

# Sztuczne Sieci Neuronowe

---

## Wykład 1 Wprowadzenie do tematyki Sztucznych Sieci Neuronowych (SSN)

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 SSN

---

- Wprowadzenie
- Biologiczne inspiracje neurokomputingu
- Podstawowy model neuronu i sieci neuronowej
- Działanie sieci neuronowej i jej uczenie
- Przykład sposobu działania i procesu uczenia
- Zastosowania

# Liniowe modele

---

- 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.

# Sieci SSN jako nielinowe modele

---

- **Sieci neuronowe** są bardzo wyrafinowaną techniką modelowania, zdolną do odwzorowywania nadzwyczaj złożonych funkcji. Mają **charakter nieliniowy**, co istotnie wzbogaca możliwości ich zastosowań. To jest jedna z wielu obecnie rozwijanych wyrafinowanych technik!
- Odwołanie się do **modeli tworzonych przy pomocy sieci neuronowych** może być najszybszym i najwygodniejszym rozwiązaniem problemu. SSN umożliwiają również kontrolę nad złożonym problemem wielowymiarowości, który przy innych podejściach znacząco utrudnia próby modelowania funkcji nieliniowych z dużą ilością zmiennych

# Sieci SSN jako nielinowe modele

---

- 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.


# Sieci SSN jako nielinowe modele

---

- 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: niedościgły wzór

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



Rys. 4. Widok rozmieszczenia elementów mózgu człowieka w przekroju podłużnym

- Mózg ludzki: objętość 1,4 l., pow. 2000cm<sup>2</sup>, masa 1,5 kg
- Kora mózgowa: grubość 3 mm, 10<sup>10</sup>-10<sup>11</sup> komórek nerwowych, liczba połączeń (synaps) 10<sup>14</sup>-10<sup>15</sup>
- Impulsy komórek nerwowych: częstotliwość 1-100Hz, czas trwania 1-2 ms, napięcie 100mV
- Szybkość pracy mózgu: 10<sup>15</sup> połączeń x 100Hz = 10<sup>17</sup> op./s

# Mózg człowieka jako prototyp sieci neuronowej

---

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**.



Rys. 2. Ludzki mózg - pierwowzór i niedościgły ideał dla badaczy sieci neuronowych



# 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.

# Ludzki mózg: uczenie się

---

Przykład: Dziecko uczy się dodawać. Ma 4 działania:

$$1+1$$

$$2+4$$

$$3+2$$

$$2+2$$

Uczone dziecko ma dwie opcje

- a) Zrozumieć zasadę dodawania i posługiwać się nią w przykładach, których nie widziało
- b) Wyuczyć się przykładów na pamięć, wtedy jeżeli zobaczy nowy, nieznaną przykład to nie będzie potrafiło go rozwiązać.

W dziedzinie nauki SSN istnieje kilka metod uczenia zarówno jednoprzebiegowych jak i wieloprzebiegowych. Takie podejście ma na celu zapobieżenia tzw. przeuczenia sieci. Przeuczenie sieci to jest najzwyczajniejsze „wyrzucie na blachę” przykładów jakimi uczymy sieć.

# Historia rozwoju sztucznych sieci neuronowych

---

- **1943** – matematyczny model sztucznego neuronu  
McCullocha i Pittsa
- **1949** – Hebb – reguła uczenia bez nadzoru (Hebba)  
w Organization of Behaviour
- **1958** – perceptron Rosenblatta – pierwsza  
implementacja SSN: elektroniczno-elektromechaniczny układ, warstwa  
wejściowa – warstwa wyjściowa, uczenie zbieżne (o ile istnieje rozwiązanie),  
aplikacja: do rozpoznawania znaków alfanumerycznych
- **1960** – Widrow i Hoff: Madaline (multiple adaptive linear neurons)
- **1969** – Minsky i Papert: książka Perceptrons – krytyka SSN,
- **zastój do początku lat 80.**

# Historia rozwoju sztucznych sieci neuronowych

---

Odrodzenie SSN:

- **1982** – Hopfield buduje pamięć autoasocjacyjną, sieć rozwiązującą NP-zupełny problem komiwojażera,
- **1974, 1982, 1986** – algorytm wstecznej propagacji błędów odpowiedzią na krytykę Minsky’ego i Paperta
- **Początek lat 90:** matematyczny dowód na sensowność wykorzystania SSN (perceptronów wielowarstwowych) w roli klasyfikatorów w warunkach niepewności probabilistycznej

