


Sztuczne sieci neuronowe (SNN)



SSN - podstawy

- Sieci neuronowe stosowane są do rozwiązywania problemów typu uczenie maszyn:
 - rozpoznawanie obrazów
 - Rozpoznawanie mowy itp.
- Cecha:

Zdolność automatycznego uczenia się poprzez adaptację swojej struktury i jej właściwości do stawianego sieci zadania

Podział sieci ze względu na charakter problemu

- Uczenie nienadzorowane,
- Uczenie z krytykiem
- Uczenie nadzorowane
- Autoasocjacja

Uczenie nienadzorowane

□ analiza skupień, klasteryzacja, grupowanie danych

- Ucząc model nie wiemy nic o tym czego czego mamy się nauczyć

przykład: sieci samoorganizujące się Kohonena,

Przykład: Czytając różne książki nie wiemy co się na ich podstawie nauczymy ale na pewno czegoś się nauczymy.

Przykład: Mając dane dotyczące różnych kwiatów np. irysów (długości i szerokości kielicha oraz długości i szerokości płatków) chcemy się dowiedzieć iloma różnymi odmianami irysa dysponujemy

Uczennice

□ analiza danych

■ Uczennice mają

przykłady

Przykłady

się nawiązują do czegoś

Przykłady

np. i

długość

dowiadujemy

dysponujemy



Az Ap – SDB



Captured Spirit – SDB



Llana – SDB



Child Star – BB



Very Varied – BB



Baboon Bottom – BB



Basso – IB



Blue Eyed Blond – IB



Gnu Rayz – IB



Chickee – MTB



Ozark Sky – MTB



Welch's Reward – MTB

owanie

o czego

honena,

ny co

ewno

kwiaków

ha oraz

ę

rysa

Uczenie nadzorowane

Uczymy się na przykładach które już ktoś rozwiązał i próbujemy zrozumieć jak zostały rozwiązane, by później samemu móc rozwiązywać podobne zadania

- Problemy regresyjne – gdy nasz cel uczenia daje się zapisać jako liczba rzeczywista (np.. Cena itp)
 - Na podstawie położenia lokalu, jego powierzchni, wieku itp. Dokonać automatycznej wyceny tegoż lokalu (Boston houses)
 - Na podstawie analiz rynku przewidzieć zmiany wartości akcji przedsiębiorstwa
- Problemy klasyfikacyjne – gdy nasz celu uczenia jest czymś co nie jest liczbą, jest symbolem (np. typ choroby, gatunek roślin itp)

TECHWIG
618,42

MIDWIG
1718,48

WIG20
1833,29

WIG20

PKO BP S.A.

103 585 207
-0,43%

37 249 253
-0,20%

309 578 900
-0,05%

Symbol	Kurs wyc.	Kurs	Diff. %
CDT	113,00	121,00	7,08
DEUT	165,95	158,00	-4,82
IBM	116,90	128,00	9,47
INTEL	48,00	49,00	2,08
MSFT	42,00	40,00	-4,76
ORCL	38,00	37,00	-2,63
AMZN	61,00	51,00	-16,39
GOOGL	21,00	21,00	0,00
FB	100,00	101,00	1,00
SPY	30,00	30,00	0,00
QQQ	250,00	264,00	5,60

9
2
9

WIG
25521,35

451 822 212
-0,13%

40
10
45



WARTOŚĆ OBROTÓW
Cały rynek

PKO 24,50

3 287 793 286

2 780 400 586



FW20Z4

1848,00

-0,48%

OW20L4180

80,00

1,91%

OW20X4150

1,00

1150,00%

PKM 127,00

11 308 000

-0,78%

19,51%

Uczenie nadzorowane

Uczymy się na przykładach które już ktoś rozwiązał i próbujemy zrozumieć jak zostały rozwiązane, by później samemu móc rozwiązywać podobne zadania

