
Sieci Neuronowe

Wykład 1 Wstęp do Sieci Neuronowych

wykład przygotowany wg.

W. Duch, J. Korbicz, L. Rutkowski, R. Tadeusiewicz, "Sieci Neuronowe", Rozdz. 1.
Biocybernetyka i Inżynieria Medyczna, tom VI, AOFE, Warszawa 2000.

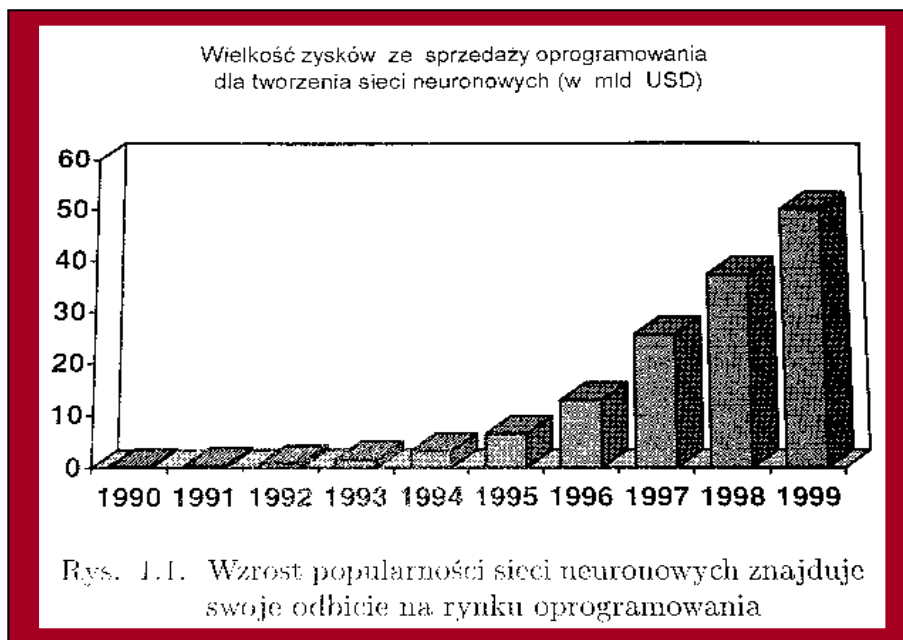
Wstęp do Sieci Neuronowych

1. Wprowadzenie
2. Biologiczne inspiracje neurokomputingu
3. Podstawowy model neuronu i sieci neuronowej
4. Działanie sieci neuronowej i jej uczenie
5. Przykład sposobu działania i procesu uczenia

Popularność sieci neuronowych

Od wielu lat bardzo dużym zainteresowaniem cieszą się sieci neuronowe, jako wygodne narzędzie przydatne do rozwiązywania bardzo wielu różnych praktycznych zadań.

Są z powodzeniem stosowane w niezwykle szerokim zakresie problemów, w tak różniących się od siebie dziedzinach jak finanse, medycyna, zastosowania inżynierskie, geologia czy fizyka.



Potencjalne zastosowania: wszędzie tam gdzie pojawiają się problemy związane z przetwarzaniem i analizą danych, z ich predykcją, klasyfikacją czy sterowaniem.

Potencjalne trudności: stabilność i wiarygodność metody.

Efektywność sieci neuronowych jako nieliniowych modeli zjawisk i procesów

Sieci neuronowe są bardzo wyrafinowaną techniką modelowania, zdolną do odwzorowywania nadzwyczaj złożonych funkcji. Mają **charakter nieliniowy**, co istotnie wzbogaca możliwość ich zastosowań.

Przez wiele lat powszechnie stosowaną techniką matematycznego opisywania różnych obiektów i procesów było **modelowanie liniowe**. Dla tego typu modeli dobrze dopracowane/znane są strategie optymalizacji przy ich budowie.

Często jednak nie ma podstaw do stosowania **aproksymacji liniowej** dla danego problemu, modele liniowe się nie sprawdzają prowadząc do zbyt szybko wyciąganych wniosków o “niemożności” matematycznego opisu danego systemu.

Wówczas odwołanie się do modeli tworzonych przy pomocy sieci neuronowych może być najszybszym i najwygodniejszym rozwiązaniem problemu. Sieci umożliwiają również kontrole nad złożonym problemem wielowymiarowości, który przy innych podejściach znacząco utrudnia próby modelowania funkcji nieliniowych z dużą ilością zmiennych.

Efektywność sieci neuronowych jako nieliniowych modeli zjawisk i procesów

Sieci neuronowe w praktyce **same konstruuja** potrzebne użytkownikowi modele, ponieważ automatycznie **uczą się** na podanych przez niego przykładach.

- użytkownik sieci gromadzi reprezentatywne dane
- uruchamia algorytm uczenia, który ma na celu wytworzenie w pamięci sieci potrzebnej struktury (modelu)
- wyuczona sieć realizuje wszystkie potrzebne funkcje związane z eksploatacją wytworzonego modelu.

Użytkownik potrzebuje pewnej (głównie empirycznej) wiedzy dotyczącej sposobu wyboru i przygotowania danych uczących, musi dokonać właściwego wyboru architektury sieci neuronowej, umieć zinterpretować wyniki... ale poziom wiedzy teoretycznej niezbędnej do skutecznego zbudowania modelu, jest przy stosowaniu sieci neuronowych znacznie niższy niż w przypadku stosowania tradycyjnych metod statystycznych.

Ludzki mózg... pierwowzór i niedościgły ideał dla badaczy sieci neuronowych.

Bardzo interesująca jest własność sieci neuronowych, wynikająca z faktu że stanowią one (w jakimś zakresie) naśladownictwo działania ludzkiego mózgu.




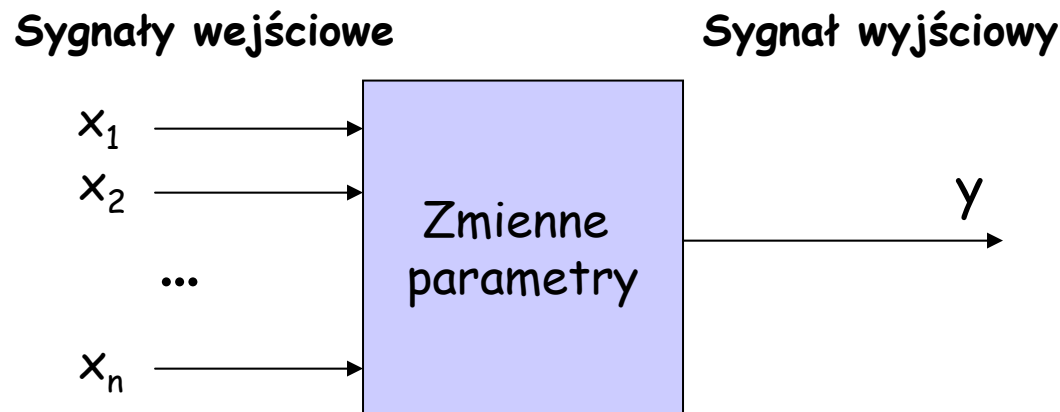
Fig. 1.2. Ludzki mózg — pierwowzór i niedościgły ideał dla badaczy sieci neuronowych

Sieci oparte są na bardzo prostym modelu, przedstawiającym wyłącznie najbardziej podstawową istotę działania biologicznego systemu nerwowego, ale który jest próbą przeniknięcia istoty jego działania. Niektórzy sądzą że rozwój modelowania neuro-biologicznego może doprowadzić do powstania prawdziwych komputerów inteligentnych, obdarzonych inicjatywą i zdolnych do samodzielnego podejmowania decyzji.