# Zalety sztucznych sieci neuronowych

---

Potrafia odpowiadać w warunkach informacji niepełnej

- Nie wymagają znajomości algorytmu rozwiązania zadania (automatyczne uczenie)
- Przetwarzają informację w sposób wysoce równoległy
- Potrafia generalizować (uogólniać na przypadki nieznane)
- Są odporne na częściowe uszkodzenia
- Potrafia realizować pamięć asocjacyjną (skojarzeniową – podobnie jak działa pamięć u ludzi) w przeciwieństwie do pamięci adresowanej (charakterystycznej dla klasycznych komputerów)

# Popularność SSN

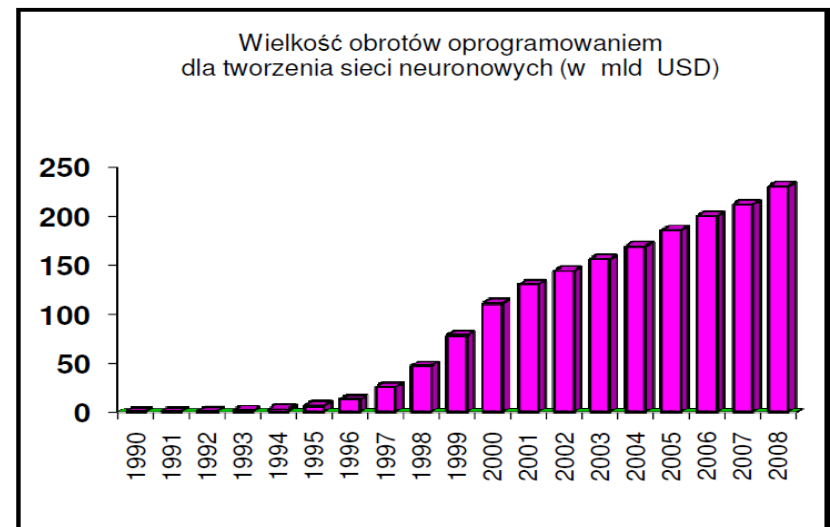
Od wielu lat bardzo dużym zainteresowaniem cieszą się sztuczne sieci neuronowe, jako wygodne narzędzie przydatne do rozwiązywania bardzo wielu różnych praktycznych zadań.

## ■ 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.



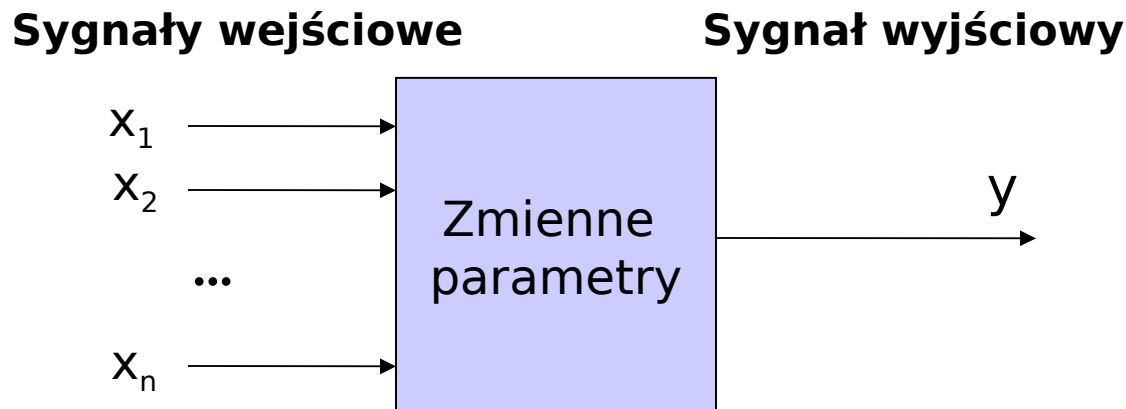
# Uboczne aspekty popularności

---

Co powoduje że to 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.