- Problemy regresyjne – gdy nasz cel uczenia daje się zapisać jako liczba rzeczywista (np.. Cena itp)
 - Na podstawie położenia lokalu, jego powierzchni, wieku itp. Dokonać automatycznej wyceny tegoż lokalu (Boston houses)
 - Na podstawie analiz rynku przewidzieć zmiany wartości akcji przedsiębiorstwa
- Problemy klasyfikacyjne – gdy nasz celu uczenia jest czymś co nie jest liczbą, jest symbolem (np. typ choroby, gatunek roślin itp)
 - Na podstawie zawartości alkoholu, kwasowości, zawartości fenoli, intensywności koloru itp. odgadnąć producenta wina spośród trzech producentów z tego samego regionu Włoch (wine)
 - Na podstawie analiz medycznych przewidzieć czy pacjentka cierpi na raka piersi czy nie



Uczenie z krytykiem

Uczenie gdy jedyną dostępną informacją o tym co nauczyliśmy się jest typu „nagroda/kara”.

W pewnym sensie odmiana uczenia pod nadzorem gdzie nie jest znana wielkość popełnionego błędu a jedynie informacja typu „prawda – fałsz”

Przykład:

- Uczenie robota chodzenia – przewróci się (-) nie przewrócił się (+)
- Strategie przetrwania dla systemów agentowych – przeżył (+), zginął (-)



Analiza koszykowa -> asocjacja

Problemy asocjacyjne to problem typu „co wiąże się z czym” przykład – sieci Hopfielda

- Przykładowe zastosowania – socjo-marketing

idąc do sklepu co jeszcze kupujemy kupując paluszki słone. Innymi słowy z czym wiążą się paluszki podczas zakupów np. piwo

Anali

Proble
wiąże
Hopfi

■ Prz

ida
pal
pal




acja

1 „CO

keting

pując
ażą się


Budowa neuronu – neuron biologiczny



Budowa neuronu – neuron liniowy

□ Wg. McCullocha i Pittsa:

$$z = \sum_{i=1}^N w_i x_i + b,$$



Gdzie:

w_i – i -ta waga


x_i – i -te neuronu (dendryt)

z – wyjście neuronu (akson)

b – wolny dendryt do niczego nie podłączony

Budowa neuronu – neuron nieliniowy typu perceptron

$$y = f\left(\sum_{i=1}^N w_i x_i + b_i\right).$$



Gdzie:

w_i – i -ta waga

x_i – i -te neuronu (dendryt)

z – wyjście neuronu (akson)



b – wolny dendryt do niczego nie podłączony

f – nieliniowa funkcja aktywacji neuronu

nieliniowy funkcje aktywacji

- Binarna: unipolarna i bipolarna (Perceptron Rosenblatta)



$$f(z) = \begin{cases} 0 & \text{dla } z \leq 0 \\ 1 & \text{dla } z > 0 \end{cases}$$



- Ciągła:
 - Sigmoidalny – również nazywany nercentronem

$$f(z) = \frac{1}{1 + \exp(-\beta z)}$$

$$j f(z) = \text{tgh}(\beta z)$$



nieliniowy

funkcje aktywacji - cd

- Neurony radialne (lokalnym charakter działania)

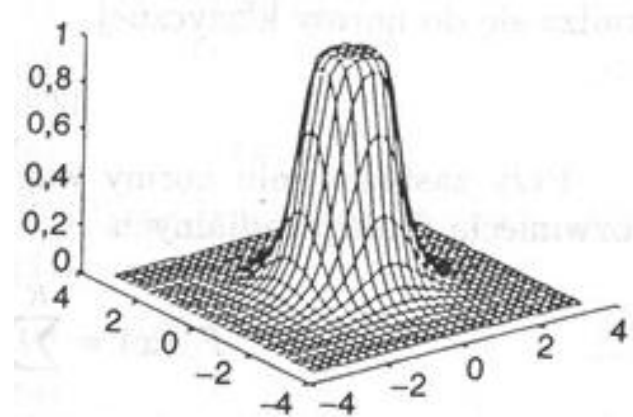


- Gaussowski $f(z) = \exp\left(-\frac{z^2}{2\sigma^2}\right)$

- Wielomianowy $f(z) = z^2 + \sigma^2$

- Hardyego $f(z) = \frac{1}{z^2 + \sigma^2}$

$$\mathbf{z} = \|\mathbf{x} - \mathbf{t}\| \quad \text{np. } z = \sqrt{\sum_i (x_i - t_i)^2}$$

