


Sztuczne sieci neuronowe

Krystyna AMBROCH, Gdańsk

1. Wprowadzenie

Pomysł budowy sztucznych sieci neuronowych zrodził się w latach czterdziestych ubiegłego wieku. Zaczęto od matematycznego, uproszczonego opisu biologicznego neuronu. Droga do jego sztucznego odpowiednika wiodła nie przez odtwarzanie jego budowy lecz przez naśladowanie sposobu przetwarzania i przesyłania informacji.

Transmisja sygnałów wewnątrz układu nerwowego jest skomplikowanym procesem chemiczno-elektrycznym. Zasadniczą rolę w przekazywaniu sygnałów do komórki nerwowej odgrywają synapsy (gr. *synapsis* – połączenia), patrz rys. 1.



Rys. 1. Budowa komórki nerwowej w uproszczeniu. Z ciała komórki odchodzą liczne wypustki, zwane *dendrytami*, które stanowią „wejścia” neuronu; są one odbiornikami pobudzeń. Połączone z ciałem tej komórki długie włókno, zwane *aksonem*, przewodzi, z udziałem synapsy, odebrane przez dendryty pobudzenie, do następnych neuronów.


Wielkość danej synapsy oraz ilość nagromadzonych na niej specjalnych substancji chemicznych, zwanych neuromediatorami, ma wpływ na wzmocnienie lub osłabienie impulsu docierającego do „wejścia” komórki za pośrednictwem tego połączenia. Ponieważ do danego neuronu docierają sygnały równocześnie z wielu neuronów, stopień pobudzenia neuronu zależy od sumy wielkości wszystkich przesłanych mu impulsów.

Budując model, wejściom komórki można przypisać współczynniki liczbowe, zwane wagami, odpowiadające ilości neuromediatora wydzielonego jednorazowo na poszczególnych synapsach. Gdy wagi są liczbami rzeczywistymi dodatnimi – mówimy o pobudzeniu komórki, przy wagach ujemnych – o hamowaniu pobudzenia neuronu przez inne synapsy. Jeśli bilans pobudzeń i hamowań jest ujemny – komórka wraca samorzutnie do stanu początkowego, a na jej wyjściu nie da się dostrzec żadnej zmiany. Mówimy wówczas, że pobudzenie komórki było mniejsze od progu jej zadziałania. Jeśli jednak suma pobudzeń i hamowań przekroczyła próg uaktywnienia komórki, wówczas sygnał wyjściowy lawinowo narasta i następnie jest przesyłany do innych neuronów połączonych z daną komórką.

Podobnie jak w przypadku neuronowych sieci biologicznych, podstawowymi elementami, z których buduje się sztuczne sieci neuronowe, są sztuczne

neurony, nazywane *neuronami*. Neurony najczęściej rozmieszczone są w warstwach, patrz rys. 2. Pierwsza warstwa neuronów nazywana jest *warstwą wejściową*. Odpowiada ona za wprowadzenie danych do sieci. Liczba neuronów znajdujących się w tej warstwie jest równa liczbie wartości wprowadzanych jednocześnie do sieci. Ostatnia warstwa neuronów, zwana warstwą wyjściową, służy do wyznaczania wartości wyjściowych sieci. Pomiędzy wymienionymi warstwami mogą znajdować się *warstwy ukryte*. Zadaniem neuronów należących do poszczególnych warstw ukrytych jest realizowanie kolejnych etapów przetwarzania informacji wejściowych w informacje wyjściowe.


Neurony znajdujące się w sąsiadujących warstwach są połączone. Połączenia tworzą ścieżki, po których przesyłane są informacje w sieci. Nie w każdej strukturze sieci połączenia mają charakter jednokierunkowy.



Rys. 2. Przykładowa struktura sztucznej sieci neuronowej dwuwarstwowej (w nazwie podaje się tylko liczbę warstw ukrytych łącznie z wyjściową). Ta sieć neuronowa ma 2 neurony w warstwie wejściowej, 3 – w warstwie ukrytej i 1 – w warstwie wyjściowej.