# Modele neuronów

---



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

Rys. 5. Orientacyjna budowa biologicznej komórki nerwowej (neuronu)

■ 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

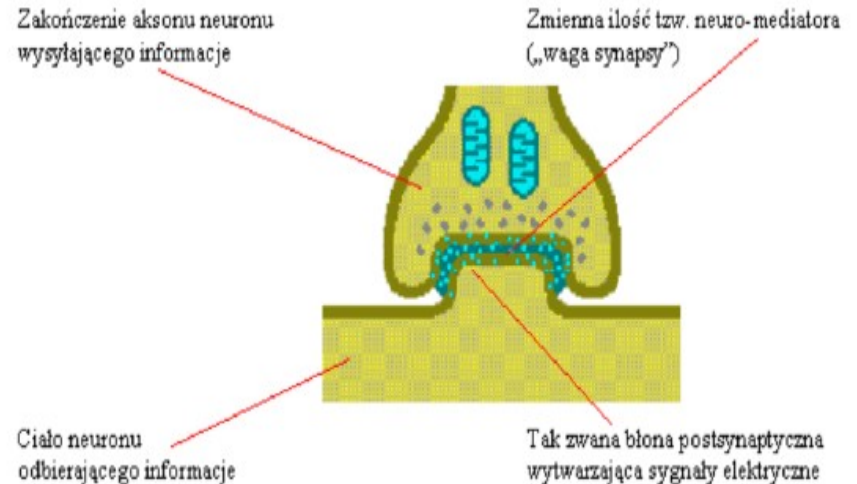
---

**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 ustalane 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.

# Synapsy - nośnik pamięci

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



Rys. 7. Schemat budowy synapsy

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 ze **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

---

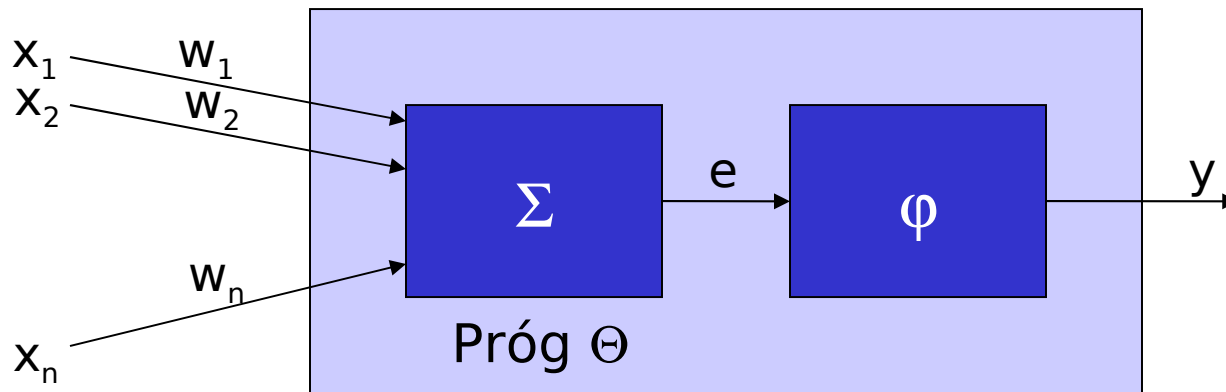
Chcąc odwzorować jedynie podstawową strukturę biologicznych systemów nerwowych twórcy sztucznych sieci neuronowych zdecydowali, że sztuczny neuron zostanie zdefiniowany następująco:

- 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 przemnożeniu 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.