Gdzie





Architektury sieci neuronowych

Typy architektur:

- sieci jednokierunkowe (feedforward networks) – sieci o jednym kierunku przepływu sygnałów
- sieci rekurencyjne – sieci ze sprzężeniem zwrotnym
- sieci komórkowe

Sieci jednokierunkowe



i – numer elementu warstwy wejściowej ($i=1,2,\dots,m$),

j – numer elementu warstwy wyjściowej ($j=1,2,\dots,n$),

h – numery kolejnych warstw ukrytych ($h=1,2,\dots,H$),

w_{k_{h-1}, k_h}^h – waga połączenia pomiędzy elementami k_{h-1} -tym, a k_h -tym odpowiednio w warstwach $(h-1)$ -szej i h -tej.

Sieci jednokierunkowe – cd.

Wynikiem przetwarzania pojedynczej warstwy takiej sieci jest:

$$N_h(\mathbf{u}_h) = F(\mathbf{W}^h \mathbf{u}_h)$$

Gdzie:

$N_h(\mathbf{u}_h)$ – operator przetwarzania neuronowego h-tej warstwy

\mathbf{W}^h – macierz współczynników wag połączeń pomiędzy warstwami (h-1) i (h)

Natomiast całą sieć można opisać jako:

$$\begin{aligned} \mathbf{y} = N(\mathbf{u}) &= F_{wyj}(\mathbf{W}^{wyj} F_H(\mathbf{W}^H F_{H-1}(\mathbf{W}^{H-1} F_{H-2}(\dots \mathbf{W}^2 F_1(\mathbf{W}^1 \mathbf{u}) \dots)))) = \\ &= N_{wyj}(N_H(N_{H-1}(\dots N_1(\mathbf{u}) \dots))) \end{aligned}$$

Gdzie:

\mathbf{y} – wektor wartości wyjściowych $\mathbf{y} = [y_1, y_2, \dots, y_n]^T$

\mathbf{u} – wektor wartości wejściowych $\mathbf{u} = [u_1, u_2, \dots, u_m]^T$

F_{wyj} – operator aktywacji neuronów warstwy wyjściowej

N_{wyj} – operator przetwarzania neuronów warstwy wyjściowej

\mathbf{W}_{wyj} – macierz współczynników wag połączeń pomiędzy warstwami H-tą a wyjściową

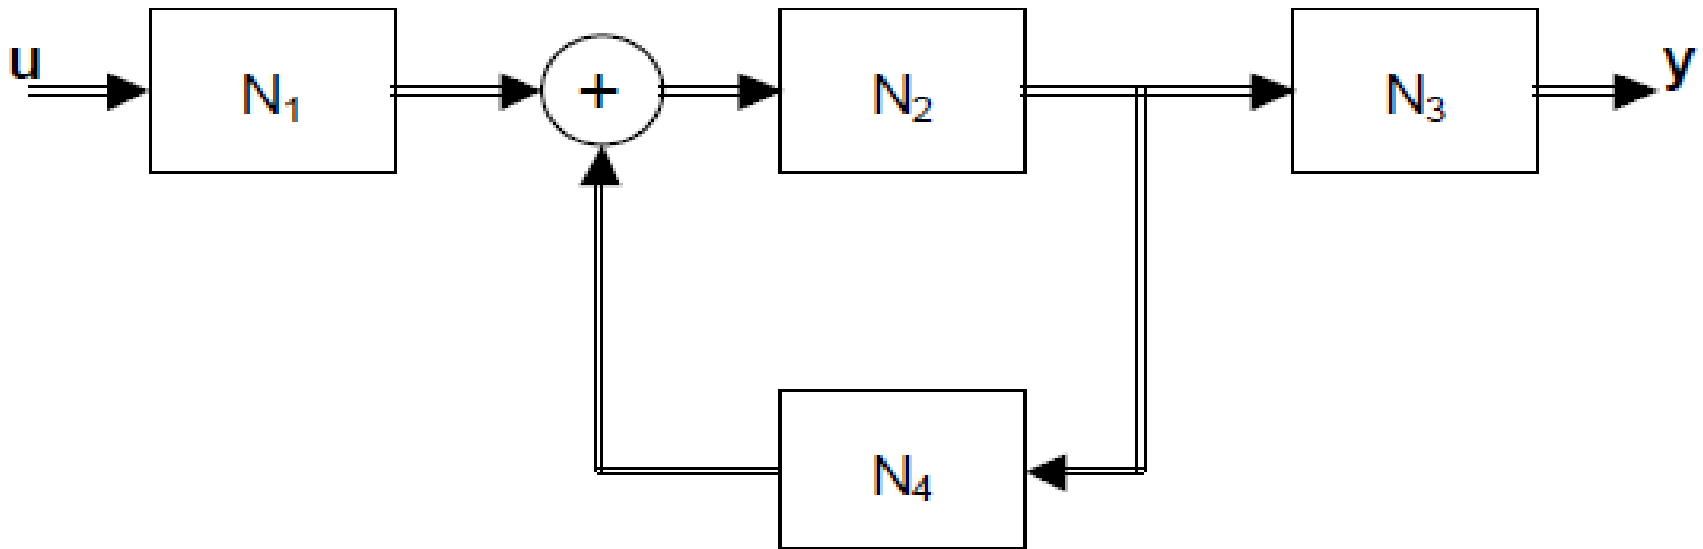
Przykłady:

perceptron wielowarstwowy (dowolna ilość warstw, najczęściej 3),

RBF (dwie warstwy)

Sieci ze sprzężeniem zwrotnym

$N_1 - N_4$ – bloki reprezentujące grupy neuronów

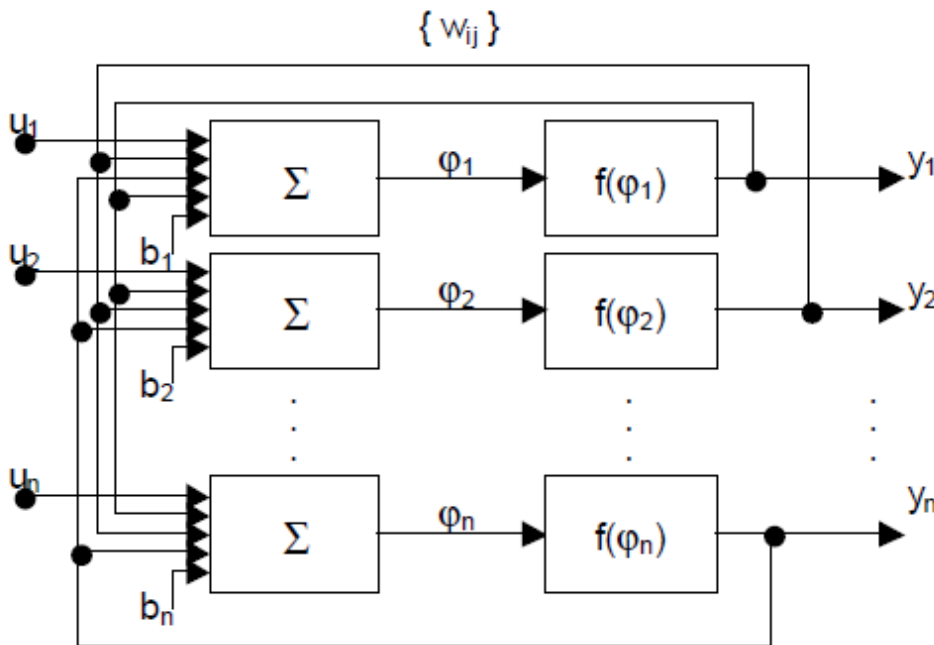


Sieci ze sprzężeniem zwrotnym

Np.. Sieć Hopfielda,

$$y_i(k+1) = 1 \left(\sum_{j=1}^n w_{ij} y_j(k) + b_i(k) \right), \quad y_i(0) = u_i$$

$i = 1, 2, \dots, n$



Gdzie:

k – numer kolejnej iteracji

b_i – sygnał sterowania
zewnętrznego

w_{ij} – wagi połączeń pomiędzy
 j -tym wyjściem a i -tym wejściem

Sieci komórkowe

Sprzężenia i współpraca pomiędzy sąsiednimi neuronami sieci

Przykład: mapy Kochonena, LVQ

