

# Monika Baczyńska

---

## Rozważania wokół aspektów biologicznych i cybernetycznych sieci neuronowych

---

Studia Philosophiae Christianae 34/2, 153-159

---

1998

Artykuł został zdigitalizowany i opracowany do udostępnienia w internecie przez Muzeum Historii Polski w ramach prac podejmowanych na rzecz zapewnienia otwartego, powszechnego i trwałego dostępu do polskiego dorobku naukowego i kulturalnego. Artykuł jest umieszczony w kolekcji cyfrowej [bazhum.muzhp.pl](http://bazhum.muzhp.pl), gromadzącej zawartość polskich czasopism humanistycznych i społecznych.

Tekst jest udostępniony do wykorzystania w ramach dozwolonego użytku.

MONIKA BACZYŃSKA

## ROZWAŻANIA WOKÓŁ ASPEKTÓW BIOLOGICZNYCH I CYBERNETYCZNYCH SIECI NEURONOWYCH

Tematyka sztucznych sieci neuronowych należy do interdyscyplinarnej dziedziny badań. Związana jest z biocybernetyką, elektroniką, matematyką stosowaną, automatyką a nawet medycyną. Związek z tą ostatnią będzie omówiony najszerzej.

W ostatnim czasie ukazało się kilka nowych publikacji na temat sztucznych sieci neuronowych<sup>1</sup>. Pozycje te są skierowane do osób zainteresowanych przetwarzaniem (obliczaniem) za pomocą sztucznych sieci neuronowych. Celem artykułu jest jednak omówienie aspektu biologicznego sztucznych sieci neuronowych – problematyki bliższej filozofom i psychologom niż technikom i inżynierom.

Pozycją, która znacznie szerzej ujmuje tematykę związaną z mózgiem, jest praca zbiorowa pod redakcją T. Górskiej, A. Grabowskiej, J. Zagrodzkiej, *Mózg a zachowanie*, (PWN, W-wa 1997).

Sztuczne sieci neuronowe powstały na gruncie wiedzy o działalności systemu nerwowego istot żywych i stanowią próbę wykorzystania zjawisk zachodzących w systemach nerwowych do poszukiwania nowych rozwiązań technologicznych. Komórka nerwowa – neuron – jest podstawowym elementem systemu nerwowego. Poznanie mechanizmów działania poszczególnych neuronów i ich współdziałania jest istotne dla zrozumienia procesów pozyskiwania, przesyłania, przetwarzania i wykorzystania informacji przebiegających w sieciach neuronowych. Z tego względu model neuronu rzeczywistego jest wyjątkowo ważny.

Każdy neuron składa się z ciała komórkowego zawierającego jądro oraz dwu rodzajów wypustek nerwowych: licznych dendrytów oraz aksonu. Sygnał wejś-

---

<sup>1</sup> Stanisław Osowski, *Sieci neuronowe w ujęciu algorytmicznym*, (WNT, Warszawa 1996): sieci neuronowe przedstawione są z punktu widzenia algorytmicznego – najbardziej użytecznego praktycznie. Pozycja ta to wyselekcjonowany przegląd najlepszych metod uczenia sieci o różnorodnej strukturze, zilustrowany wynikami wielu eksperymentów numerycznych oraz poparty zastosowaniami praktycznymi. Książka przeznaczona jest dla wszystkich zainteresowanych tą tematyką, zarówno dla początkujących jak i zaawansowanych w uprawianiu tej dyscypliny.

J. Hertz, A. Krogh, R.G. Palmer, *Wstęp do teorii obliczeń neuronowych*, (WNT, W-wa 1995): to zwięzły przegląd osiągnięć teorii obliczeń neuronowych. Ze względu na przejrzystość i dokładność książka ta jest przeznaczona dla szerszego kręgu odbiorców chcących zapoznać się z biologią układów neuronowych, ich optymalizowaniem oraz możliwością uczenia się i poznawania sieci.