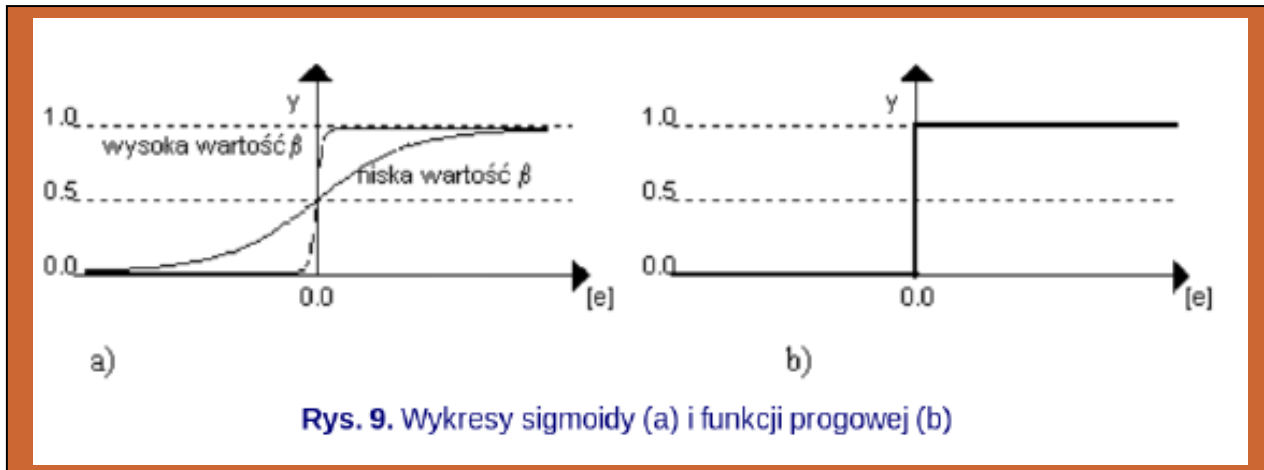
# Struktura sztucznego neuronu

- Jest bardzo interesujące i wręcz intrygujące że sztuczne sieci neuronowe mogą osiągać tak bardzo znaczące rezultaty praktyczne, korzystając z niezwykle uproszczonego modelu neuronu.
- Schematu polega 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 znakovienne** (pobudzania i hamowania). Ma to modelować istniejące w rzeczywistym mózgu tzw. drogi pobudzania i hamowania (które są w rzeczywistości rozdzielone i realizowane przez specjalne neurony hamujące).

