

i reguł są dołączane liczbowe współczynniki pewności, wnioskowanie prowadzi się w oparciu o schematy logik wielowartościowych. W przypadku reprezentacji danych niepewnych w postaci zbiorów rozmytych stosuje się różne metody wnioskowania rozmytego, które - mówiąc bardzo ogólnie - polegają na wyznaczeniu rozmytych konkluzji reguł i ich zamianie na ostre wartości liczbowe.

Współcześnie systemy eksperckie są stosowane tak powszechnie i w tak wielu dziedzinach, że można wyróżnić wśród nich pewne kategorie. Ze względu na rodzaj współpracy z człowiekiem dzieli się je na: 1) *doradcze* - czyli takie, które współpracują aktywnie z użytkownikiem, przedstawiają mu różne rozwiązania do wyboru i są w stanie modyfikować je w zależności od zgłaszanych sugestii, 2) *samodzielne* - czyli takie, które działają bez kontroli człowieka (np. sterując obiektami lub procesami), 3) *krytykujące* - a więc takie, które na podstawie przedstawionego przez użytkownika problemu i rozwiązania dokonują analizy tego ostatniego. Ze względu na pewność przetwarzanej informacji rozróżnia się: 1) *systemy z wiedzą pewną* - tutaj wnioskuje się zazwyczaj w oparciu o logikę klasyczną, 2) *systemy z wiedzą niepewną* - przetwarzaną zwykle w oparciu o logikę wielowartościową, rozmytą lub aparat probabilistyczny. Z uwagi na stopień ogólności zastosowań mówi się o: 1) *systemach wyspecjalizowanych* - o reprezentacji wiedzy i metodach wnioskowania dostosowanych do konkretnej, bardzo wąskiej, dziedziny problemowej, 2) *systemach szkieletowych* - o pustej, ale określonej ogólnie bazie wiedzy, którą można wypełnić informacjami z różnych dziedzin.

Techniki koneksyjne. Informatyczne techniki koneksyjne³⁵, nazywane też neuropodobnymi, stanowią podstawę działania konkretnych systemów do przetwarzania danych, zwanych też sztucznymi sieciami neuronowymi³⁶. Idea tychże układów zrodziła się w ramach badań cybernetycznych, zaś wywodzi się wprost z elementarnej obserwacji biologicznej, że mózg - a więc najbardziej skuteczny z naturalnych systemów do przetwarzania informacji - stanowi w istocie skomplikowaną sieć neuronów. Owocem prób połączenia tej obserwacji ze światem techniki stały się: zrazu pierwszy matematyczny model komórki nerwowej [McCulloch, Pitts 1943], a niedługo potem modele i fizyczne realizacje sieci sztucznych komórek [Widrow, Hoff 1960].

Współcześnie dziedzina projektowania sztucznych sieci neuronowych jest niezwykle szeroko rozwinięta³⁷. Choć proponowane rozwiązania (będące dzie-

³⁵ Określenie *koneksyjne* pochodzi od angielskiego terminu *connectionism*, który oznacza technikę równoległego i rozproszonego przetwarzania danych, wykorzystywaną przede wszystkim w dziedzinie sztucznych sieci neuronowych.

³⁶ Zawarte w niniejszym ustępie ogólne informacje o technikach koneksyjnych pochodzą przede wszystkim z książek [Tadeusiewicz 1993] oraz [Żurada 1992].

³⁷ Wyraża się to między innymi w oszalałającej liczbie zastosowań. Ponieważ sztuczne sieci neuronowe są w istocie pewnymi systemami do podejmowania decyzji, ich zastosowania w dużej mierze pokrywają się z zastosowaniami systemów eksperckich. Przed wszystkim dotyczy to rozpoznawania/diagnozowania, predykcji i sterowania. Spośród innych typowych zadań powierzanych sieciom warto

łem inżynierów) wykazują dość luźne związki z funkcjami naturalnych układów neuronalnych, to ich ogólne własności - własności odróżniające je od tradycyjnych systemów informatycznych - pokrywają się z cechami układów naturalnych. W tym kontekście wymienia się najczęściej trzy cechy: **równoległe przetwarzanie sygnałów, zdolność do uczenia się i stosunkowo małą wrażliwość na uszkodzenia części struktury**.

