

# **METODY SZTUCZNEJ INTELIGENCJI**

## **Laboratorium nr 1**

Temat: **Funkcje aktywacji neuronów, struktury sieci neuronowych**

## 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 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

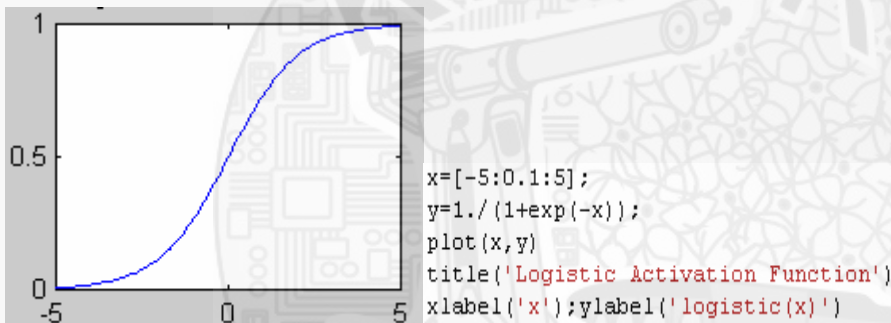
- dyskretna - *skok jednostkowy*:

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

- 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.

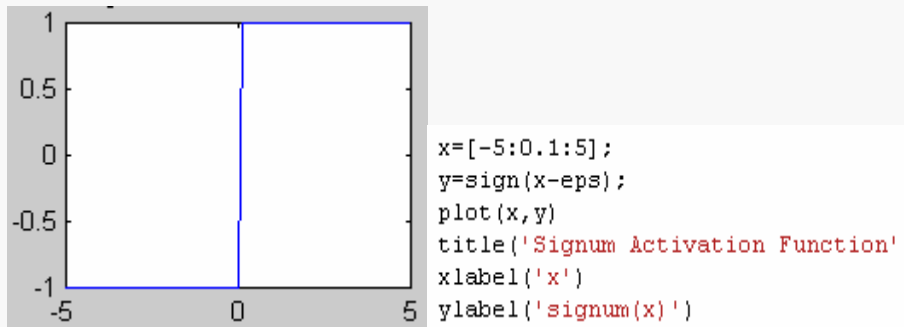


Rys. 4. Bipolarne funkcje aktywacji

- 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

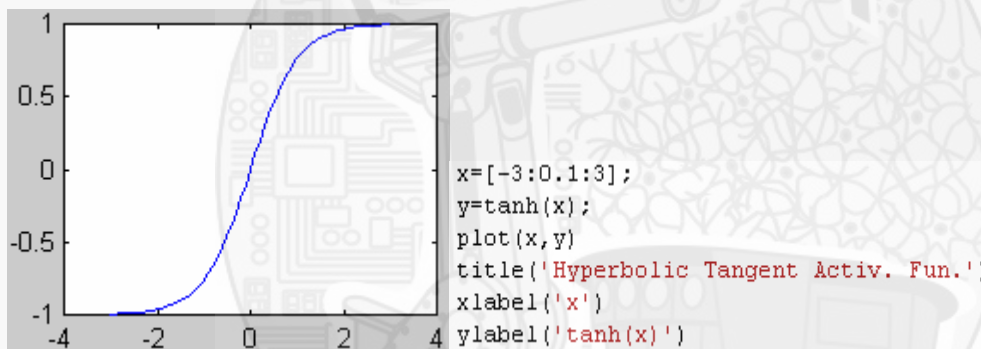
- funkcja *sigmoidalna bipolarna*:

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

- 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

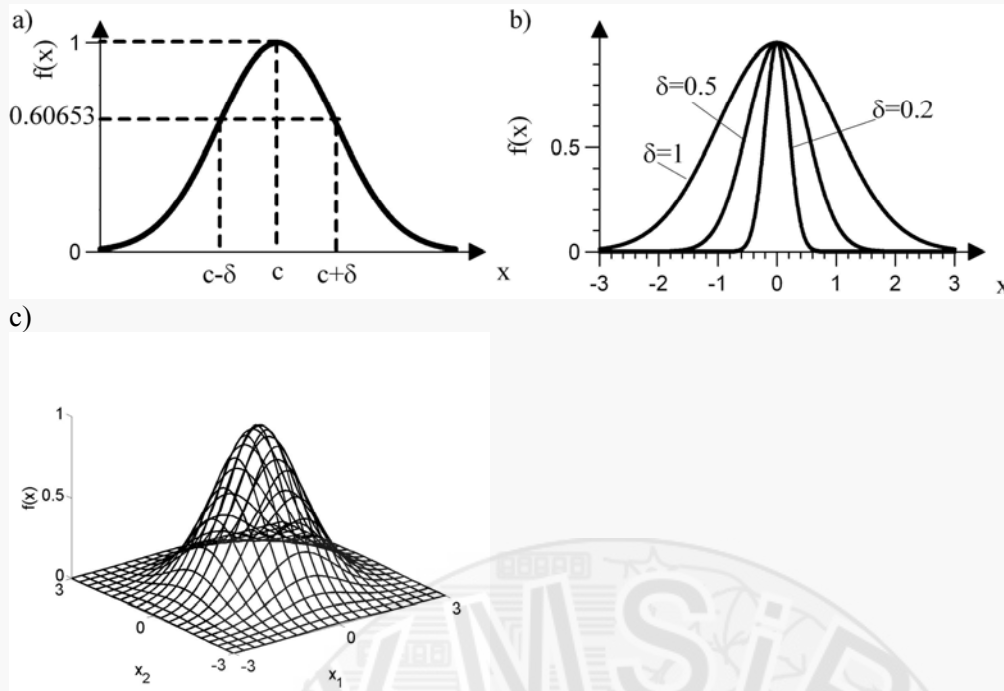
Specjalną odmianę sieci stanowią sieci o radialnej funkcji aktywacji neuronów, w której neuron ukryty realizuje funkcję zmieniającą się radialnie wokół wybranego centrum  $\mathbf{b}$ . Funkcje takie, oznaczane ogólnie w postaci  $\varphi(\|\mathbf{x} - \mathbf{b}\|)$ , są nazywane radialnymi funkcjami 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  $\delta$ , 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.

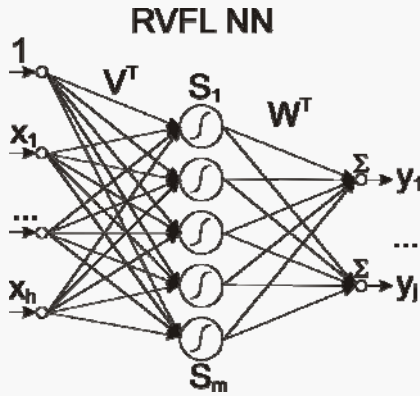
#### 3.1. Sieci jednowarstwowe na przykładzie sieci *RVFL*

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  $\beta$  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* opisanej 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 funkcja aktywacji neuronu  $S_1$  realizuje obliczenia