Uboczne aspekty popularności

Co powoduje że to raczej “egzotyczne” narzędzie obliczeniowe jest tak popularne? Z pewnością wykazało skuteczność ale nie należy tego stwierdzenia generalizować... może być zawodne.

Mogą być stosowane z dużym prawdopodobieństwem sukcesu tam, gdzie pojawiają się problemy z tworzeniem modeli matematycznych. Pozwalają „automatycznie”, w wyniku procesu uczenia, odwzorować różne złożone zależności pomiędzy sygnałami wejściowymi i wyjściowymi.



Moda czy metoda?

Z pewnością uzasadnione jest mówienie o sieciach neuronowych w kategoriach bardzo interesującej i nowoczesnej metody rozwiązywania problemów, o jeszcze nie do końca wyeksploatowanych możliwościach.

Technika sieci neuronowych nie jest dziś specjalną nowością.

Można przyjąć że sama dziedzina zaistniała dopiero wraz z wydaniem historycznej pracy

W. S. McCulloch, W. Pitts, *A logical calculus of the ideas immanent in nervous activity*,

Bulletin of Mathematical Biophysics, No 5, 1943, pp. 115-133.

w której po raz pierwszy pokuszono się o matematyczny opis komórki nerwowej i powiązanie tego opisu z problemem przetwarzania danych.

Mózg człowieka jako prototyp sieci neuronowej

Sieci neuronowe powstały w wyniku badań prowadzonych w dziedzinie sztucznej inteligencji, szczególne znaczenie miały prace które dotyczyły budowy modeli podstawowych struktur występujących w mózgu.

Cechy charakterystyczne dla biologicznych systemów nerwowych które mogą być szczególnie użyteczne technicznie:

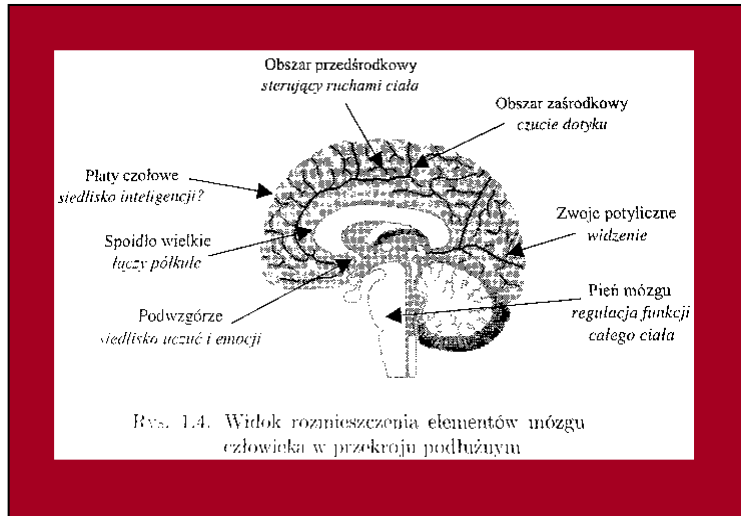
→ odporność systemów biologicznych na uszkodzenia nawet znacznej części ich elementów

→ nadzwyczajna zdolność do uczenia się

Badania przeprowadzone na polu tzw. symbolicznej sztucznej inteligencji, lata 1960-1980, doprowadziły do powstania tzw. systemów ekspertowych.

Systemy te są oparte na ogólnym modelu procesu sformalizowanego wnioskowania. Systemy te, jakkolwiek bardzo użyteczne w pewnych dziedzinach nie były w stanie naśladować pewnych elementarnych struktur w mózgu ludzkim, a tym samym wyjaśnić kluczowych aspektów inteligencji człowieka. Doprowadziło to do przekonania że, aby skonstruować system *w pełni inteligentny*, należy wzorować się na strukturze obdarzonych inteligencją systemów rzeczywistych, czyli na strukturze mózgu.

Mózg człowieka jako prototyp sieci neuronowej

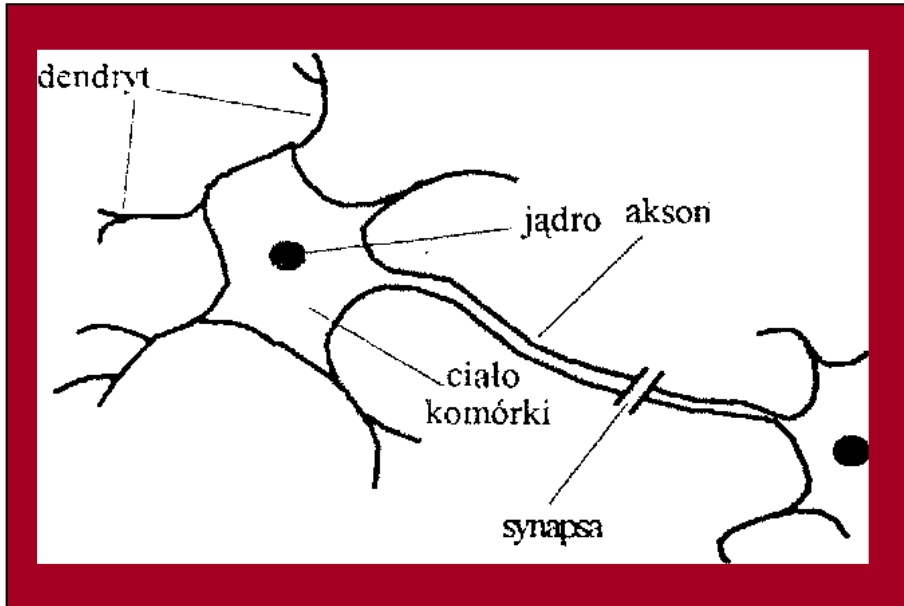


Mózg człowieka (badania anatomiczne i histopatologiczne) to przede wszystkim duża liczba elementarnych komórek nerwowych czyli neuronów.

Szacuje się na 10 mld, w większości połączonych ze sobą w formie skomplikowanej sieci.

Ustalono że średnio na jeden neuron przypada kilka tysięcy połączeń, ale dla poszczególnych komórek ilości połączeń mogą się między sobą różnić.