D. Rutkowska, M. Piliński, L. Rutkowski, *Sieci neuronowe, algorytmy genetyczne i systemy rozmyte*, (PWN, Warszawa-Lódź 1997). Pozycja ta przybliży zagadnienia sieci neuronowych, algorytmów genetycznych i systemów rozmytych oraz wybranych powiązań między nimi i zastosowań.

ciowy (informacja, pobudzenie) doprowadzony jest do komórki za pośrednictwem synaps – wyspecjalizowanej struktury błonowej składającej się z zakończenia aksonu i części błony następnej komórki. Synapsy znajdują się głównie na dendrytach, ale i bezpośrednio na ciele komórki. Liczba kontaktów synaptycznych i dendrytów oraz długość i rozgałęzienia aksonów są różne dla różnych komórek. Niezmienna pozostaje jednak ich rola: jednokierunkowe przekazywanie pobudzenia od aksonu do dendrytów. Sama transmisja sygnałów wewnątrz systemu nerwowego jest skomplikowanym procesem chemiczno-elektrycznym.

Nie wdając się w szczegóły można powiedzieć, że przekazywanie impulsu nerwowego od jednej komórki do drugiej opiera się na wydzielaniu, pod wpływem nadchodzących od synaps bodźców, specjalnych substancji chemicznych zwanych neuromediatorami. Substancje te oddziałują na błonę komórki powodując zmianę jej potencjału elektrycznego. Zmiana ta jest tym silniejsza, im więcej neuromediatora pojawi się na błonie.

Poszczególne synapsy różnią się wielkością oraz możliwościami gromadzenia neuromediatora w pobliżu błony synaptycznej. Z tego powodu taki sam impuls docierający do pewnego wejścia komórki za pośrednictwem określonej synapsy może spowodować silniejsze lub słabsze jej pobudzenie niż dochodząc do innego wejścia tej samej komórki. Miarą stopnia pobudzenia komórki jest stopień polaryzacji jej błony, który z kolei zależy od sumarycznej ilości neuromediatora wydzielonego we wszystkich synapsach.

Każdemu wejściu komórki możemy przypisać współczynnik liczbowy (wagę), odpowiadający ilości neuromediatora wydzielonego jednorazowo na poszczególnych synapsach. Ponieważ ilość neuromediatora może wpływać bądź pobudzająco, bądź hamująco na pobudzenie komórki, więc wagi synaptyczne mogą przyjmować wartości rzeczywiste zarówno dodatnie, jak i ujemne.

W wyniku docierania impulsów wejściowych do poszczególnych synaps i uwolnienia odpowiednich ilości neuromediatora, następuje określone pobudzenie elektryczne komórki. Jeśli zaburzenie równowagi elektrycznej jest niewielkie, lub jeśli bilans pobudzeń i hamowań jest ujemny, komórka wraca samorzutnie do stanu początkowego, a na jej wyjściu nie da się dostrzec żadnej zmiany. Oznacza to, że pobudzenie komórki było mniejsze od tak zwanego progu jej zadziałania. Tylko wtedy, gdy suma pobudzeń i hamowań przekroczyła próg uaktywnienia komórki, sygnał wyjściowy lawinowo narasta i formuje się charakterystyczny kształt impulsu nerwowego. Impuls przesyłany jest aksonem do innych neuronów połączonych z daną komórką. Sygnał ten jest niezależny od tego, o jaką wartość próg zadziałania komórki zostaje przekroczony. Komórka działa na zasadzie: wszystko albo nic.

Po spełnieniu swojej roli neuromediator jest usuwany. Mechanizm jego usuwania polega bądź na wchłanianiu przez komórkę, bądź na rozkładzie, bądź też na przemieszczaniu się poza obszar synaps. Po wygenerowaniu impulsu przez komórkę nerwową zostaje uruchomiony proces refrakcji. Jest to gwałtowne podwyższenie progu uaktywnienia komórki do wartości nieskończonej. Dzięki temu bezpośrednio po wygenerowaniu impulsu neuron nie jest w stanie wygenerować następnego, nawet przy bardzo silnym pobudzeniu. Taki stan utrzymuje się przez pewien czas  $t_r$ , zwany okresem

refrakcji bezwzględnej. Po nim następuje okres refrakcji względnej  $t_w$ , w którym pobudzenie jest możliwe, ale musi być silniejsze od wartości progowej. Wreszcie próg zadziałania wraca do wartości spoczynkowej.