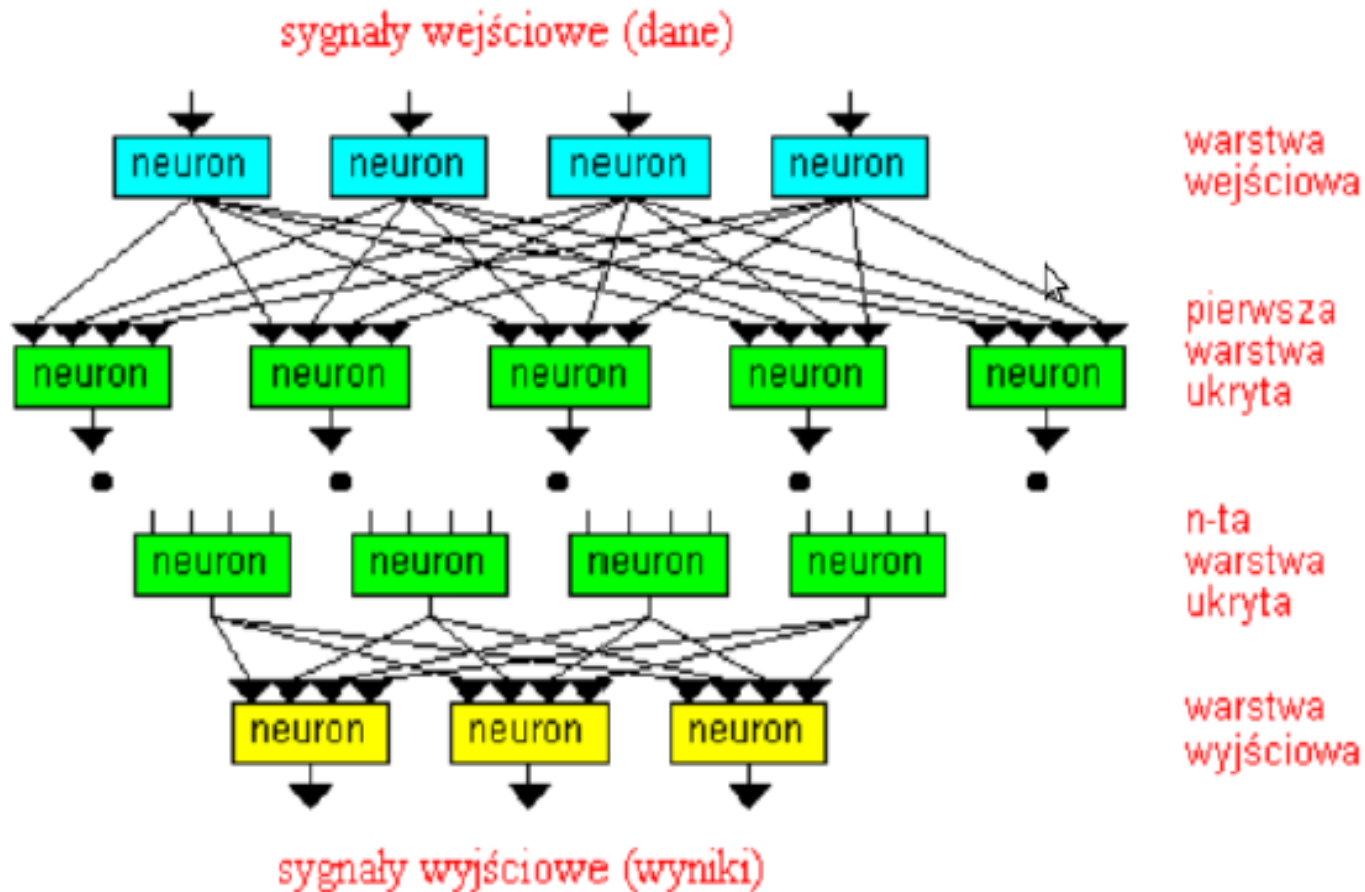
# Struktura sztucznej sieci neuronowej

---

**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



Rys. 10. Schematyczna budowa typowej 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.

# Struktura sztucznej sieci neuronowej

---

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



# 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.

# Struktura sztucznej sieci neuronowej

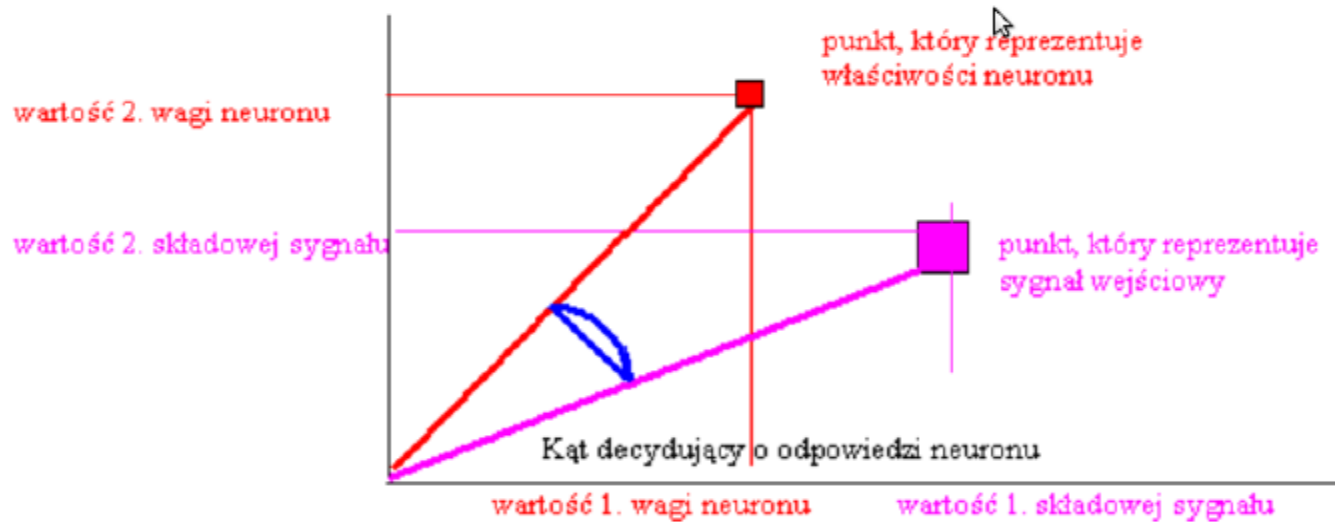
Dość dużą użytecznością praktyczną cechują się sieci mające stosunkowo dużo sprzężeń zwrotnych, konkretnie – sieci w których **wszystkie połączenia mają charakter sprzężeń zwrotnych**. Sieci takie są znane jako tzw. sieci Hopfielda.