2. Model sztucznego neuronu

Przyjrzyjmy się (patrz rys. 3) modelowi typowego neuronu, tzn. neuronu występującego w warstwie ukrytej lub wyjściowej. Taki neuron składa się z dwóch, zasadniczych dla jego funkcjonowania, elementów: *bloku sumowania* Σ i *bloku aktywacji* F .



Rys. 3. Model sztucznego neuronu

Neuron przetwarza wektor $\mathbf{x} = [x_i]$, wymiaru $(n \times 1)$, sygnałów wejściowych x_i na jeden sygnał wyjściowy y . x_i ($i = 1, \dots, n$) i y są najczęściej liczbami rzeczywistymi z pewnych ograniczonych przedziałów, zaś n jest liczbą neuronów w warstwie wcześniejszej. Na podstawie danych x_i , w bloku sumowania Σ , obliczana jest wartość $\varphi = \vartheta(x)$ *funkcji agregującej* ϑ .

W najprostszym przypadku funkcja ϑ jest kombinacją liniową sygnałów wejściowych x_i , określoną równaniem:

$$\vartheta(x) = \sum_{i=1}^n w_i x_i = \mathbf{w}^T \mathbf{x}$$

gdzie: $\mathbf{x} = [x_i]$ jest wektorem $(n \times 1)$ sygnałów wejściowych, $\mathbf{w} = [w_i]$ jest wektorem $(n \times 1)$ współczynników, będących liczbami rzeczywistymi i zwanymi wagami, które z jednej strony wyrażają stopień ważności informacji przekazywanej i -tym wejściem, a z drugiej stanowią swego rodzaju pamięć neuronu.


Następnie sygnał φ jest przetwarzany przez blok aktywacji F , dający na wyjściu sygnał wyjściowy y , który – w sieciach o najprostszym strukturach – związany jest z wartością φ funkcji agregującej ϑ zależnością, zwaną funkcją aktywacji, która może być postaci:

$$y = \begin{cases} 1 & \text{gdy } \varphi > \varphi_k \\ 0 & \text{gdy } \varphi \leq \varphi_k \end{cases},$$

gdzie φ_k jest zadaną wartością progową.

Wykorzystanie struktury sztucznej sieci neuronowej do rozwiązania wybranego problemu, np. rozpoznawania obrazów lub klasyfikacji, wymaga wyznaczenia wag połączeń między neuronami sąsiednich warstw. Wyznaczanie wag nazywane jest *uczeniem*. Sposób uczenia zależy od celu, którym jest rodzaj postawionego problemu. Uczenie odbywa się na poziomie poszczególnych neuronów.

Załóżmy, że celem jest zbudowanie modelu opisującego zależność pomiędzy zmiennymi wejściowymi X_1 i X_2 a zmienną D . Budowany model składa się z jednego neuronu.



Rys. 4. Rysunek poglądowy postawionego problemu

Generowana przez sieć – po wprowadzeniu wektora $\mathbf{x} = [x_1, x_2]$ wartości zmiennych wejściowych X_1 i X_2 – wartość y zmiennej wyjściowej Y zależy od wektora $\mathbf{w} = [w_1, w_2]$ wartości wag:

$$y = f(\mathbf{w}).$$

Procedura uczenia jest iteracyjna:

$$\mathbf{w}_{i+1} = \mathbf{w}_i - \alpha \nabla E(\mathbf{w}_i),$$

gdzie: wektor \mathbf{w}_0 jest wybrany losowo, $i + 1 = 1, 2, \dots, m$; m jest ostatnim krokiem tej procedury, $\nabla E(\mathbf{w})$ jest gradientem funkcji błędu


$$E(\mathbf{w}) = (D - f(\mathbf{w})),$$

α – współczynnikiem uczenia, dobieranym tak, by uniknąć zatrzymania algorytmu uczenia w minimum lokalnym funkcji błędu. Procedura uczenia zmierza do takiego doboru wektora \mathbf{w} , dla którego wartość funkcji błędu jest najmniejsza.