Modele neuronów



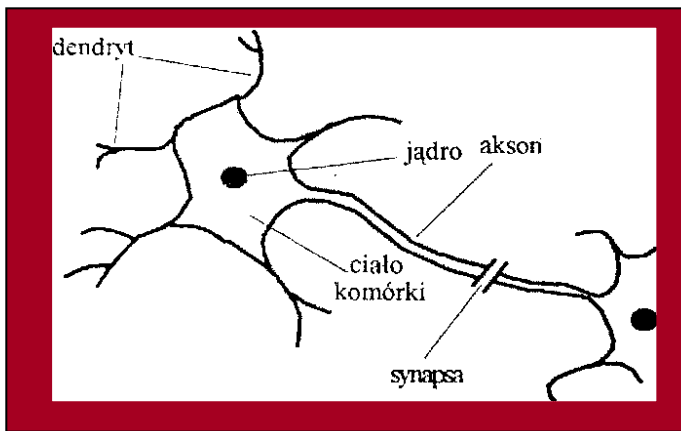
Każdy z neuronów jest specjalizowaną komórką biologiczną mogącą przenosić i przetwarzać złożone sygnały elektrochemiczne.

Neuron na ogół posiada rozgałęzioną strukturę wejść informacyjnych (dendryty), scalające sygnały ze wszystkich wejść ciało (perikarion) oraz opuszczający komórkę jako pojedyncze włókno nośnik informacji wyjściowej (akson), powielający potem przeprowadzony przez siebie wynik pracy neuronu i rozsyłający go do różnych neuronów odbiorczych poprzez rozgałęzioną strukturę wyjściową (telodendron).

Modele neuronów

Akson jednej komórki łączy się z dendrytami innych komórek poprzez biochemiczne złącza, modyfikujące sygnały i stanowiące nośnik pamięci. Są to tzw. **synapsy**, w oryginale biologicznym bardzo skomplikowane, ale w sztucznych sieciach neuronowych sprowadzane jedynie do **operatorów przemnażania wejściowych sygnałów przez współczynniki ustalone w toku procesu uczenia**.

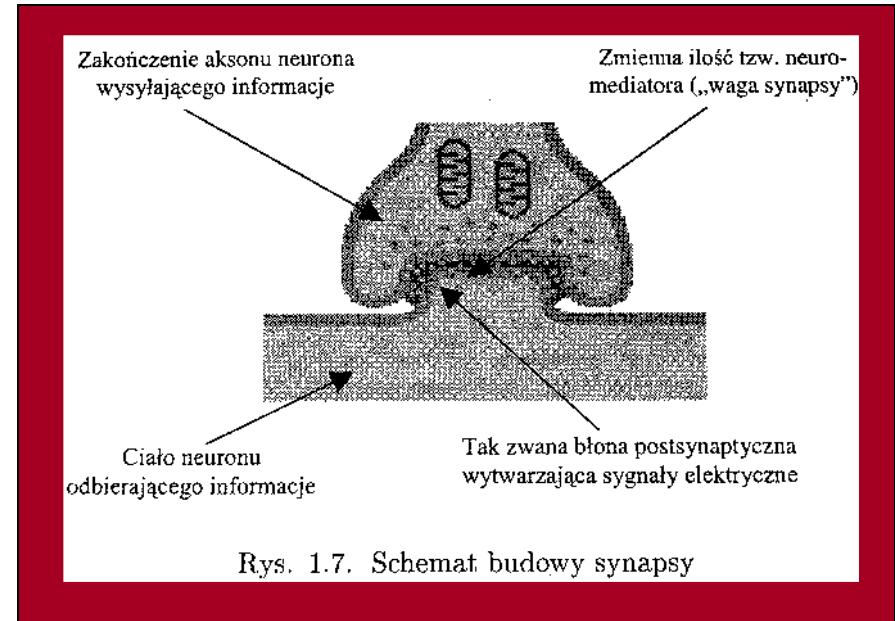
Pobudzony przez synapsy neuron przechodzi do stanu aktywnego, co objawia się tym, że wysyła on przez swój akson wyjściowy sygnał elektrochemiczny o charakterystycznym kształcie, amplitudzie i czasie trwania. Sygnał ten za pośrednictwem kolejnych synaps dociera do innych neuronów.



Neuron przechodzi w stan pobudzenia tylko wówczas, gdy łączny sygnał, który dotarł do ciała komórki poprzez dendryty przekroczy pewien poziom progowy. Siłą otrzymanego przez neuron sygnału zależy w największym stopniu od efektywności (wagi) synapsy do której dociera impuls.

Synapsy - nośnik biologicznej pamięci

W każdej synapsie występuje szczelina wypełniona specjalną substancją, tak zwanym *neurotransmiterem* albo *neuromediatozem*.



Mechanizm funkcjonowania neurotransmitera (“wagi synapsy”) ma duże znaczenie w biologii układu nerwowego, wpływając na chemiczne przemiany neurotransmitera można sztucznie wpływać na zachowanie człowieka (niektóre leki i narkotyki). Jest to więc substancja chemiczna która ma zdolność przesyłania (i wzmacniania lub osłabiania) sygnału przez występującą w każdej synapsie lukę między neuronem nadającym sygnał i neuronem który ten sygnał odbiera.

Uczenie i samouczenie w neuronach i sieciach neuronowych

Jeden z najbardziej znanych badaczy systemów neurologicznych (Donald Hebb) głosił pogląd, że na proces uczenia składają się głównie zmiany “siły” połączeń synaptycznych. W klasycznym eksperymencie Pawłowa, dotyczącym odruchów warunkowych, w którym dźwięk dzwonka rozlega się przed podaniem psu obiadu, pies bardzo szybko uczy się łączyć się dźwięk dzwonka z jedzeniem. Odbywa się to w ten sposób że konkretne połączenia synaptyczne ulegają wzmocnieniu w wyniku procesu uczenia.

Obecnie sądzi się, że korzystając z bardzo dużej liczby takich prostych mechanizmów uczenia oraz używając licznych, ale wyjątkowo prostych elementów przetwarzających informacje, jakimi są neurony, mózg jest zdolny do realizacji wszystkich tych wyjątkowo złożonych żądań jakie na codzień wykonuje. Oczywiście, w rzeczywistym biologicznym mózgu występuje wiele bardziej złożonych mechanizmów przetwarzania informacji, angażujących wiele dodatkowych elementów.