Liczba komórek nerwowych współpracujących ze sobą jest imponująco wielka. Przyjmuje się, że mózg ludzki zawiera  $10^{11}$  neuronów. Każdy z nich wykonuje stosunkowo proste funkcje sumowania wagowego sygnałów wejściowych i porównania otrzymanej sumy z wartością progową. Każdy z neuronów może mieć różne wagi i wartości progowe. Komórki nerwowe mózgu nie są jednak połączone ze sobą każda z każdą, lecz w sposób wybiórczy. W ten sposób tworzone są w obrębie mózgu specyficzne systemy operacyjne. Struktura taka powstaje na ogół w trakcie rozwoju osobniczego, ale może się modyfikować także w dorosłym układzie nerwowym.

Cechą charakterystyczną budowy mózgu jest jego hierarchiczna organizacja. Dzięki temu aktywność jednej, pobudzonej przez bodziec, komórki nerwowej może się coraz bardziej (i równomiernie) rozprzestrzeniać na wyższych poziomach sieci, albo też aksony kilku komórek niższego poziomu mogą zbiegać się na jednym neuronie poziomu wyższego.

Olbrzymia liczba neuronów i powiązań międzyneuronowych (do około 1000 wejść neuronu) powoduje, że błąd zadziałania pojedynczych neuronów ginie w ogólnej masie. Sieć neuronowa wykazuje dużą odporność na zakłócenia – jest siecią krępką, w której pojedyncze błędy nie mają zasadniczego wpływu na wynik działania.

Bardzo ważną cechą systemów nerwowych jest ich duża szybkość działania pomimo stosunkowo długiego cyklu działania pojedynczej komórki (rzędu milisekund). Jest to możliwe dzięki olbrzymiej równoległości przetwarzania informacji w mózgu stworzonej przez dużą liczbę neuronów i powiązań międzyneuronowych.

Jednocześnie trudność fenomenologicznego przedstawienia pracy mózgu polega na olbrzymiej liczbie zachodzących w nim równoległe operacji sieciowych. Trudność ta stała się możliwa do przezwyciężenia z chwilą pojawienia się komputerów. Ich moc obliczeniowa pozwoliła na skonstruowanie sieci neuropodobnych, realizujących niemal wiernie funkcje układu nerwowego. Sztuczne sieci neuronowe, różniące się od sieci biologicznych opisem elementów i budową układu, dają nadzieję na stworzenie nowej generacji układów elektronicznych. Szybkość działania i efektywność zostałyby wtedy znacznie zwiększone i przybliżone do poziomu występującego w sposób naturalny w przyrodzie.

Jak wskazuje opis, każdy neuron (biologiczny) jest pewnego rodzaju procesorem: sumuje z odpowiednimi wagami sygnały wejściowe pochodzące z innych neuronów, by utworzyć nieliniową (progową) funkcję sumy i przekazać ją do kolejnych neuronów z nim powiązanych. W związku ze wspomnianą zasadą progu uaktywnienia: wszystko albo nic, w pierwszych modelach neuronu przyjmowano sygnał wyjściowy w postaci binarnej 0 lub 1. Wartość 1 odpowiadała pobudzeniu neuronu (gdy pobudzenie było większe od progu uaktywnienia), natomiast wartość 0 odpowiadała brakowi pobudzenia (gdy pobudzenie było mniejsze od progu uaktywnienia).

Już w 1943 roku McCulloch i Pitts opracowali model komórki nerwowej przyjmując binarność neuronu. Model ten do dzisiaj stanowi podstawowe ogniwo większości używanych modeli sieci. Sygnały wejściowe  $x_j$  ( $j=1,2,\dots,N$ ) sumowane są z odpowiednimi wagami  $W_{ij}$  (sygnał przepływa w kierunku od węzła  $j$  do węzła  $i$ ) w sumatorze, a następnie porównywane z progiem  $b_i$ . Sygnał wyjściowy neuronu  $y_i$  wyraża się wówczas zależnością:

$$y_i = f\left(\sum_{j=1}^N W_{ij}x_j(t) + b_i\right).$$

Funkcja aktywacji  $f(\ )$  jest w tym modelu funkcją skokową:

$$F(\ ) = \begin{cases} 1 & \text{dla } (\ ) > 0 \\ 0 & \text{dla } (\ ) < 0. \end{cases}$$

Współczynniki  $W_{ij}$  występujące we wzorze reprezentują wagę połączeń synaptycznych: wartość  $W_{ij}$  dodatnia reprezentuje synapsę pobudzającą, ujemna – hamującą, zaś zerowa świadczy o braku połączenia między  $i$ -tym a  $j$ -tym neuronem.

