

Neurony biologiczne i ich implementacje

dr inż. Jacek Czerniak
jczerniak@ukw.edu.pl

[prof. zw. dr hab. inż. Ryszard Tadeusiewicz]



- ur. 05.05.1947, Środa Śląska
- 02.04.1971 mgr inż. elektryk
- 29.04.1975 dr nauk technicznych
- 28.04.1980 dr hab. nauk technicznych w zakresie automatyki
- 01.02.1986 prof. nauk technicznych
- Doktor Honoris Causa - 9(4) uczelni
- autor ok. 700 publikacji
- autor lub współautor 72 książek
- redaktor 17 książek
- promotor 55 doktoratów
- recenzent jawny 82 rozpraw habilitacyjnych
- recenzent jawny 72 wniosków profesorskich

Elementarne wprowadzenie do techniki sieci neuronowych
z przykładowymi programami (książka w Internecie)

10.12.2013

<http://winntbg.bg.agh.edu.pl/skrypty2/0263/>

[Nagrody Nobla związane z badaniami układu nerwowego]

- 1904 - Pavlov I.P. - teoria odruchów warunkowych**
- 1906 - Golgi C., - badanie struktury układu nerwowego**
- 1906 - Ramón Y Cajal S. - odkrycie, że mózg składa się z sieci oddzielnych neuronów**
- 1920 - Krogh S.A. - opisanie funkcji regulacyjnych w organizmie**
- 1932 – Sherrington Ch. S. - badania sterowania nerwowego pracy mięśni**
- 1936 – Dale H., Hallett L.O. - odkrycie chemicznej transmisji impulsów nerwowych**
- 1944 - Erlanger J., Gasser H. S. - procesy w pojedynczym włóknie nerwowym**
- 1949 - Hess W.R. - odkrycie funkcji śródmózgowia**
- 1963 - Eccles J.C., Hodgkin A.L., Huxley A.F. - mechanizm elektrycznej aktywności neuronu**
- 1969 – Granit R., Hartline H.K., Wald G. – fizjologia widzenia**
- 1970 – Katz B., Von Euler U. - transmisja informacji humoralnej w komórkach nerwowych**
- 1974 – Claude A., De Duve Ch. - badania strukturalnej i funkcjonalnej organizacji komórki.**
- 1977 – Guillemín R., Schally A., Yalow R. - badania hormonów mózgu**
- 1981 – Sperry R. - odkrycia dotyczące funkcjonalnej specjalizacji półkul mózdzku**
- 1981 – Hubel D.H., Wiesel T. - odkrycie zasad przetwarzania informacji w systemie wzrokowym**
- 1991 – Neher E., Sakmann B. - funkcje kanałów jonowych w komórkach nerwowych**

10.12.2013

Sieci neuronowe to efekt, a przyczyny są powyżej ...

Obszary mózgu i ich klasyczne funkcje

Obszar przedśrodkowy - *sterujący ruchami ciała*

Obszar zaśrodkowy -
czucie dotyku


Płaty czołowe
*Siedlisko
inteligencji?*

Spoidło wielkie
Łączy półkule

Podwzgórze
*Siedlisko uczuć
i emocji*

Zwoje potyliczne
Widzenie


Pień mózgu -
*Regulacja funkcji
całego ciała*



[Budowa i działanie mózgu]


- Objętość: 1400 cm^3
- Powierzchnia: 2000 cm^2
- Liczba neuronów: około 100 miliardów (10^{11})
- Liczba połączeń między komórkami : 10^{15} przy przeciętnym dystansie od 0.01 mm do 1 m.
- Komórki nerwowe wysyłają i przyjmują impulsy o:
 - częstotliwości: 1-100 Hz
 - czasie trwania: 1-2 ms
 - szybkości propagacji: 1-100 m/s.
- Szybkość pracy mózgu: 10^{18} operacji/s

]





Takie proporcje ma ciało człowieka, jeśli
brać pod uwagę wielkość struktur
nerwowych związanych
ze sterowaniem poszczególnymi
częściami ciała

Schematyczny rysunek neuronu




Rzeczywiste i wirtualne neurony



Oraz wizja graficzna na podstawie setek obrazów mikroskopowych




Impuls w układzie nerwowym




- bodziec działający na komórkę zmienia jej właściwości, do wnętrza napływają jony Na^+
- w chwili wyrównania ładunków depolaryzacja rozszerza się na sąsiednie odcinki błony, przesuając się wzdłuż aksonów, aż do zakończeń neuronu

[Tworzenie modelu neuronu]