**Rys. 12.** Struktura prostej sieci Hopfielda

# Działanie sieci neuronowej i jej uczenie

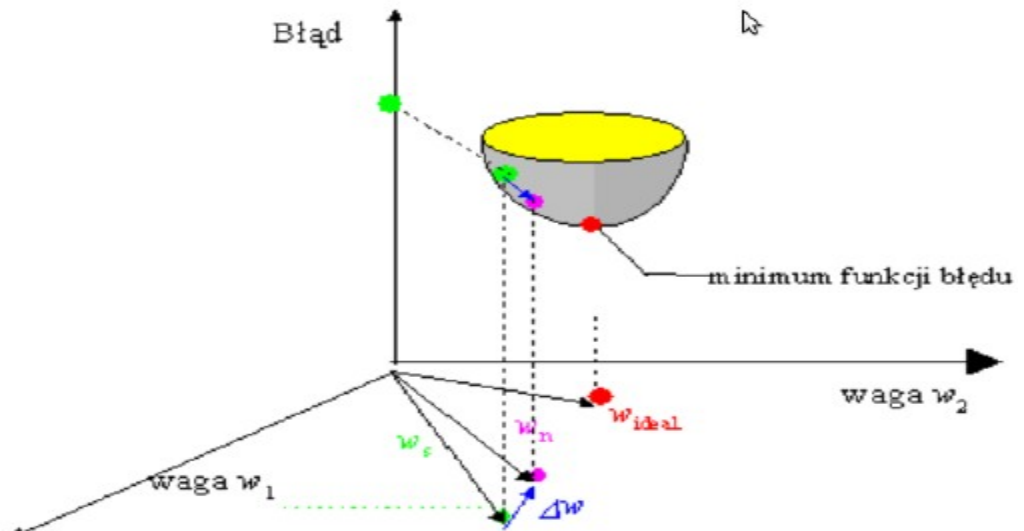
Działanie sieci neuronowej jest wypadkową działania poszczególnych neuronów oraz zachodzących pomiędzy nimi interakcji. Pojedynczy neuron w typowych przypadkach realizuje (z matematycznego punktu widzenia) operacje iloczynu skalarnego wektora sygnałów wejściowych oraz wektora wag. W efekcie, odpowiedź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



Rys. 13. Interpretacja wzajemnego położenia wektora wag i wektora sygnału wejściowego

# 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).



Rys. 14. Istota metody zmiany wektora wag podczas uczenia 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. Wynikającym z postawionego zadania.

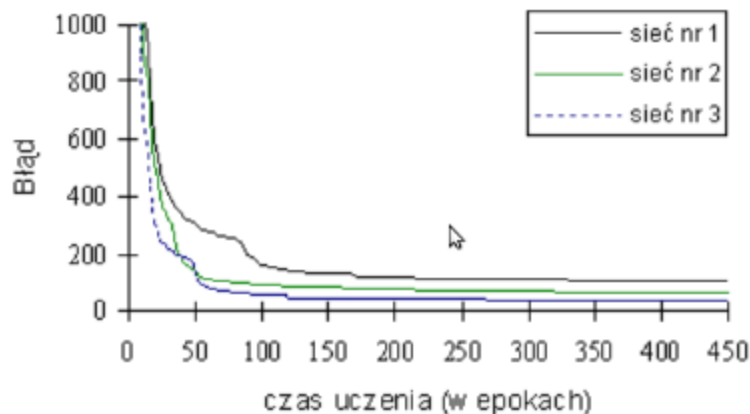


Rys. 15. Istota metody wstecznej propagacji błędów

# Działanie sieci neuronowej i jej uczenie

---

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.



Rys. 16. Malenie błędów w trakcie procesu uczenia dla różnych badanych sieci




# Prosta sieć neuronowa - intuicyjny opis.

---

Wyobraźmy sobie że badana sieć jest mózgiem hipotetycznego zwierzęcia wyposażonego w **dwa percepcyjory** – 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”**.

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.