Model McCullocha-Pittsa jest modelem dyskretnym, w którym stan neuronu w chwili  $t+1$  określany jest na podstawie stanu sygnałów wejściowych neuronów w chwili poprzedniej  $t$ . Jest to uzasadnione występowaniem zjawiska refrakcji w rzeczywistej komórce neuronowej, co oznacza, że neuron może zmieniać swój stan z pewną ograniczoną częstotliwością.

Modele neuronów oparte na modelu McCullocha-Pittsa mogą jednak różnić się między sobą. Typ przyjętej funkcji nieliniowej, w szczególności jej ciągłość, ma decydujący wpływ na wybór techniki uczenia neuronu (dobór wag).

Drugim czynnikiem różnicującym jest wybór strategii uczenia uzależniony od tego czy znany jest, czy nie, pożądany sygnał wyjściowy neuronu ( $d_i$ ).

Wyróżniamy więc dwa podejścia: uczenie z nauczycielem i uczenie bez nauczyciela. W tym drugim przypadku mamy dwie możliwości doboru wag: 1) na zasadzie konkurencji neuronów (strategia zwana Winner Takes All) bądź 2) stosując metodę uczenia Hebba.

Celem artykułu nie jest szczegółowe i wyczerpujące przedstawienie budowy sztucznego neuronu, podane więc zostanie tylko kilka przykładów dla ukazania zróżnicowania samych modeli neuronów.

Zwykłym modelem McCullocha-Pittsa tyle, że o odpowiednio przyjętej strategii uczenia jest prosty PERCEPTRON. Uczenie go należy do grupy uczenia z nauczycielem i polega na takim doborze wag  $W_{ij}$  oraz  $b_i$ , aby sygnał wyjściowy  $y_i$  był najbliższy wartości zadanej  $d_i$ .

Neuron typu SIGMOSOIDALNEGO ma strukturę podobną do modelu McCullocha-Pittsa z tą różnicą, że funkcja aktywacji jest ciągła i przyjmuje postać funkcji sigmoidalnej unipolarnej lub bipolarnej. Znana jest wartość na wyjściu, a więc uczenie neuronu jest uczeniem z nauczycielem.

Model neuronu typu ADALINE, opracowany przez Widrowa, także z sigmoidalną funkcją aktywacji charakteryzuje się ponadto adaptacyjnym sposobem doboru wag.

Dla neuronów typu INSTAR i uzupełniającego go OUTSTAR przyjmuje się liniową funkcję aktywacji, natomiast uczenie odbywa się według reguły Grossberga, która umożliwia wybór opcji pełnego zapomnienia poprzednio nauczonej wartości.

Neurony typu WINNER TAKES ALL tworzą grupę neuronów współzawodniczących ze sobą. Każdy z nich otrzymuje te same sygnały wejściowe  $x_j$ , lecz tylko ten o najwyższym sygnale wyjściowym (zależnym od aktualnych wartości wag) zwycięża i przyjmuje na wyjściu stan 1. Uczenie tego typu neuronów nie wymaga nauczyciela.

Inny model neuronu zaproponował Hebb badając działanie komórek nerwowych. Zauważył on, że powiązanie dwóch komórek jest wzmacniane, jeśli obie komórki są pobudzone w tym samym czasie. Stworzony na takich założeniach model neuronu HEBBA może przyjmować różne funkcje aktywacji, a uczenie może przebiegać w trybie z nauczycielem lub bez nauczyciela.

W odróżnieniu od modeli deterministycznych, których wartość wyjściowa jest określona, istnieją modele stochastyczne. W modelach takich stan wyjściowy neuronu zależy nie tylko od sumy ważonej sygnałów wejściowych, ale także od zmiennej losowej generowanej każdorazowo z zakresu (0,1).

Pojedyncze modele neuronów łączone są ze sobą na różne sposoby, różne są także sposoby ich wzajemnego współdziałania. Dzięki temu powstały różne typy sieci powiązane dodatkowo z odpowiednią metodą uczenia. Przedstawione będą tylko te najczęściej spotykane.