Struktura sztucznego neuronu

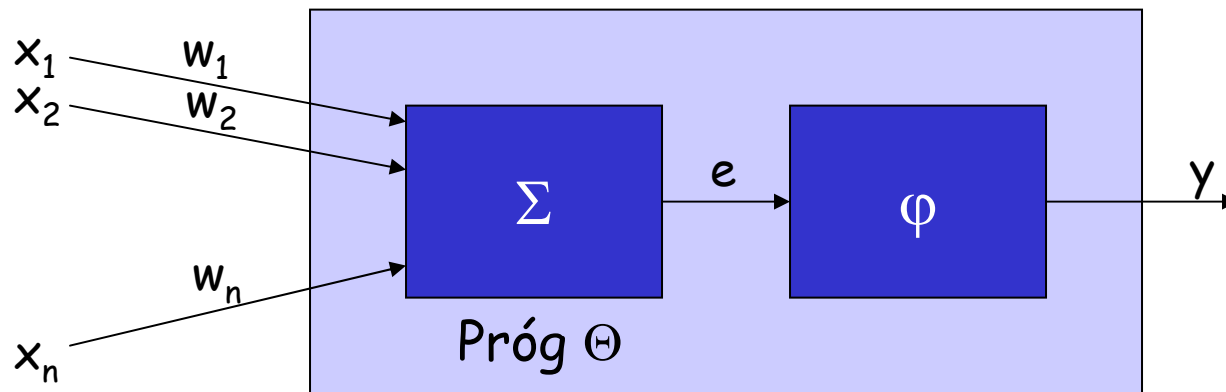
Chcąc odwzorować jedynie podstawową strukturę biologicznych systemów nerwowych twórcy sztucznych sieci neuronowych zdecydowali, że sztuczny neuron zostanie zdefiniowany następująco:

- Do neuronu dociera pewna liczba sygnałów (wartości) wejściowych.
- Każda wartość jest wprowadzana do neuronu przez połączenie o pewnej sile (wadze); wagi te odpowiadają efektywności synapsy w neuronie biologicznym.
- Każdy neuron posiada również pojedynczą wartość progową, określającą jak silne musi być pobudzenie, aby doszło do wzbudzenia.
- W neuronie obliczana jest ważona suma wejść (to znaczy suma wartości sygnałów wejściowych po przemnażanych przez odpowiednie współczynniki wagowe), a następnie odejmowana jest od niej wartość progowa. Uzyskana w ten sposób wartość określa pobudzenie neuronu. Jest to oczywiście daleko posunięte przybliżenie rzeczywistych zjawisk biologicznych.
- Sygnał reprezentujący łączne pobudzenie neuronu przekształcany jest z kolei przez ustaloną funkcję aktywacji neuronu (funkcja przejścia neuronu). Wartość obliczona przez funkcję aktywacji jest ostatecznie wartością wyjściową (sygnałem wyjściowym) neuronu.

Zachowanie neuronu (i całej sieci neuronowej) jest silnie uzależnione od rodzaju użytej funkcji aktywacji.


Struktura sztucznego neuronu

Jest bardzo interesujące i wręcz intrygujące że sztuczne sieci neuronowe mogą osiągać tak bardzo znaczące rezultaty praktyczne, korzystając z niezwykle uproszczonego modelu neuronu, którego złożoność nie jest wiele większa od schematu polegającego na tym że neuron jedynie wyznacza ważoną sumę swoich wejść i przechodzi w stan pobudzenia wtedy gdy łączny sygnał wejściowy przekroczy pewien ustalony poziom progowy.



Struktura sztucznego neuronu

W sztucznych sieciach neuronowych chętnie sięgamy do funkcji aktywacji dostarczających sygnałów o wartościach zmieniających się w sposób ciągły. Najczęściej wykorzystuje się funkcje aktywacji w postaci tzw. *sigmoidy*.



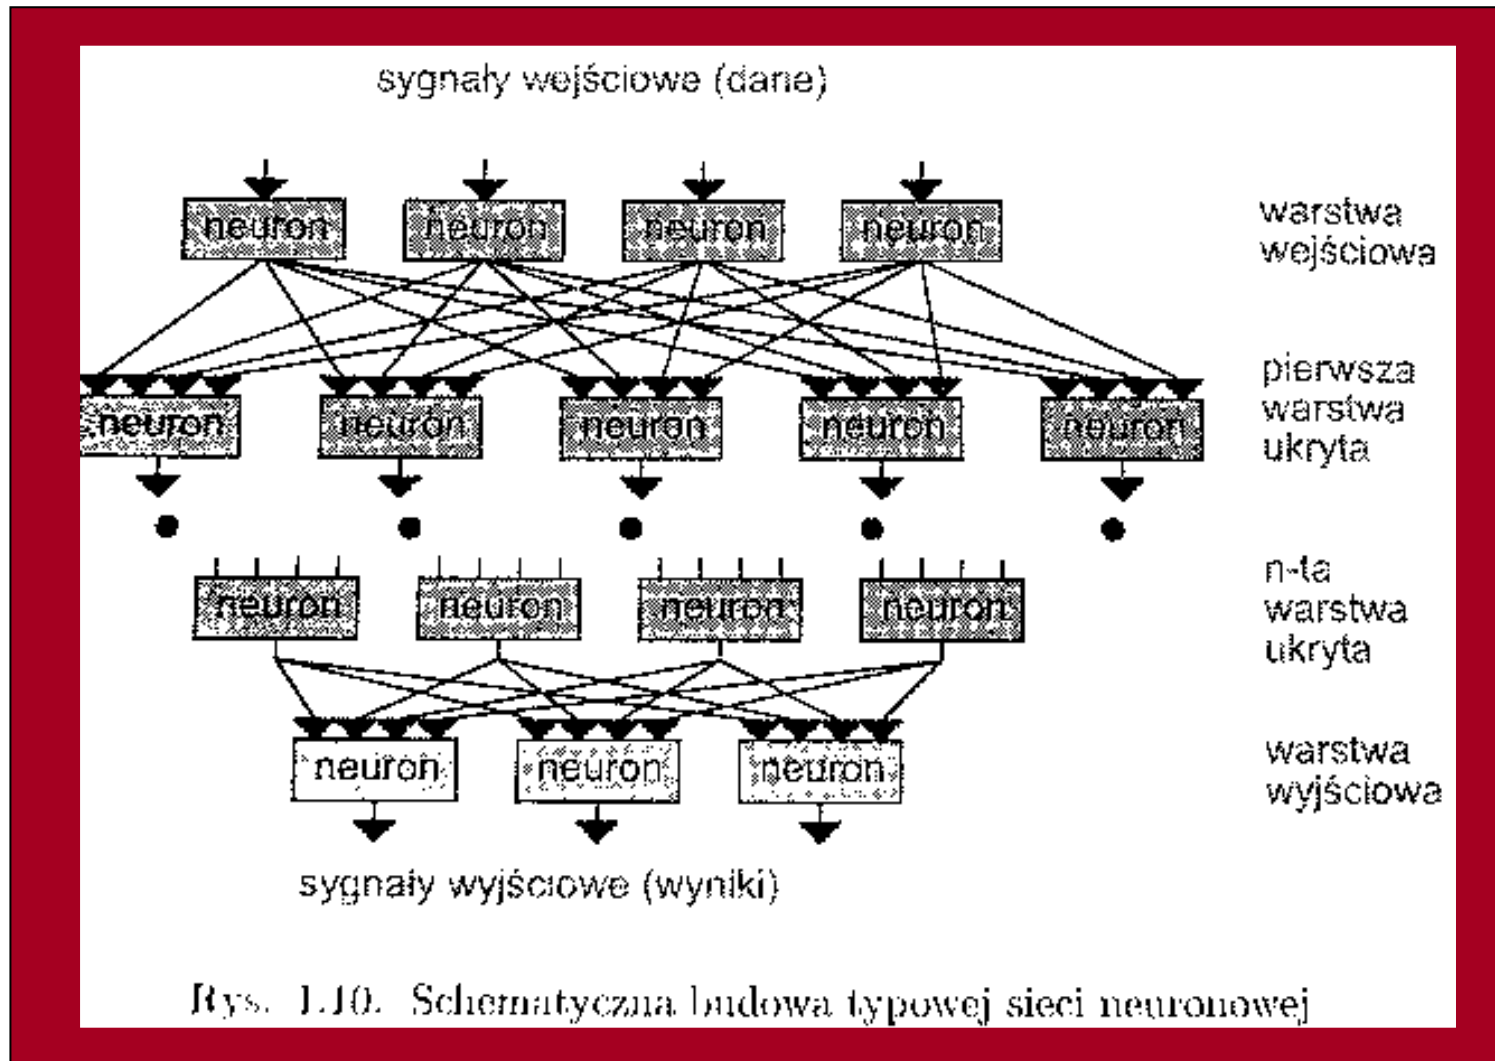
W modelu sztucznej sieci neuronowej wprowadza się często sygnały znakozmienne (pobudzenia i hamowania). Ma to modelować istniejące w rzeczywistym mózgu tzw. drogi pobudzenia i hamowania (które są w rzeczywistości rozdzielone i realizowane przez specjalne neurony hamujące).