- Mózg - równoległy system złożony z około 10^{11} procesorów
- Każdy procesor ma bardzo prosty program i oblicza ważoną sumę danych wejściowych pochodzących od innych procesorów, zwraca jedną liczbę będącą funkcją tej sumy
- Liczba ta przesyłana jest do innych procesorów i przez nie przetwarzana w podobny sposób (np. z różnymi funkcjami)
- Duża gęstość połączeń oznacza, że błędy niewielkiej liczby składników będą prawdopodobnie mało znaczące


Modelowanie procesów elektrycznych w neuronach



[Neurony - elementy składowe]



[Neuron McCullocha i Pittsa(1943)]



- dyskretne chwile czasu
- można zbudować dowolnie skomplikowane urządzenie cyfrowe (posługując się bramkami NOR i NAND - algebra Boole'a)


$$y^{k+1} = \begin{cases} 1 & \sum_{i=1}^n w_i x_i^k \geq T \\ 0 & \sum_{i=1}^n w_i x_i^k < T \end{cases}$$

$$x_i \in \{0,1\}$$


$$w_i \in \{-1,1\}, i = 1, 2, \dots, n$$

$$k = 0, 1, 2, \dots$$

Własności neuronu determinują: przyjęta agregacja danych wejściowych oraz założona funkcja wyjścia




W przypadku neuronu liniowego jego zachowanie daje się łatwo zinterpretować



Z neuronem liniowym (i z innymi neuronami budowanymi na jego bazie) związana jest jeszcze sprawa wyrazu wolnego w formule agregacji

Czysta agregacja liniowa: $s = \sum_{i=1}^n w_i x_i$ ma wadę, polegającą na tym, że charakterystyka neuronu **musi** tu przechodzić przez początek układu



Żeby zachować liniową postać wzoru opisującego neuron dodaje się dodatkowe **pseudo-wejście** nazywane BIAS, które zawsze dostarcza sygnał $\equiv 1$

Bogatsze możliwości daje **agregacja afiniczna** (z wyrazem wolnym w formule):