# Prosta sieć neuronowa - process uczenia.

---

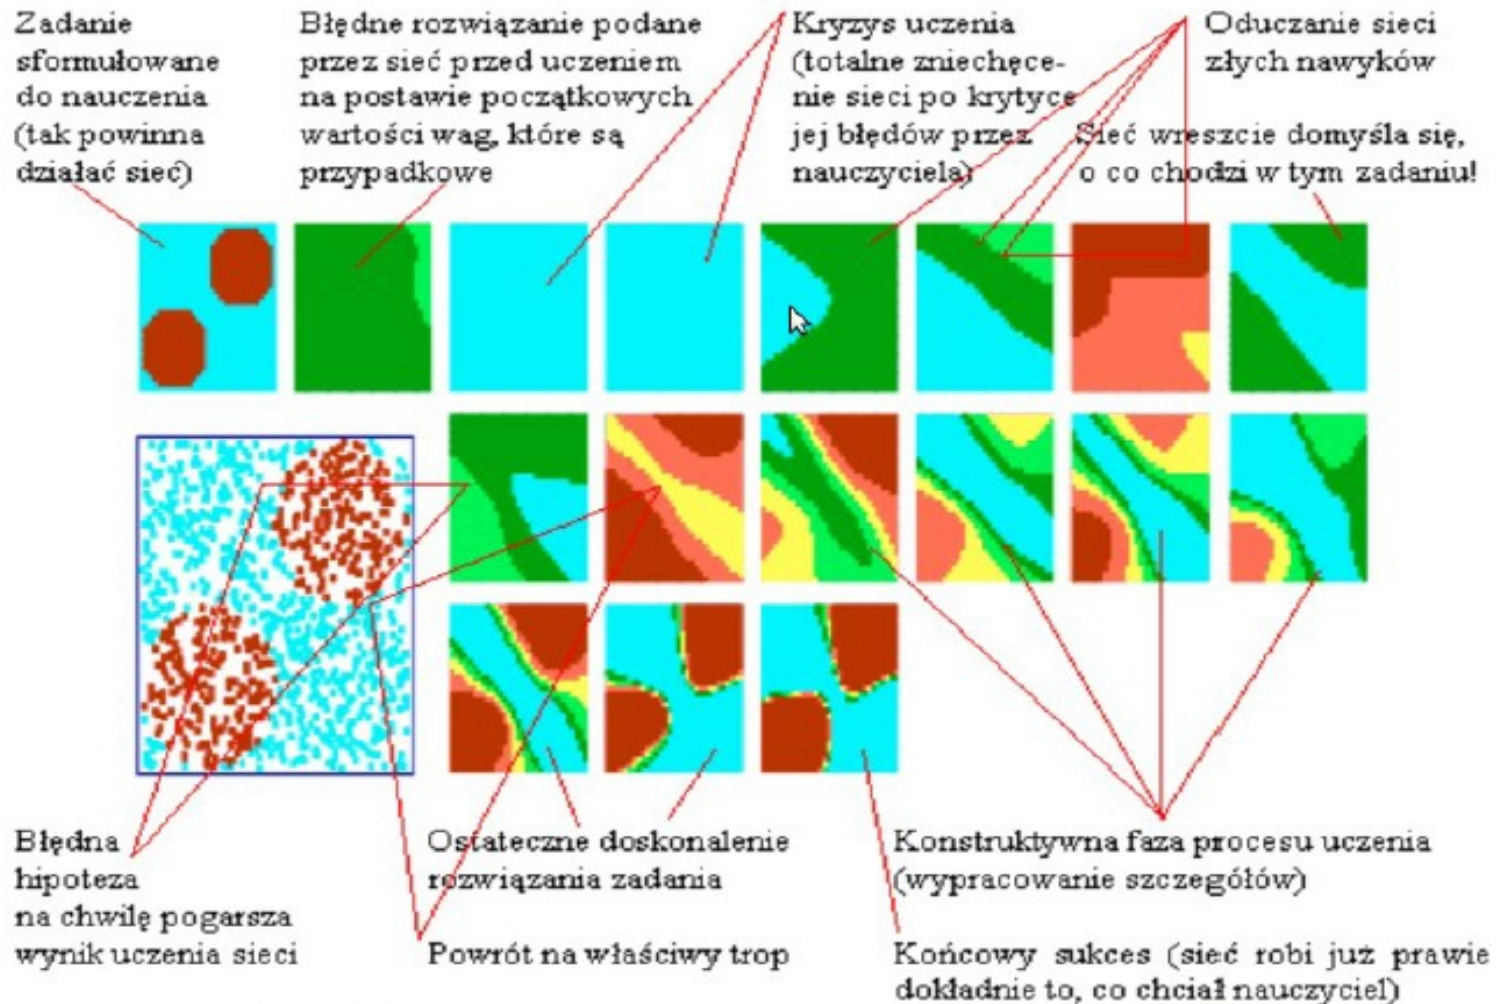
Chcąc uczyć należy **sformułować** “zadanie” którego “zwierzę” musi się **nauczyć**. Czyli ustalić **dla których konfiguracji** ma mieć stosunek pozytywny a dla których negatywny.

**Przebieg uczenia sieci neuronowej** – 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 aprobuje, 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.

# Prosta sieć neuronowa - process uczenia.



Rys. 17. Przebieg i charakterystyczne elementy uczenia perceptronu wielowarstwowego

# Przegląd zastosowań SSN

---

Funkcje pełnione przez SSN 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.czyst.pl](http://www.ptsn.pcz.czyst.pl))