Struktura sztucznej sieci neuronowej

Sieć neuronów, aby mieć wartość użytkową, musi posiadać **wejścia** (służące do wyprowadzania wartości zmiennych obserwowanych na zewnątrz) oraz **wyjście** (które oznaczają wynik obliczeń).

Wejścia i wyjścia odpowiadają w mózgu wybranym **nerwom**: **sensorycznym** dla wejść i **motorycznym** dla wyjść. Występować mogą również neurony spełniające wewnętrzne funkcje w sieci, które pośredniczą w analizie informacji dostarczanych przez nerwy sensoryczne i biorą udział w przetwarzaniu sygnałów sensorycznych na decyzje aktywizujące określone elementy wykonawcze. Ponieważ w tych pośredniczących neuronach zewnętrzny obserwator nie ma dostępu ani do wejść ani do wyjść, neurony takie zwykle się opisują jako **neurony ukryte**. Neurony ukryte (czy też warstwy ukryte) to te elementy sieci, do których nie można bezpośrednio przekazywać/odbierać sygnałów ani od strony wejścia ani od strony wyjścia.

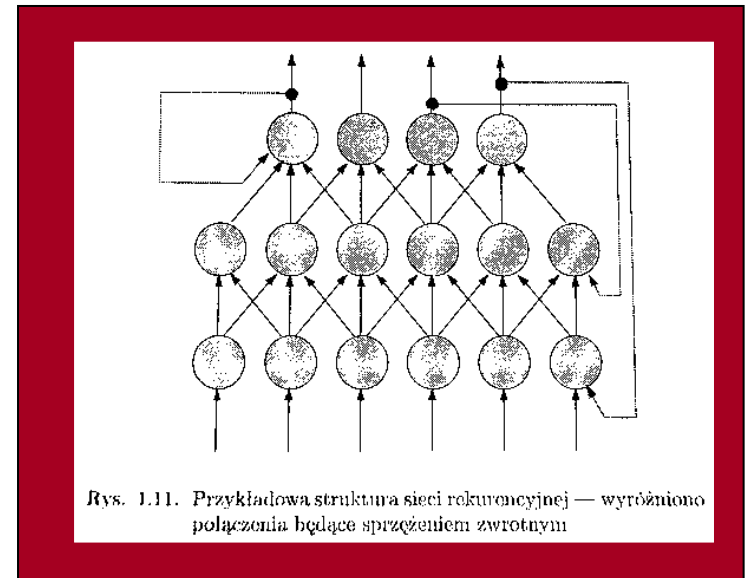
Struktura sztucznej sieci neuronowej



Struktura sztucznej sieci neuronowej

Neurony wejściowe, ukryte i wyjściowe muszą pozostać wzajemnie połączone co stawia przed twórcą sieci problem wyboru jej struktury. Kluczową kwestią przy wyborze struktury sieci jest występowanie lub brak w tej strukturze sprzężenia zwrotnego.

- Proste sieci mają strukturę jednokierunkową (ang. feedforward): sygnał przepływa w nich tylko w jednym kierunku – od wejść, poprzez kolejne neurony ukryte, osiągając ostatecznie neurony wyjściowe. Strukturę taką charakteryzuje zawsze stabilne zachowanie, co jest jej zaletą.
- Sieć może mieć również wbudowane sprzężenie zwrotne (tzn. zawiera połączenia powrotne od późniejszych do wcześniejszych neuronów), wówczas może wykonać bardziej skomplikowane obliczenia, w szczególności takie, które mają charakter rekurencyjny




Rys. 1.11. Przykładowa struktura sieci rekurencyjnej — wyróżniono połączenia będące sprzężeniem zwrotnym

Struktura sztucznej sieci neuronowej

Są badania wskazujące, że sieć o mniejszej liczbie neuronów, która zawiera jednak sprzężenia zwrotne, może dzięki nim wykonać równie złożone obliczenia, jak sieć bez tych sprzężeń, zawierająca znacznie większą liczbę neuronów.

Jednak nie odbywa się to “bezboleśnie” – na skutek krążenia sygnałów w sieciach ze sprzężeniem zwrotnym (z wejścia do wyjścia i przez sprzężenie zwrotne z powrotem na wejście) może ona zachowywać się niestabilnie i mieć bardzo złożoną dynamikę, w ramach której można oczekiwać najbardziej skomplikowanych form zachowania – np. w formie chaosu deterministycznego.