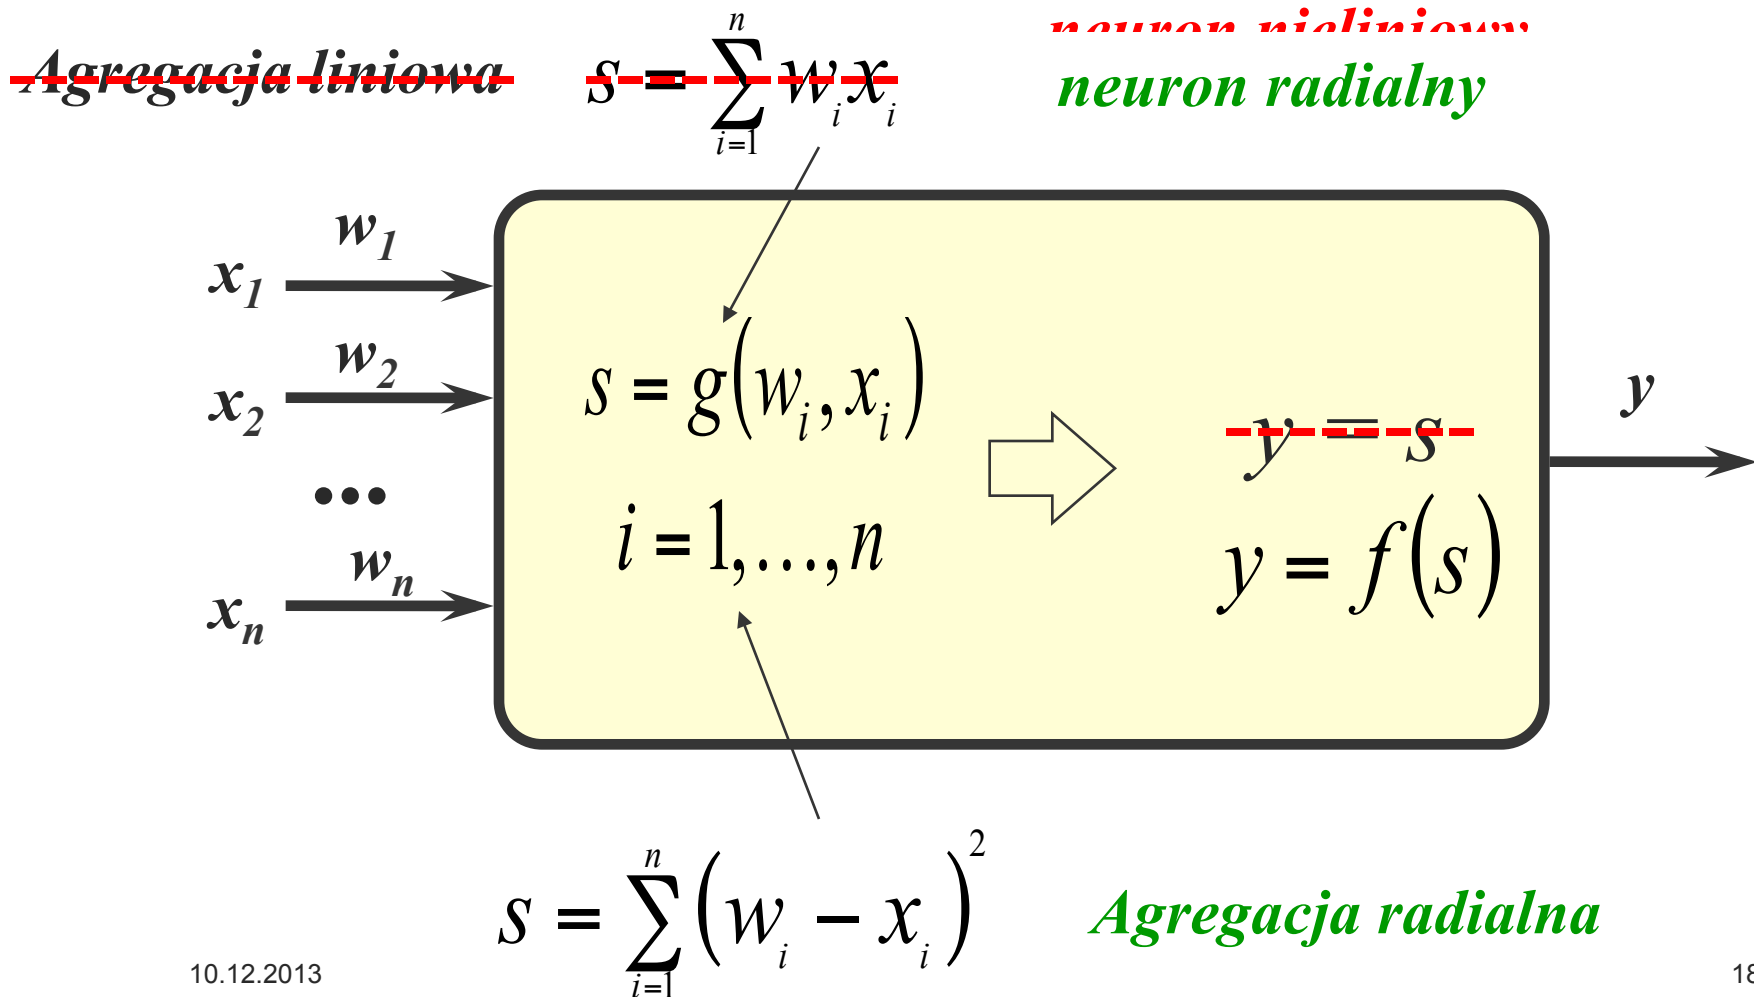
$$s = \sum_{i=1}^n w_i x_i + w_0$$

Wtedy agregacja **jest nadal** liniowa:


$$s = \sum_{i=0}^n w_i x_i$$

ponieważ zagregowany
(w taki lub inny sposób)
sygnał wejściowy może być
przetworzony przy użyciu funkcji
nieliniowej o teoretycznie
dowolnym kształcie.


Własności neuronu determinują: przyjęta
agregacja danych wejściowych oraz założona
funkcja wyjścia



Funkcje aktywacji neuronu może być dowolna, ale najczęściej stosowane są niżej podane kształty.




Wykres sigmoidy w zależności od parametru β




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

Funkcja tangens hiperboliczny ma praktycznie taki sam kształt, tylko jej wartości zmieniają się od **-1** do **+1**, a nie od **0** do **+1** jak w sigmoidzie




$$f(s) = \tanh(\beta s) = \frac{\exp(\beta s) - \exp(-\beta s)}{\exp(\beta s) + \exp(-\beta s)}$$

Nieliniowe funkcje aktywacji też
bywają różne:




Dobierając współczynniki wagowe wejść neuronu można wpływać na kształt jego nieliniowej charakterystyki!