Sieć jednokierunkowa jest najbardziej popularnym typem sieci. Przepływ sygnałów odbywa się w niej w jednym kierunku – od wejścia do wyjścia. Przeważnie neurony ułożone są w warstwach, a powiązania międzyneuronowe dotyczą tylko neuronów z warstw sąsiednich. Warstwa pierwsza to warstwa wejściowa, złożona z buforów danych wejściowych. Warstwa ostatnia to warstwa wyjściowa, na której liczba neuronów odpowiada wymiarowi wektora zadanego  $d$ . W szczególnym przypadku może to być jeden neuron. Pozostałe warstwy umieszczone są między warstwami zewnętrznymi i – o ile istnieją – noszą nazwę warstw ukrytych. Ich liczba może być dowolna, tak jak dowolna może być liczba neuronów w tych warstwach. Ustalone jest natomiast połączenie międzywarstwowe i kierunek przepływu sygnału – od warstwy poprzedzającej do warstwy po niej następującej.

Sieć neuronowa rekurencyjna charakteryzuje się dowolnością powiązań neuronowych, przez które przepływ sygnałów może następować w obydwu kierunkach. Ze względu na istniejące sprzężenie zwrotne, ustalenie wartości sygnałów wyjściowych nie odbywa się w sposób bezpośredni.

Inny rodzaj powiązań międzyneuronowych reprezentuje sieć komórkowa. Poszczególne neurony takiej sieci powiązane są jedynie lokalnie ze swoimi sąsiadami, przy czym powiązanie to jest wzajemne (dwukierunkowe) i dotyczy neuronów należących do tzw. sąsiedztwa. Model takiej sieci jest bardzo skomplikowany ze względu na liczne wzajemne powiązania neuronów.

Pojęcie „uczenia się” dotychczas zostało tylko nadmienione przy okazji przedstawienia różnych modeli neuronów. Uczenie sieci jest jej pro-

gramowaniem, mającym na celu takie dobranie wag połączeń, by sieć potrafiła wykonać określone zadanie. Czasami możliwe jest zaprojektowanie sieci przez wpisanie do niej na stałe pewnych informacji. Częściej jednak sieć „jest uczona” wykonania pewnych obliczeń przez iteracyjne dostrajanie wartości wag poszczególnych neuronów. Uczenie takie może przebiegać pod nadzorem (uczenie z nauczycielem). Polega ono na porównaniu sygnału wyjściowego sieci ze znanymi prawidłowymi odpowiedziami. Gdy jednak brak jest konkretnych prawidłowych przykładów, sieć musi sama stworzyć te kategorie na podstawie jedynie dostępnych korelacji danych wejściowych. Mamy wtedy do czynienia z uczeniem bez nadzoru, które w wielu przypadkach, na przykład w systemach ekspertowych i robotyce, pomaga zaoszczędzić na czasie i koszcie programowania.

Możliwość uczenia się jest niewątpliwą zaletą sztucznych sieci neuronowych. Dodatkowo mają one zdolność uogólniania zdobytej wiedzy. Sieć nauczona na pewnym zbiorze danych generuje właściwe wyniki nawet przy podaniu na jej wejściu danych wprawdzie należących do tej samej grupy, ale wcześniej jej nie prezentowanych. Dzięki takim właśnie cechom sieci neuronowe zaliczamy do układów charakteryzujących się sztuczną inteligencją. Przez to właśnie są one wykorzystywane do operacji i zadań bardziej skomplikowanych niż te, które do tej pory wykonywały komputery.

Stosuje się sieci neuronowe między innymi do tworzenia struktur druzgórzędowych białka (lokalna konfiguracja liniowych sekwencji 20 różnych aminokwasów w postaci spirali). Tworzone są algorytmy wyznaczania miejsc podziału wyrazów na sylaby. Bardzo dobre wyniki uzyskano już w uczeniu sieci rozpoznawania znaków pisanych (litery, cyfry) – rozpoznawanie ręcznie pisanych kodów pocztowych jest już wykorzystywane przez pocztę USA. Wykorzystywana jest sztuczna sieć neuronowa do rozpoznawania przedmiotów przy pomocy sonaru. Wreszcie czynione są próby nauczania sieci neuronowej rozpoznawania mowy, co ze względu na złożoność problemu jest chyba największym wyzwaniem dla wielu zespołów naukowych.