Podobnie jak ich naturalne pierwowzory sztuczne układy neuronalne składają się z ogromnej liczby identycznych elementów przetwarzających, tzw. *sztucznych neuronów*. Elementy te odbierają z otoczenia pewne sygnały wejściowe, przetwarzają je i generują wyniki - interpretowane, na przykład, jako reakcje na bodźce percepcyjne czy rozwiązania problemów. Poszczególne neurony są połączone albo ze wszystkimi innymi neuronami sieci, albo z pewną ich wyróżnioną grupą, na przykład kolejną warstwą. Z każdym połączeniem międzyneuronalnym jest skojarzona pewna liczba z określonego zakresu (np. [0,1]), nazywana wagą. Wagi decydują o tym, jak silne sygnały docierają do odpowiednich neuronów: wartości mniejsze osłabiają sygnał, wartości większe - wzmacniają go. W większości przypadków wszystkie neurony - odbierające i wysyłające sygnały za pośrednictwem połączeń o określonych wagach - działają identycznie, tj. zgodnie z przyjętym przez konstruktora modelem komórki nerwowej. Na przykład mnożą sygnały odbierane od innych neuronów przez wagi połączeń, otrzymane iloczyny dodają, do sumy stosują pewną funkcję matematyczną i otrzymany wynik przekazują kolejnym neuronom³⁸.

Działanie sieci jako całości polega na równoległym propagowaniu sygnałów przez kolejne grupy neuronów w celu uzyskania sygnału wyjściowego, tożsamego zwykle z sygnałem elementów wyróżnionych, tzw. *neuronów wyjściowych*. O odpowiedzi sieci na konkretny sygnał wejściowy decyduje wcześniejszy *trening*. W jego trakcie zachodzą stopniowe zmiany wag połączeń międzyneuronalnych - zmiany kontrolowane przez odpowiedni algorytm i ukierunkowane na pożądane działanie sieci. Po zakończeniu treningu sieć nie zmienia ustalonej struktury wewnętrznej, a jej zachowanie można przyrównać do czarnej skrzynki, która zamienia pewne informacje wejściowe na gotowe reakcje.

wymienić: 1) *przetwarzanie sygnałów i obrazów* - sieci realizują klasyczne zadania przetwarzania sygnałów i obrazów, np. konwersję, filtrację, aproksymację, transformatę Fouriera, kompresję; 2) *uczenie się* - sieci neuronowe są najczęściej wykorzystywanym narzędziem do pozyskiwania wiedzy; często łączy się je z omawianymi dalej algorytmami genetycznymi; 3) *optymalizacja* - sieci stosuje się z powodzeniem do rozwiązywania zagadnień optymalizacji o bardzo dużej złożoności obliczeniowej, np. klasycznego zagadnienia komiwojażera. Dodajmy też, że część informatyków wiąże duże nadzieje z *neurokomputerami*, czyli komputerami opartymi na sieciach neuronowych, które byłyby w stanie przetwarzać informacje równoległe i w sposób rozproszony. Jednocześnie trwają prace nad różnymi modelami *pamięci skojarzeniowych*, które mogłyby uzupełniać inne rodzaje pamięci. Por. [Tadeusiewicz 1993].

³⁸ Takie zasady przetwarzania sygnałów określa pierwszy z matematycznych modeli komórki nerwowej autorstwa McCullocha i Pittsa [McCullocha, Pitts 1943].

Zaznaczmy na koniec, że o możliwościach konkretnej sieci decydują funkcje neuronów i struktura ich wzajemnych połączeń. Ten drugi element ma o wiele większe znaczenie. Wagi połączeń reprezentują w pewien szczególny sposób „wiedzę” całej sieci, mianowicie w ich wartościach odzwierciedla się ogół możliwych powiązań pomiędzy dostępnymi sieci bodźcami i jej możliwymi reakcjami. Ponieważ zapis taki ma na celu po prostu skuteczne działanie sieci, a nie ukonstytuowanie jakichś przejrzystych znaczeniowo (dla człowieka) symboli i związków pomiędzy nimi, nazywa się go *subsymbolicznym*.

Zarysowane wyżej ogólne zasady działania sztucznych sieci neuronowych zobrazujemy przykładem *perceptronu* - tj. pewnej często stosowanej i dobrze poznanej sieci wielowarstwowej³⁹. Sieć taka składa się z warstwy wejściowej - złożonej z neuronów odbierających bodźce z otoczenia, warstw ukrytych - których neurony odbierają sygnały z warstw bezpośrednio je poprzedzających, przetwarzają je i przekazują neuronom z warstw bezpośrednio po nich następujących, oraz z warstwy wyjściowej - o neuronach, których zbiorczy sygnał jest interpretowany jako odpowiedź sieci na dany bodziec wejściowy. W zależności od liczby warstw i funkcji neuronów można mówić się o różnych rodzajach perceptronów.