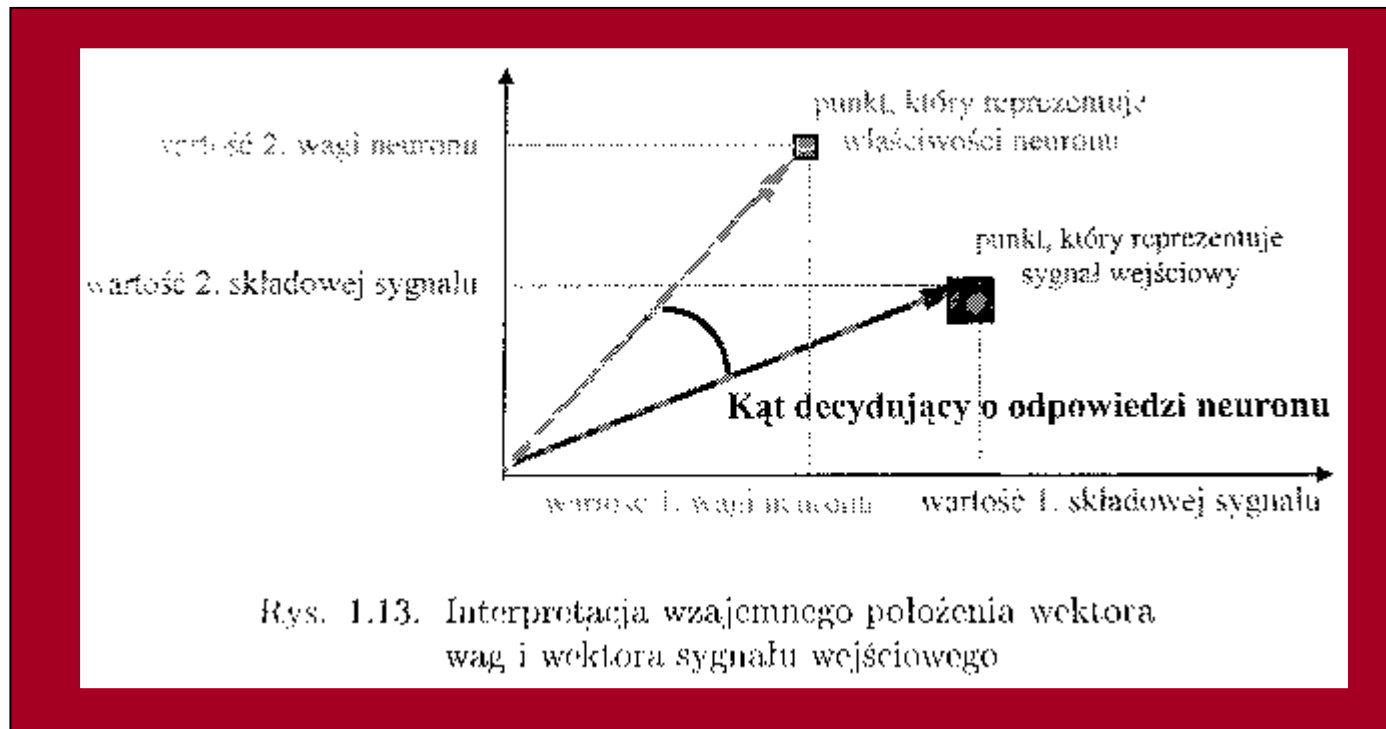
Dość dużą użytecznością praktyczną cechują się sieci mające stosunkowo dużo sprzężeń zwrotnych, konkretnie – sieci w których wszystkie połączenia mają charakter sprzężeń zwrotnych. Sieci takie są znane jako tzw. sieci Hopfielda.



Rys. 1.12. Struktura prostej sieci Hopfielda


Działanie sieci neuronowej i jej uczenie

Działanie sieci neuronowej jest wypadkową działania poszczególnych neuronów oraz zachodzących pomiędzy nimi interakcji. Pojedynczy neuron w typowych przypadkach realizuje (z matematycznego punktu widzenia) operację iloczynu skalarnego wektora sygnałów wejściowych oraz wektora wag. W efekcie, odpowiedź neuronu zależy od wzajemnych stosunków geometrycznych pomiędzy wektorami sygnałów i wektorami wag.



Działanie sieci neuronowej i jej uczenie

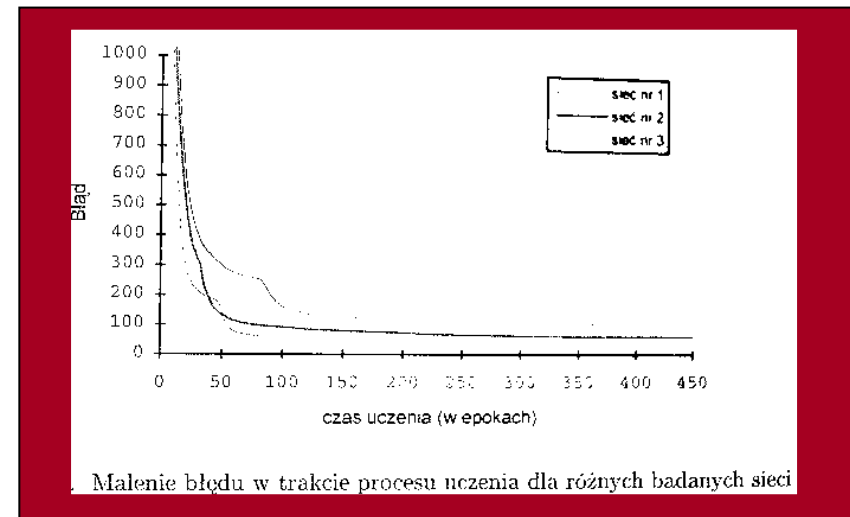
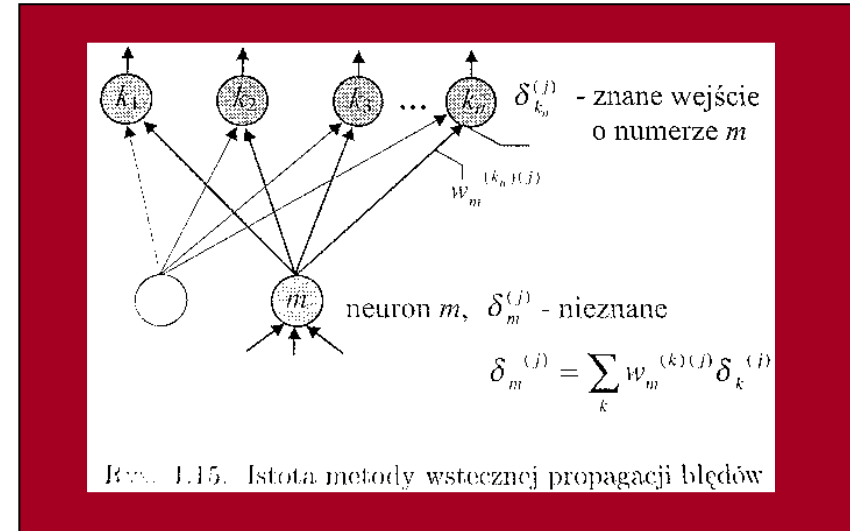
Właściwą geometrię położenia wektorów wag, gwarantującą poprawne działanie, uzyskuje się w wyniku procesu uczenia, który może być interpretowany jako metoda automatycznego poszukiwania takiego zestawu współczynników wagowych występujących we wszystkich neuronach całej sieci, który gwarantuje najmniejszą wartość sumarycznego błędu popełnianego przez sieć (sumowanie odbywa się po zbiorze różnych zadań stawianych sieci).