3. Liniowa sieć neuronowa

Przyjrzyjmy się teraz najbardziej charakterystycznym strukturalom sieci i sposobom ich uczenia. Do najprostszych należy *sieć liniowa*, która składa się z dwóch warstw: warstwy wejściowej (jej zadaniem jest wstępne przetworzenie danych wejściowych: normalizacja, skalowanie) i liniowej warstwy wyjściowej (w neuronach tej warstwie *funkcja agregująca* ϑ jest liniowa oraz liniowa jest *funkcja aktywacji*). Sieć liniowa nie posiada warstw ukrytych. Sieć o tej strukturze jest dogodnym narzędziem do opisu zależności liniowych. Jest również wykorzystywana do redukcji wymiaru przestrzeni danych wejściowych – w modelach realizujących analizę głównych składowych.

Neuron liniowy warstwy wyjściowej jest zdolny do rozpoznawania sygnałów wejściowych.



Rys. 5. Model neuronu liniowego

Sygnał wyjściowy y ,

$$y = \mathbf{w}^T \mathbf{x} = \sum_{i=1}^n w_i x_i,$$

gdzie:


$\mathbf{x} = [x_i]$ jest wektorem $(n \times 1)$ sygnałów wejściowych, $\mathbf{w} = [w_i]$ jest wektorem $(n \times 1)$ wag, tego neuronu będzie tym większy, im bardziej położenie wektora wejściowego \mathbf{x} w przestrzeni wejść przypominać będzie położenie wektora wag \mathbf{w} w przestrzeni wag. W ten sposób można powiedzieć, że neuron rozpoznaje sygnały wejściowe, wyróżniając te, które są podobne do jego wektora wag.

W warstwie każdy neuron dostaje ten sam wektor sygnałów wejściowych, natomiast ma swój własny wektor wag; wektor wag jest mu przydzielony losowo lub jest pozostałością po wcześniejszym uczeniu sieci. Pojawienie się określonego wektora wejściowego \mathbf{x} powoduje powstanie sygnałów wyjściowych y_i , ($i = 1, \dots, n$), na wyjściach wszystkich n neuronów rozważanej warstwy. Największy sygnał wyjściowy y_m pojawi się na tym neuronie, którego wektor wag \mathbf{w} najbardziej przypomina \mathbf{x} .

Sieć tego typu może rozpoznawać n różnych klas obiektów (np. rozpoznawać litery i cyfry i odpowiednio je klasyfikować), gdyż każdy neuron zapamiętuje jeden wzorcowy obiekt, na którego pojawienie jest „uczulony”. O tym, do której klasy należy zaliczyć aktualnie pokazany obiekt, decyduje numer wyjścia, na którym pojawia się największy sygnał wyjściowy y_m . „Wzorce” poszczególnych klas są w poszczególnych neuronach w postaci ich wektorów wag.

4. Nieliniowa sieć neuronowa – perceptron wielowarstwowy

Innym rodzajem sieci neuronowych są sieci nieliniowe. Ich typowym przedstawicielem jest *perceptron wielowarstwowy*. Tworzą go neurony ułożone w warstwy o jednym kierunku przepływu sygnałów, o połączeniach międzywarstwowych jedynie między sąsiednimi warstwami. Funkcja agregująca ϑ neuronów warstw ukrytych i warstwy wyjściowej jest liniowa, natomiast funkcja aktywacji – nieliniowa.



Rys. 6. Model perceptronu wielowarstwowego

Na rys. 6. przyjęto następujące oznaczenia: $i = 1, 2, \dots, m$; m – liczba neuronów warstwy wejściowej; $j = 1, 2, \dots, n$; n – liczba neuronów warstwy wyjściowej; $h = 1, 2, \dots, H$; H – liczba warstw ukrytych; $k_h = 1, 2, \dots, K_h$, K_h – liczba neuronów h -tej warstwy ukrytej; $w_{k_{h-1}k_h}^h$ – waga połączenia pomiędzy elementami k_{h-1} -tym i k_h -tym odpowiednio w warstwach $(h - 1)$ -szej i h -tej.

