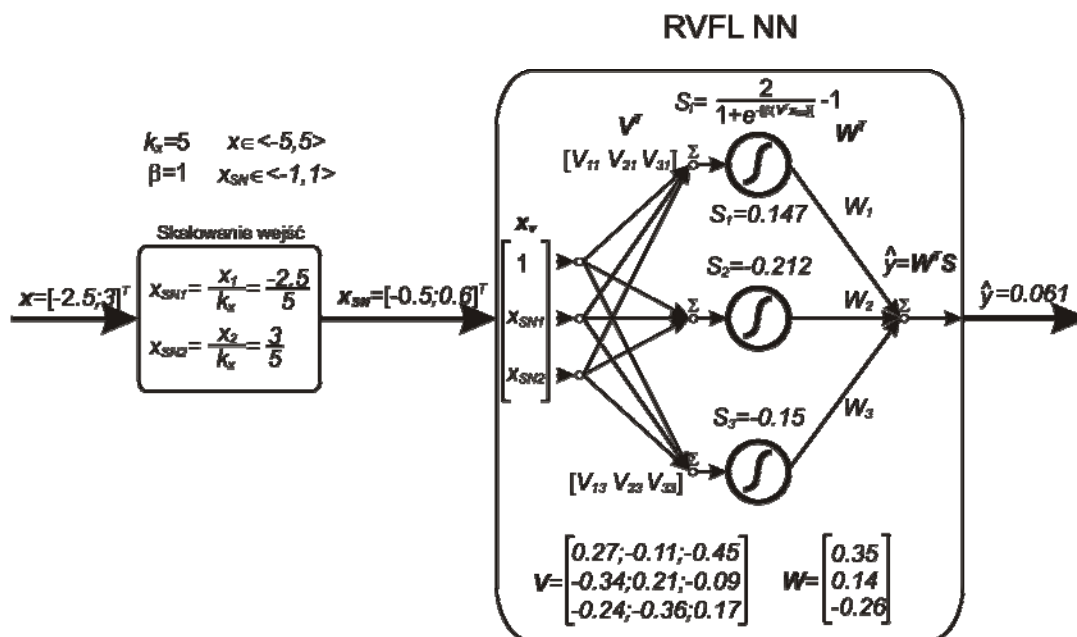


Rys. 9. Schemat działania SN SISO RVFL dla 1 neuronu

Wartość wyjścia z SN RVFL wynosi: $\hat{y} = 0.0462$.

Przykład 2. Obliczanie wartości wyjścia z SN RVFL MISO

Zajmiemy się teraz wyznaczaniem wartości wyjścia \hat{y} z SN RVFL MISO (*Multi Input Single Output*) dla danych analogicznych jak w przykładzie 1., dla SN zbudowanej z $m=3$ neuronów o sigmoidalnych bipolarnych funkcjach aktywacji, oraz dwóch wejściach $x = [x_1, x_2]^T$ (rys. 10.).



Rys. 10. Schemat działania SN MISO RVFL dla 3 neuronów

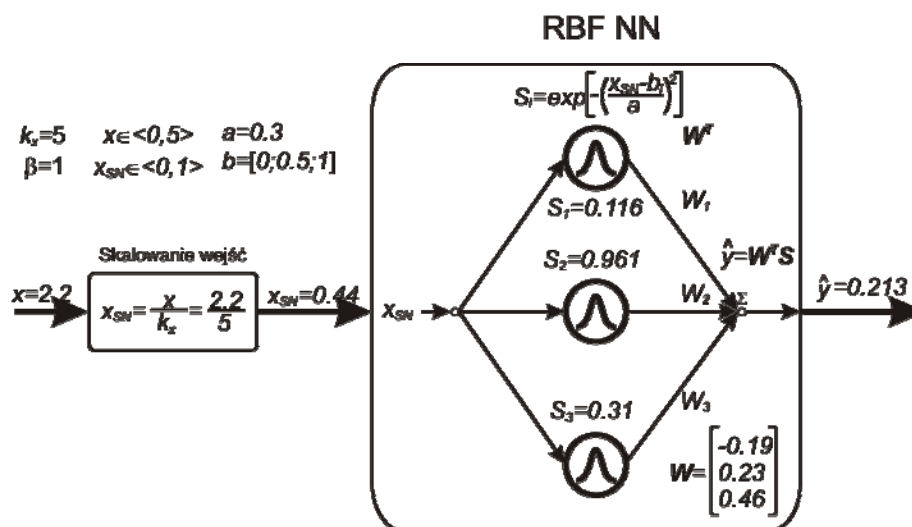
Wartość wyjścia z SN RVFL wynosi: $\hat{y} = 0.061$.