Działanie sieci neuronowej i jej uczenie

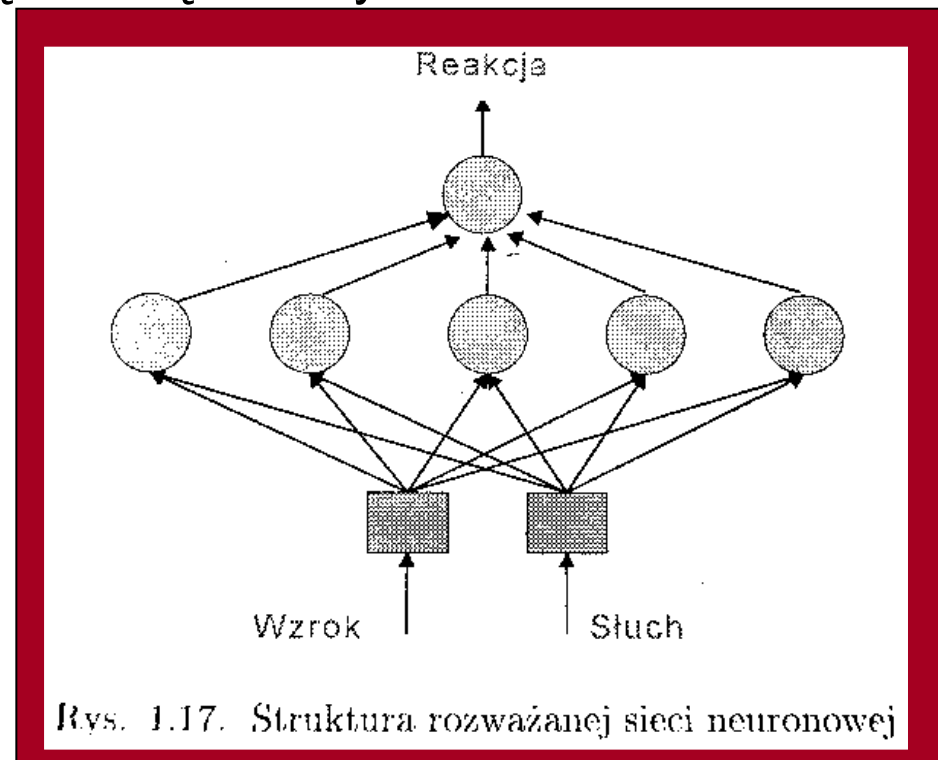
W wyniku stosowania odpowiedniego algorytmu uczenia (najbardziej znany jest tu algorytm wstecznej propagacji błędów) sieć może systematycznie zmniejszać błąd popełniany w trakcie procesu uczenia, w wyniku czego obserwujemy w czasie uczenia stopniową poprawę jej działania.

Doskonalenie działania sieci neuronowej podczas jej uczenia może być obserwowane na wykresie pokazującym zmienność sumarycznego błędu popełnianego przez sieć w trakcie procesu uczenia, ale może być także obserwowana za pomocą “mapy” pokazującej, jak wygląda działanie sieci dla różnych wartości sygnałów wejściowych w zestawieniu z działaniem wzorcowym, wynikającym z postawionego zadania.



Prosta sieć neuronowa - intuicyjny opis.

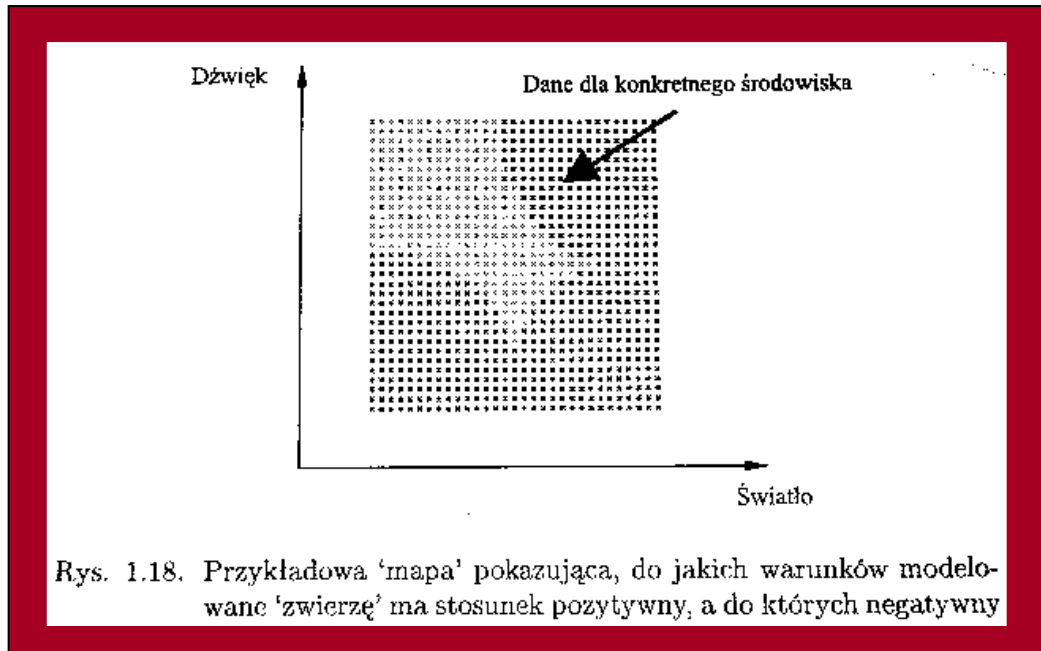
Wyobraźmy sobie że badana sieć jest mózgiem hipotetycznego zwierzęcia wyposażonego w dwa perceptory – na przykład prymitywny wzrok i słuch. Zakładamy, że modelowane zwierzę może wykazywać tylko jeden typ reakcji – na przykład swoje emocje. Sieć będzie mogła sprawić że “zwierzę” będzie się “cieszyć” lub “smucić”.



Rys. 1.17. Struktura rozważanej sieci neuronowej

Prosta sieć neuronowa - intuicyjny opis

Zachowanie sieci na każdym etapie uczenia będziemy ilustrować jak na poniższym rysunku. Widoczne jasne i ciemne kwadraty stanowią obraz “stanu świadomości” sieci neuronowej w konkretnych warunkach, a więc przy konkretnych sygnałach docierających do receptorów “zwierzęcia”.



Każdy punkt wewnątrz kwadratu symbolizuje zespół dwóch danych wejściowych (światło, dźwięk). Dla każdej konfiguracji “zwierzę” może mieć nastawienie pozytywne (ciemny kwadrat) lub negatywne (jasny kwadrat). Możliwe są też sytuacje pośrednie modelowane różnymi odcieniami szarości.