Zapamiętajmy:

Najczęściej wykorzystywany jest taki model neuronu:




Sieć zbudowana z takich neuronów nazywana jest zwykle MLP
(*Multi-Layer Perceptron*)


Przykładowe funkcje przejścia używane przy budowie sztucznych neuronów

Funkcja	Wzór funkcji	Wzór pochodnej
Sigmoida	$f(s) = 1 / (1 + e^{-(\beta * s)})$	$f''(s) = \beta * (1 - f(s)) * f(s)$
Tangens Hiperboliczny	$f(s) = \tanh(\beta * s)$	$f''(s) = \beta (1 - f^2(s))$
Sinusoida	$f(s) = \sin(\beta * s)$	$f''(s) = \beta (1 - f^2(s))^{1/2}$
Kosinusoida	$f(s) = \cos(\beta * s)$	$f''(s) = -\beta (1 - f^2(s))^{1/2}$
$s / (1 + s)$ brak nazwy	$f(s) = (\beta * s) / (1 + \beta * s)$	$f''(s) = \beta / (1 + \beta * s) - (\beta * s) / (1 + \beta * s)^2$


Funkcje przejścia neuronu powinno się rozpatrywać jako powierzchnie w przestrzeniach wielowymiarowych




Γ




$$\sigma(I) = \frac{1}{1 + e^{-sI}}$$





Γ





$$\sigma(I) = \frac{1}{1 + e^{-sI}}$$




$$\sigma(I) = \frac{1}{1 + e^{-sI}}$$





Sieci budowane z neuronów o charakterystykach sigmoidalnych pozwalają na wydzielanie w przestrzeni sygnałów wejściowych sieci podobszarów ograniczonych skarpami „urwisk sigmoidalnych”






Każdy model budowany z pomocą sieci neuronowych klasy MLP cechuje zwykle obecność „urwisk sigmoidalnych”





Przykład zadania klasyfikacyjnego i jego rozwiązanie uzyskane z użyciem sieci MLP i techniki „urwisk sigmoidalnych”





Inne zadanie klasyfikacyjne i jego dwa rozwiązania





Stromość zboczy „urwisk”, korzystna w zadaniach typu klasyfikacyjnego, może być w zdaniach regresyjnych łagodzona odpowiednim doбором parametrów sigmoidy



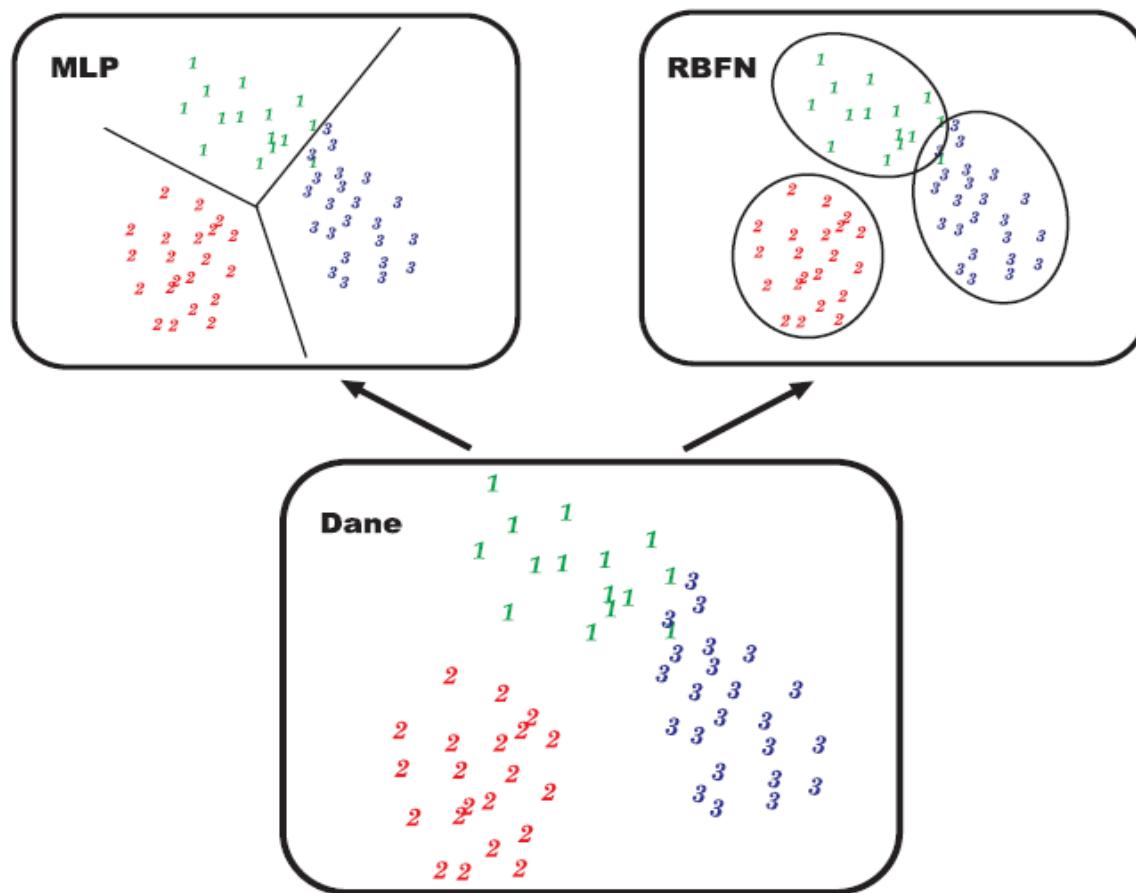
Można otrzymywać zależności w jednych rejonach bardzo ostre, a w innych – zmieniające się w sposób łagodny, zgodnie z naturą danych uczących