Przykład 3. Obliczanie wartości wyjścia z SN RBF SISO

Zajmiemy się teraz wyznaczaniem wartości wyjścia \hat{y} z SN RBF SISO (*Single Input Single Output*) dla SN zbudowanej z $m=3$ neuronów o funkcjach aktywacji typu krzywa Gaussa oraz jednym wejściu. Funkcję aktywacji i -tego neuronu SN typu Gaussa możemy zapisać za pomocą zależności

$$S_i(x) = \exp \left[- \left(\frac{x - b_i}{a_i} \right)^2 \right], \tag{12}$$

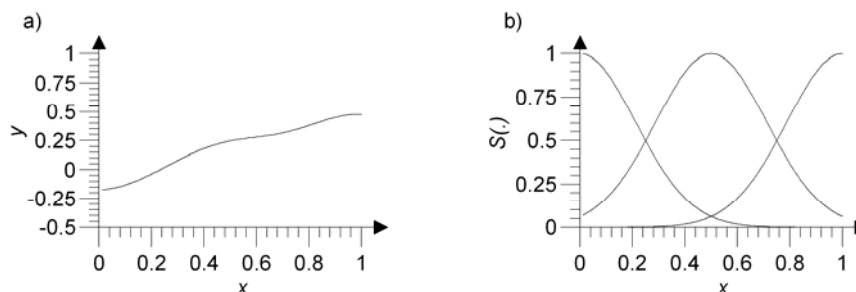
gdzie a_i jest parametrem określającym szerokość krzywej gaussowskiej dla i -tego neuronu, natomiast b_i parametrem określającym położenie środka krzywej. Schemat działania sieci z radialnymi funkcjami aktywacji neuronów przedstawiono na rys. 11.



Rys. 11. Schemat działania SN SISO RBF dla 3 neuronów

Wartość wyjścia z SN RVFL wynosi: $\hat{y}=0.213$.

W wyniku działania sieci dla całego zbioru wejść $x_{SV} \in \langle 0;1 \rangle$ otrzymano wartości wyjścia z SN pokazane na rys. 12.a). Na rys. 12.b) pokazano przebiegi wartości funkcji aktywacji typu Gaussa poszczególnych neuronów.



Rys. 12.a) Przebieg wartości wyjścia z SN, b) przebiegi wartości funkcji aktywacji neuronów

4. Zadania do wykonania

4.1. Wyznaczyć przebiegi wartości funkcji aktywacji neuronu:

- liniowego,
 - dyskretnego unipolarnego,
 - dyskretnego bipolarnego,
 - ciągłego unipolarnego (funkcja sigmoidalna unipolarna, $\beta=nr$ zespołu),
 - ciągłego bipolarnego (funkcja sigmoidalna bipolarna, $\beta=nr$ zespołu),
 - radialnego (funkcja Gaussa dla $b=0$, $\delta=nr$ zespołu),
- dla $x \in \langle -2, 2 \rangle$ (oprócz punktu 4.1.f), gdzie przedział zmienności wejścia x jest dowolny), przykłady należy zrealizować w postaci *m*-pliku Matlab-a oraz modelu Simulink-a.

4.2. Wyznaczyć przebiegi wartości wyjścia z SN (analogicznie jak w przykładzie 3, rys. 12.), dla:

Katedra Mechaniki Stosowanej i Robotyki

Wydział Budowy Maszyn i Lotnictwa, Politechnika Rzeszowska

a) SN *SISO RVFL*, dla $x \in \langle 0, 5 \rangle$, liczby neuronów sieci dla poszczególnych zespołów przyjąć zgodnie z danymi podanymi w tab. 1., wagi warstwy wejściowej V oraz wyjściowej W dobrać w sposób losowy z przedziału $\langle -0.5; 0.5 \rangle$,

b) SN *SISO RBF*, dla $x \in \langle 0, 5 \rangle$, liczby neuronów sieci dla poszczególnych zespołów przyjąć zgodnie z danymi podanymi w tab. 1., centra neuronów radialnych rozmieścić równomiernie w przestrzeni wejść, np. dla 8 neuronów radialnych położenia centrów funkcji mogą przyjmować wartości $\mathbf{b} = [0, 1/7, 2/7, \dots, 7/7]$, odpowiednio dobrać współczynnik szerokości funkcji Gaussa (patrz wykład), wagi warstwy wyjściowej W dobrać w sposób losowy z przedziału $\langle -0.5; 0.5 \rangle$.

Parametry SN dla poszczególnych zespołów przedstawiono w tab. 1.

Tab.1. Parametry SN dla poszczególnych zespołów

nr zespołu	1.	2.	3.	4.	5.	6.	7.	8.	9.	10.	11.	12.	13.	14.	15.
$m=l_{neur}$	6	7	5	8	9	10	12	6	8	7	9	11	5	4	8

Sprawozdanie powinno zawierać:

- opis matematyczny rozwiązywanego problemu,
- dane przyjęte w symulacji,
- listingi programów,
- otrzymane wykresy (każdy wykres powinien być opisany i skomentowany),
- wnioski.