Dla większej przejrzystości analizy możliwości perceptronu, przyjmijmy, że funkcja aktywacji jest postaci

$$y = \begin{cases} 1 & \text{gdy } \varphi \geq 0 \\ 0 & \text{gdy } \varphi < 0 \end{cases},$$

gdzie

$$\varphi = \sum_{i=1}^n w_i x_i$$

jest wartością funkcji agregującej. Obszar, w którym neuron podejmuje decyzję $y = 1$ ogranicza hiperpłaszczyzna o równaniu

$$\sum_{i=1}^n w_i x_i = 0.$$

Proces uczenia, polegający na zmianie wartości współczynników w_i , pozwala ustawić graniczną hiperpłaszczyznę w dowolnym położeniu; nie pozwala jednak na zmianę rodziny realizowanego odwzorowania, co powoduje, że pewnych odwzorowań nie da się uzyskać za pomocą takiego neuronu. Jednak to, czego nie może zrobić jeden neuron, może zrobić kilkuwarstwowa sieć zbudowana z neuronów tego samego typu. W przypadku nieliniowych neuronów dodanie nowych warstw istotnie poszerza zakres rodzajów odwzorowań, które sieć potrafi zrealizować. Możliwości sieci perceptronowej, zbudowanej z wyżej opisanych neuronów, ilustruje rys. 7. Przedstawiona

tabela dotyczy rozpoznawania figur geometrycznych przez taką sieć oraz zagadnienia separowalności. Pod pojęciem *obszaru decyzyjnego* rozumiemy zbiór wszystkich punktów $\mathbf{x} = (x_1, x_2, \dots, x_n)$, gdzie n jest wymiarem przestrzeni, którym zostanie przyporządkowana ta sama klasa. Problem XOR dotyczy separowalności – przy wykorzystaniu możliwości opisanego perceptronu – klas A i B na płaszczyźnie: punktom o współrzędnych $(0, 1)$ i $(1, 0)$ powinna być przyporządkowana klasa A , natomiast punktom $(0, 0)$ i $(1, 1)$ – klasa B . Ostatnia kolumna tabeli prezentuje obszary, które mogą być rozpoznawane przez neurony ostatniej warstwy tej sieci.


Struktura	Typ obszarów decyzyjnych	Problem XOR	Najbardziej ogólne kształty obszarów
Jednowarstwowa 	Półpłaszczyzna ograniczona przez hiperpłaszczyznę		
Dwuwarstwowa 	Wypukłe obszary otwarte lub zamknięte		
Trójwarstwowa 	Dowolne (złożoność ograniczona liczbą neuronów)		

Rys. 7. Rodzaje odwzorowań realizowane przez perceptron

Za pomocą nieliniowej sieci neuronowej o co najmniej trzech warstwach (nie licząc warstwy wejściowej) można zrealizować dowolne odwzorowanie.

5. Sieć dynamiczna – dyskretna i ciągła sieć Hopfielda

Sieci rekurencyjne (dynamiczne) są znacznie bardziej skomplikowane w porównaniu z sieciami jednokierunkowymi. Przepływ sygnałów jest tu dwukierunkowy. Występują również sprzężenia zwrotne, tzn. wyjścia neuronów mogą być połączone z wejściami neuronów tej samej warstwy lub którejs z warstw pośrednich. Strukturę ogólną takiej sieci przedstawia rys. 8, gdzie bloki N_1, \dots, N_4 stanowią układy wielu neuronów połączonych między sobą.