Urwiska sigmoidalne mogą wygradzać w przestrzeni sygnałów wyodrębnione „wyspy” otoczone urwiskami definiującymi ich rozmiar i położenie





Porównanie sieci RBF z sieciami MLP




RBF : $f_1(\mathbf{x}; \mathbf{w}) = \mathbf{w} \cdot \mathbf{G}(\mathbf{x})$

MLP : $f_2(\mathbf{x}; \mathbf{w}) = \sigma \left(\sum_{i_1} w_{i_1}^1 \sigma \left(\sum_{i_2} w_{i_2}^2 \sigma \left(\dots \sigma \left(\sum_{i_L} w_{i_L}^L x_{i_L} \right) \dots \right) \right) \right)$



W sieciach RBF funkcja przejścia ma najczęściej kształt funkcji Gaussa



Idea sieci RBF opiera się na przeświadczeniu, że pojedynczy element zbioru uczącego daje możliwość określenia pożądanego sygnału wyjściowego sieci w pojedynczym punkcie przestrzeni sygnałów wejściowych. W miarę oddalania się od tego punktu – wiemy w istocie coraz mniej.



Jednak złożenie takich elementarnych wiadomości pochodzących od różnych danych uczących pozwala wypowiadać się na temat całych rejonów przestrzeni sygnałów wejściowych



[Zalety z używania SSN]

- Brak konieczności jawnego formułowania jakichkolwiek założeń dla modeli
- Możliwość rozwiązywania problemów nie mających dobrej definicji formalnej
- Możliwość zastępowania procesu programowania oraz „ręcznego” tworzenia modelu - procesem uczenia sieci
- Możliwość pracy współbieżnej

Literatura dotycząca SSN

- Bilski J., Świąć A. (2000): Metoda wstecznej propagacji błędów i jej modyfikacje. Biocybernetyka i inżynieria biomedyczna 2000 - sieci neuronowe, tom VI, Akademicka Oficyna Wydawnicza
- Findeisen W., Szymanowski J., Wierzbicki A. (1977): Teoria i metody obliczeniowe optymalizacji. PWN
- Herz J., Krogh A., Palmer R.G. (1995): Wstęp do teorii obliczeń neuronowych. WNT,
- Jędruch W. (1996): Sztuczne sieci neuronowe, Wydawnictwo Naukowe PWN
- Korbicz J., Obuchowicz A., Uciński D. (1994): Sztuczne sieci neuronowe - Podstawy i zastosowania. Akademicka Oficyna Wydawnicza PLJ,
- Master T., (1996): Sieci neuronowe w praktyce, WNT
- Niederliński A. (1983): Systemy i sterowanie: Wstęp do automatyki i cybernetyki technicznej. PWN
- Osowski S. (1996): Sieci neuronowe w ujęciu algorytmicznym, WNT,
- Osowski S. (2000): Sieci neuronowe do przetwarzania informacji, Oficyna Wydawnicza Politechniki Warszawskiej,
- Rutkowska D., Piliński M., Rutkowski L. (1997): Sieci neuronowe, algorytmy genetyczne i systemy rozmyte, Wydawnictwo Naukowe PWN
- Tadeusiewicz R. (1993): Sieci neuronowe. Akademicka Oficyna Wydawnicza RM,
- Tadeusiewicz R. (1998): Elementarne wprowadzenie do techniki sieci neuronowych z przykładowymi programami, Akademicka Oficyna Wydawnicza PLJ,
- Żurada J., Barski M., Jędruch W. (1996): Sztuczne sieci neuronowe. Podstawy teorii i zastosowania, Wydawnictwo PWN,

[Dziękuję za uwagę]

- Zapraszam na kolejny wykład tym razem o:
- Sztucznych Sieciach Neuronowych
 - dr inż. Jacek Czerniak
 - jczerniak@ukw.edu.pl