Chcąc uczyć należy **sformułować** “zadanie” którego “zwierzę” musi się **nauczyć**. Czyli ustalić **dla których konfiguracji** ma mieć stosunek pozytywny a dla których negatywny.


Prosta sieć neuronowa - proces uczenia

Przebieg uczenia sieci neuronowej – sprowadzony do realiów przedstawionego tu przykładu – polega na wielokrotnym umieszczaniu naszego “zwierzęcia” w różnych warunkach, wybieranych losowo z przedziału dostępnych wartości występujących w systemie sygnałów. Innymi słowy do wejść sieci (receptorów “zwierzęcia”) dostarczane są przypadkowe (ale znane) sygnały.

Sieć reaguje tak jak jej nakazuje aktualnie zawarta w niej wiedza, czyli jedne warunki a probuje, inne nie. Natomiast “nauczyciel” (komputer prowadzący trening) mając mapę pożądanых zachowań sieci, podaje jej sygnał wzorcowy – to ma ci się podobać a tamto nie!

Po wykonaniu zadanej liczby kroków proces uczenia jest przerywany i sieć poddana jest “egzaminowi”. Podczas tego egzaminu “zwierzę” musi podać dla wszystkich możliwych punktów swoje oceny. Wyniki tych egzaminów (co kilkadziesiąt lub kilkaset danych treningowych) zilustrowane są na rysunku.

Prosta sieć neuronowa - proces uczenia



Przegląd zastosowań sieci neuronowych

Jakkolwiek sieci neuronowe stanowią dziedzinę wiedzy całkowicie samodzielą, w rozwiązaniach praktycznych stanowią zwykle część sterującą procesem bądź część decyzyjną przekazującą sygnał wykonawczy innym elementom urządzenia, nie związanym bezpośrednio z sieciami neuronowymi.

Przegląd zastosowań sieci neuronowych

Funkcje pełnione przez sieć można ująć w kilka podstawowych grup:

- aproksymacji i interpolacji
- rozpoznawania i klasyfikacji wzorców
- kompresji
- predykcji i sterowania
- asocjacji

Sieć neuronowa pełni w każdym z tych zastosowań rolę **uniwersalnego aproksymatora** funkcji wielu zmiennych, realizując **funkcję nieliniową** o postaci $y = f(x)$, gdzie x jest wektorem wejściowym, a y realizowaną funkcją wektorową wielu zmiennych.

Duża liczba zadań modelowania, identyfikacji, przetwarzania sygnałów da się sprowadzić do zagadnienia aproksymacyjnego.

Przegląd zastosowań sieci neuronowych

Przy klasyfikacji i rozpoznawaniu wzorców sieć uczy się podstawowych cech tych wzorców, takich jak odwzorowanie geometryczne układu pikselowego wzorca, rozkładu składników głównych wzorca, składników transformacji Fouriera czy innych jego właściwości. W uczeniu podkreślane są różnice występujące w różnych wzorcach, stanowiące podstawę podjęcia decyzji przypisania ich do odpowiedniej klasy.

W dziedzinie predykcji zadaniem sieci jest określenie przyszłych odpowiedzi systemu na podstawie ciągu wartości z przeszłości. Mając informacje o wartościach zmiennej x w chwilach poprzedzających predykcje $x(k-1)$, $x(k-2)$,, $x(k-N)$, sieć podejmuje decyzje, jaka będzie estymowana wartość $x(k)$ badanego ciągu w chwili aktualnej k . W adaptacji wag sieci wykorzystuje się aktualny błąd predykcji oraz wartość tego błędu w chwilach poprzedzających.

Przegląd zastosowań sieci neuronowych

W zagadnieniach identyfikacji i sterowania procesami dynamicznymi sieć neuronowa pełni zwykle kilka funkcji. Stanowi model nieliniowy tego procesu, pozwalający na wypracowanie odpowiedniego sygnału sterującego. Pełni również funkcje układu śledzącego i nadążnego, adaptując się do warunków środowiskowych. Ważną rolę, zwłaszcza w sterowaniu robotów, odgrywa funkcja klasyfikatora wykorzystywana w podejmowaniu decyzji co do dalszego przebiegu procesu.

W zadaniach asocjacji sieć neuronowa pełni rolę pamięci skojarzeniowej. Można wyróżnić pamięć asocjacyjną, w przypadku której skojarzenie dotyczy tylko poszczególnych składowych wektora wejściowego oraz pamięć heteroasocjacyjną, gdzie zadaniem sieci jest skojarzenie ze sobą dwóch wektorów. Jeśli na wejście sieci podany będzie wektor odkształcony (np. o elementach zniekształconych szumem bądź pozbawiony pewnych elementów danych w ogóle), sieć neuronowa jest w stanie odtworzyć wektor oryginalny, pozbawiony szumów, generując przy tym pełną postać wektora stowarzyszonego z nim.

Przegląd zastosowań sieci neuronowych

Najważniejszą cechą sieci neuronowych, stanowiącą o jej ogromnych zaletach i szerokich możliwościach zastosowań, jest równoległe przetwarzanie informacji przez wszystkie neurony. Przy masowej skali powiązań neuronowych uzyskuje się dzięki temu znaczne przyspieszenie procesu przetwarzania informacji. W wielu przypadkach jest możliwe przetwarzanie sygnałów w czasie rzeczywistym.

Bardzo duża liczba powiązań międzyneuronowych sprawia, że sieć staje się odporna na błędy występujące w niektórych powiązaniach. Funkcje uszkodzonych wag przejmują inne i w efekcie działania sieci nie dostrzega się istotnych zaburzeń. Własności te wykorzystuje się między innymi przy poszukiwaniu optymalnej architektury sieci neuronowej przez obcinanie pewnych wag.

Przegląd zastosowań sieci neuronowych

Inną, nie mniej ważną cechą sieci jest jej zdolność do uczenia się i generalizacji nabytej wiedzy. Sieć wykazuje własność tak zwanej sztucznej inteligencji. Wytrenowana na ograniczonej grupie danych uczących potrafi skojarzyć nabytą wiedzę i wykazać oczekiwane działanie na danych nie uczestniczących w procesie uczenia.

Ostatnia dekada XX wieku charakteryzuje się niezwykle burzliwym rozwojem teorii sieci neuronowych i ich zastosowań. Zagadnienia te są przedmiotem prowadzonych na całym świecie badań, w których uczestniczą dziesiątki tysięcy specjalistów w zakresie biocybernetyki i inżynierii biomedycznej, informatyki, elektroniki, automatyki i robotyki, fizyki, matematyki stosowanej i ekonomii.

W 1995 roku rozpoczęło działalność Polskie Towarzystwo Sieci Neuronowych
(www.ptsn.pcz.czest.pl)