W celu przybliżenia funkcji perceptronów, a tym samym i innych sieci wielowarstwowych, rozważymy trójwarstwowy układ o konkretnym zastosowaniu. Niech nasz hipotetyczny układ służy do rozpoznawania znaków reprezentowanych przez matryce punktów o wymiarach 15×10 punktów (znak definiują zaznaczone punkty matrycy). Po zakończeniu treningu sieć ma poprawnie klasyfikować znaki jako elementy jednej z 20 różnych klas. Co ważne, ma rozpoznawać prawidłowo nie tylko znaki prezentowane w trakcie treningu, ale również podobne do nich, na przykład narysowane częściowo lub charakteryzujące się nieco innym rozkładem punktów.

Z uwagi na opisane powyżej przeznaczenie, układ powinien zawierać warstwę wejściową o 150 neuronach reprezentujących poszczególne punkty matrycy znaku, warstwę wyjściową o 20 neuronach reprezentujących rozpoznawane klasy znaków i wybraną liczbę warstw ukrytych (nasz przykład będzie miał tylko jedną warstwę). W trakcie uczenia się oraz działania neurony przyjmują tylko dwa stany, reprezentowane liczbami -1 i 1. W przypadku neuronu wejściowego 1 oznacza zaznaczenie odpowiadającego mu punktu matrycy, zaś w przypadku neuronu wyjściowego 1 oznacza, że prezentowany znak należy do klasy odpowiadającej temu neuronowi (-1 oznacza fakt przeciwny). Poszczególne neurony danej warstwy są połączone ze wszystkimi neuronami warstwy poprzedniej. Każdy z nich mnoży odbierane sygnały przez wagi połączeń, otrzymane iloczyny dodaje i stosuje do nich specjalnie dobraną funkcję matematyczną⁴⁰.

³⁹ Pierwsza praca na jego temat to [Rosenblatt 1968].

⁴⁰ W literaturze rozpatruje się bardzo wiele takich funkcji. Jedną z najczęściej używanych jest tzw. sigmoidalna funkcja logistyczna, $f(x) = 1/(1 + \exp(-bx))$, gdzie b jest parametrem, a x sumarycznym pobudzeniem neuronu.

Wagi połączeń, reprezentujące wiedzę sieci o kształtach znaków, są ustalane w trakcie procesu uczenia się.

Uczenie się rozpoczyna się od losowego przypisania wagom połączeń liczb z przedziału $[-1,1]$. Następnie, zgodnie z określoną strategią, na wejście sieci są wprowadzane sygnały reprezentujące kolejne znaki wzorcowe; sygnały te są propagowane przez neurony kolejnych warstw, po czym jest rejestrowany stan neuronów warstwy ostatniej. Stan ten jest każdorazowo porównywany z pożądaną reakcją sieci (uczenie ma charakter nadzorowany, to znaczy wiemy do jakiej klasy przynależą prezentowane wzorce i potrafimy wskazać odpowiadający im neuron). Obserwowana różnica między pożądanym a rejestrowanym sygnałem neuronów wyjściowych stanowi podstawę do modyfikacji wag połączeń. Modyfikacja przebiega w oparciu o typowy dla perceptronów algorytm wstecznej propagacji błędów [Rumelhart, Hinton, Williams 1986]. Uczenie kończy się wtedy, kiedy w kolejnym cyklu prezentacji sieć rozpoznaje wzorce bezbłędnie.

Wytrenowany perceptron można wykorzystać jako klasyfikator nieznanych znaków. Odpowiadający nowemu znakowi sygnał jest propagowany poprzez kolejne warstwy sieci, aż do ustalenia się stanu neuronów warstwy ostatniej. Decyzję sieci reprezentuje neuron emitujący największy sygnał (na przykład zwyciężski neuron nr 5 oznacza, że pokazywany znak należy do klasy nr 5).

Oprócz sieci wielowarstwowych - omówionych wyżej na przykładzie perceptronu - tworzy się wiele innych rodzajów sieci. W literaturze przedmiotu opisano ich tak wiele, że nawet pobieżny przegląd ich zasad działania wykracza poza przyjęte ramy rozdziału. Zauważmy tylko, że najczęściej stosowanymi kryteriami podziału są: struktura wewnętrzna sieci i stosowana metoda uczenia się.

I tak na przykład ze względu na strukturę połączeń międzyneuronalnych i sposób propagacji sygnału wyróżnia się: sieci *jednowarstwowe, wielowarstwowe, jednokierunkowe, dwukierunkowe, ze sprzężeniami zwrotnymi*, sieci *o połączeniach typu „każdy neuron z każdym”*, sieci *o zadanej z góry topologii połączeń*. Każda z nich ma swoje wady i zalety, a także konkretne obszary zastosowań. Szczególnie ciekawym rodzajem sieci są tzw. *sieci stanów stabilnych*, w których nie obowiązuje podział na elementy wejściowe, przetwarzające i wyjściowe. Sygnał podawany na wszystkie neurony układu jest przetwarzany dotąd, aż zostanie osiągnięty jeden ze stanów stabilnych; stany takie interpretuje się jako możliwe reakcje sieci na bodźce [Tadeusiewicz 1993, s. 141-164].