Najbardziej złożona naturalna sieć komórek nerwowych, jaką jest mózg człowieka, ma – i zawsze będzie mieć – przewagę nad komputerem cyfrowym w wielu zadaniach. Przykładem jest przetwarzanie informacji wizualnej: roczne dziecko o wiele lepiej i szybciej rozpoznaje przedmioty, twarze itp. niż nawet najbardziej rozwinięte systemy sztucznej inteligencji uruchamiane na najszybszych superkomputerach.

Właściwościami, dzięki którym mózg przewyższa systemy sztuczne jest między innym jego odporność na uszkodzenia (codziennie umiera wiele komórek nerwowych nie przynosząc szkody całościowemu funkcjonowaniu mózgu). Mózg jest elastyczny tzn. przystosowuje się przez uczenie do zmieniających się warunków otoczenia. Jest w stanie poradzić sobie z informacją rozmytą, losową, zaszumioną lub niespójną. Informacje przepływają w mózgu w sposób równoległy, a on sam jest mały, zwarty i zużywa bardzo mało energii.

Wymienione zalety mózgu ludzkiego stały się bodźcem do konstruowania modeli zbliżających się do ideału. Kopiowanie żywych systemów ner-

wowych daje nadzieje na stworzenie nowej generacji układów elektro-  
nicznych – neurokomputerów.

Komputer, którego praca oparta by była na zasadach funkcjonowania sys-  
temu nerwowego, cechowałby się ogromną szybkością działania, równo-  
ległością przepływu informacji, elastycznością i krzepkością. Są to cechy  
niedosięgnięte dla standardowych systemów elektronicznych (komputerów  
cyfrowych). Tylko czy rzeczywiście możliwe jest stworzenie czegoś tak  
doskonałego, występującego jedynie w przyrodzie?

Dzisiejszy stan wiedzy nie daje możliwości bardzo dokładnego poznania  
budowy i funkcjonowania mózgu czy wybranego fragmentu układu ner-  
wowego. A przecież to właśnie układ nerwowy, mniej lub bardziej złożony,  
jest oryginałem, na podstawie którego tworzony jest model. Nasuwa się  
pytanie, czy wobec nieznamości oryginału można stworzyć model tak  
samo złożony i doskonały jak oryginał?

Inżynierowie, technicy zgodnie przyznają, że tworzona struktura jest  
bardzo uproszczona (zarówno na poziomie neuronów jak i całej sieci), a ich  
zadaniem w żadnym wypadku nie jest stworzenie modelu wiernego orygina-  
łowi. Tworzone są więc modele matematyczne (wzory opisujące  
przepływ informacji), modele elektryczne (schematy przepływu informacji  
przyrównywanej do przepływu bodźca w postaci energii elektrycznej), ale  
ciągle nie ma modelu, który łączyłby budowę z istotą działania.

Problem informacyjnego modelowania mózgu przedstawił profesor M.  
Lubański w rozdziale *Informacja – system* w pracy M. Hellera, M.  
Lubańskiego, S.W. Ślęgi *Zagadnienia filozoficzne współczesnej nauki* (Wyd.  
ATK, W-wa 1997). Istotą takiego modelowania jest to, w jakim stopniu  
prawa transformacji informacji (przepływu bodźców), którym podlega w  
swej pracy mózg ludzki, mogą być odtworzone na innym substracie.

Modelowania sieci neuronowej dokonuje się na komputerze, pisząc dla  
niego odpowiedni program, bądź też tworząc obiekt fizycznie istniejący –  
neuroprocesor. Maszyny tak wyposażone nazywamy inteligentnymi ze  
względu na tę cechę przydaną sieciom neuronowym.

Wprawdzie wszystkie programy zawdzięczają swą inteligencję twórcy –  
człowiekowi programiście, to sztuczne sieci neuronowe cechuje jednak  
zdolność samouczenia się, a więc skądinąd samodoskonalenia. W jakim  
stopniu jednak są one inteligentne – czy jest już to inteligencja własna  
(sztuczne sieci – sztuczna inteligencja), czy jeszcze inteligencja pro-  
gramisty, pozostaje problemem nierozstrzygniętym. Maszyna jest ciągle  
maszyną, czyli narzędziem w rękach człowieka i od człowieka zależy, na ile  
jest ona „inteligentna”. Innym problemem jest to, że pojęcie „sztuczna  
inteligencja” rozszerza swoje znaczenie, a maszyny zyskują cechy zas-  
trzeżone dla organizmów żywych, między innymi dzięki właśnie sztucznym  
sieciom neuronowym.