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

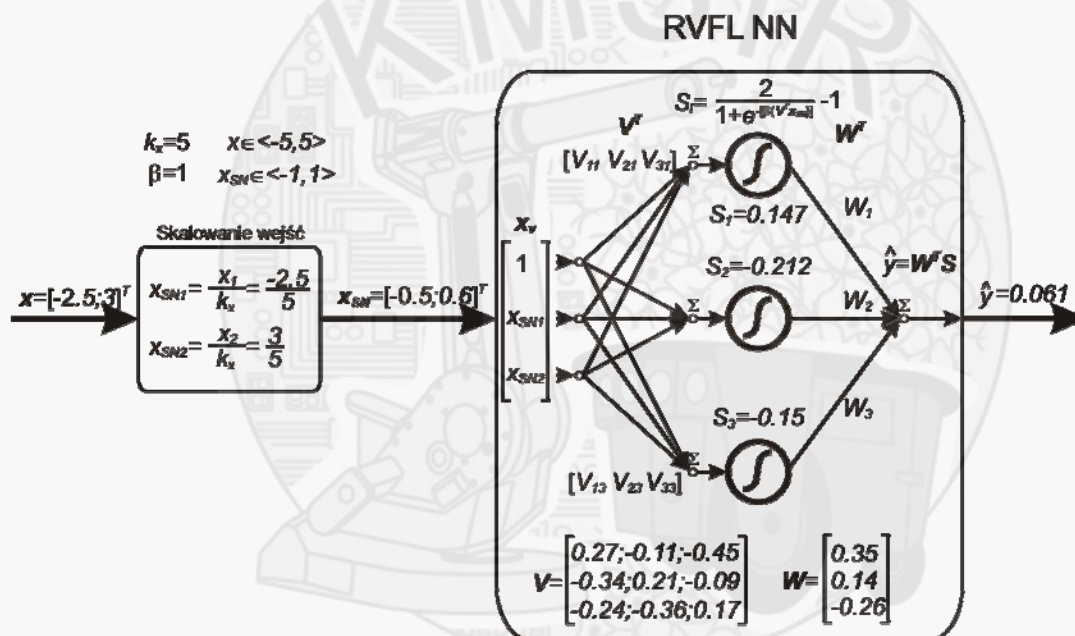


Rys. 9. Schemat działania SN SISO RVFL dla 1 neuronu

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:  $\hat{y} = 0.061$ .

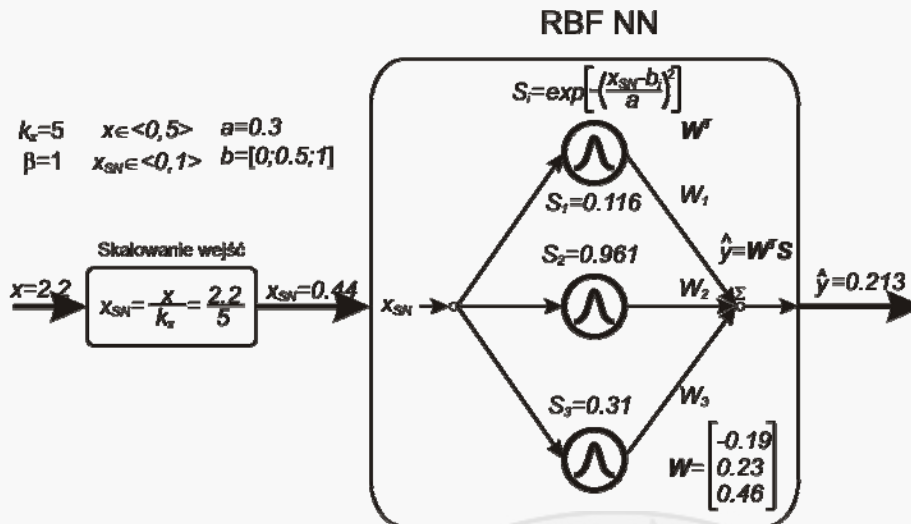
**Przykład 3.** Obliczanie wartości wyjścia z SN RBF SISO

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  $x_{SN} \in \langle 0;1 \rangle$  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:

a) SN SISO RVFL, dla  $x \in \langle 0,5 \rangle$ , liczby neuronów sieci dla poszczególnych zespołów przyjmując zgodnie z danymi podanymi w tab. 1., wagi warstwy wejściowej  $V$  oraz wyjściowej  $W$  dobrac 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 przyjmując 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  $b=[0$ ,



$1/7, 2/7, \dots, 7/7]$ , 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:**

1. Wstęp teoretyczny

- podstawowe wiadomości na temat funkcji aktywacji neuronów,
- podstawowe wiadomości na temat struktur SN.

2. Przebieg ćwiczenia

- przykładowy listing kodu Matlab-a służący do wygenerowania przebiegów poszczególnych funkcji aktywacji neuronów (4.1) wraz z wykresami,
- obrazy modeli Simulink-a realizujących przykłady z punktu (4.1),
- przykładowy listing kodu Matlab-a służący do wygenerowania wyjścia z SN dla zadanych struktur sieci (4.2.), wykresy przebiegu wartości wyjścia z sieci oraz funkcji aktywacji neuronów (analogicznie jak na rys. 13),
- obrazy modeli Simulink-a realizujących przykłady z punktu (4.2).

3. Wnioski

Uwaga. Każdy realizowany podpunkt sprawozdania powinien być odpowiednio skomentowany.