Ze względu na stosowane metody treningu (modyfikacji wag połączeń) sieci dzieli się na: uczone w sposób *nadzorowany* - kiedy nauczyciel wymusza określone reakcje na bodźce i uczone w sposób *nienadzorowany* - kiedy sieć sama dochodzi do optymalnych reakcji. W obydwu wypadkach proponuje się bardzo wiele metod, które wywodzą się nie tylko z teorii matematycznych (np. gradientowych metod optymalizacji), ale również z obserwacji psychologicznych (np. wymuszanie rywalizacji między poszczególnymi neuronami,

nagradzanie i karanie neuronów ze względu na cel uczenia się). W sieciach rozbudowanych, gdzie mamy do czynienia z podziałem zadań między wyspecjalizowane grupy neuronów, często stosuje się różne metody uczenia się, dostosowane do funkcji poszczególnych grup. (Por. [Hinton 1999])⁴¹.

Algorytmy genetyczne. Idea algorytmów genetycznych została wprowadzona do informatyki pod koniec lat 60-tych XX wieku przez J. Hollanda [Holland 1968 i 1975]. Kierowany przez niego zespół już na początku badań postawił sobie dwa, dość ambitne, cele: 1) opisać i wyjaśnić istotę procesów adaptacyjnych w przyrodzie, 2) stworzyć użyteczne oprogramowanie działające na wzór systemów biologicznych. Jakkolwiek cele te są dalekie od pełnej realizacji, techniki ewolucyjne doczekały się wielu zastosowań, z których większość mieści się w formule sztucznej inteligencji. Poniżej przedstawimy

⁴¹ Kończąc ogólną charakterystykę sztucznych sieci neuronowych (SSN), warto wspomnieć o innym, pokrewnym im, modelu przetwarzania danych, a mianowicie o *automatach komórkowych* (AK). Idea AK została wprowadzona do informatyki przez J. von Neumanna (z istotnym udziałem polskiego matematyka Stanisława Ulama) zupełnie niezależnie od badań nad SSN. Również dziś według dość powszechnej opinii obydwie modele przetwarzania danych są **względem siebie alternatywne**. (Por. np. [Białynicki-Birula 2007]).

Poniżej będziemy argumentować za bezzasadnością tej opinii, dokładniej zaś, postaramy się wyjaśnić, że AK należy potraktować jako **szczególny (graniczny) przypadek SSN**. Oto argumentacja.

1) Klasyczny AK stanowi zbiór komórek powiązanych ze sobą określoną relacją sąsiedztwa, zmieniających swoje stany (zwykle dyskretne, np. binarne) równolegle i synchronicznie, w oparciu o reguły określające nowy stan danej komórki zależnie od stanów komórek sąsiednich. Synchroniczna zmiana stanu wszystkich komórek prowadzi do nowego stanu automatu (jako całości).

2) Struktura AK - będącego zbiorem identycznych komórek powiązanych ze sobą określoną relacją sąsiedztwa - przypomina strukturę prostej (skrajnie uproszczonej) SSN, w której wagi połączeń międzyneuralnych mogą przyjmować wartości 0 i 1 (0 oznacza brak sąsiedztwa, 1 - sąsiedztwo). Rozszerzając relację sąsiedztwa o wagi połączeń między komórkami sąsiednimi, uzyskuje się strukturę klasycznych sieci neuronowych.

3) Działanie AK - polegające na synchronicznych zmianach stanów pojedynczych komórek zależnie od stanów komórek sąsiednich i pewnych ogólnych reguł zmian - także przypomina działanie SSN. W przypadku sieci bowiem stany (sygnały) sztucznych neuronów są zmieniane również równolegle, na podstawie stanów (sygnałów) neuronów z nimi połączonych i wag odpowiednich połączeń, zgodnie z jednolitymi dla całej sieci regułami zmian. Trzeba zauważyć - podobnie jak wyżej odnośnie struktury - że uzupełniając tradycyjne reguły zmian stanów komórek w AK o jakieś odniesienie do hipotetycznych wag połączeń między komórkami sąsiednimi (o ile tradycyjną koncepcję AK rozszerzymy o wagi niebinarne), uzyskujemy reguły charakteryzujące *de facto* SSN.

Powyższą argumentację traktujemy jako uzasadnienie braku szerszego omówienia automatów komórkowych w niniejszej książce - co mogłoby mieć sens gdyby model ten można było uznać za alternatywny wobec modelu konekcyjnego.