Rys. 8. Ogólna struktura sieci rekurencyjnej

Znanym przykładem takiej sieci jest *sieć Hopfielda*. W *dyskretnej sieci Hopfielda* zmiany stanu sieci

następują w czasie dyskretnym. Jest ona zbudowana z N neuronów, z których – w danej chwili k – jeden, losowo wybrany z jednakowym prawdopodobieństwem wyboru spośród wszystkich neuronów tej sieci, oblicza ważoną sumę wyjść wszystkich pozostałych neuronów, pomniejszoną o pewną stałą θ_p , tj.:

$$\varphi_p(k) = \sum_{j=1}^N w_{pj}x_j(k) - \theta_p,$$

a następnie – tak otrzymanej sumie $\varphi_p(k)$ – przyporządkowuje w chwili $k + 1$ jedną z trzech wartości, zgodnie ze wzorem:

$$x_p(k+1) = \begin{cases} 1 & \text{gdy } \varphi_p(k) > 0, \\ x_p(k) & \text{gdy } \varphi_p(k) = 0, \\ 0 & \text{gdy } \varphi_p(k) < 0, \end{cases}$$

gdzie :

$x_j(k)$ – wejście j -tego neuronu w chwili k ,

w_{pj} – waga połączenia między wyjściem j -tego i wejściem p -tego neuronu,

θ_p – wartość progowa p -tego neuronu.

Wartości $x_i(0)$, gdzie $i = 1, \dots, N$, N -liczba wszystkich neuronów tej sieci, określające stan początkowy, są ustalone.

W opisany sposób informacja będzie przepływała między warstwami lub w warstwie, aż do spełnienia ustalonego kryterium zbieżności, po czym zostanie przekazana na wyjście sieci.

Dyskretna sieć Hopfielda jest stosowana w charakterze pamięci autoskojarzeniowej, gdzie istotą problemu jest odtwarzanie na zasadzie skojarzeń całości informacji na podstawie dostępnego jej fragmentu, jak odczytanie prawie nieczytelnego pisma lub zrozumienie bardzo niewyraźnej mowy.

Hopfield zaproponował również ciągłą wersję swojej sieci charakteryzującą się ciągłym czasem zmian stanów sieci, ciągłą funkcją aktywacji $f : \mathbb{R} \rightarrow \mathbb{R}$ postaci

$$f(x_i) = \frac{1}{2}(1 + \tanh(\beta x_i)),$$

gdzie $\beta > 0$ jest ustalonym parametrem, oraz zmianami stanu sieci określonymi przez odpowiedni układ równań różniczkowych zwyczajnych, zbudowany przez analogię do podanego tu wcześniej układu równań różnicowych opisującego zmiany stanu sieci dyskretnej.

Ciągła sieć Hopfielda jest stosowana przy rozwiązywaniu problemów optymalizacyjnych.

Istnieje wiele innych, bardziej złożonych struktur sztucznych sieci neuronowych. Ich budowa podporządkowana jest nadrzędnemu celowi, jakim jest zadanie, którego wykonywania sieć ma się nauczyć.

Sieci zbudowane są z dużej ilości bardzo prostych i identycznie pracujących elementów, połączonych tak, że przetwarzanie informacji odbywa się tu w sposób równoległy. To, że informacja nie jest skupiona w jednym miejscu, lecz rozłożona we wszystkich połączeniach synaptycznych, powoduje dużą odporność sieci na uszkodzenia i umożliwia efektywne wykonywanie złożonych zadań. Ta właściwość sztucznych sieci neuronowych istotnie wpływa na ich ogromną popularność.

Bibliografia

- [1] Korbicz J., Obuchowicz A., Uciński D., *Sztuczne sieci neuronowe*, Akademicka Oficyna Wydawnicza PLJ, Warszawa, 1994.
- [2] Osowski S., *Sieci neuronowe*, Oficyna Wydawnicza Politechniki Warszawskiej, Warszawa, 1994.
- [3] Tadeusiewicz R., *Sieci neuronowe*, Akademicka Oficyna Wydawnicza, Warszawa, 1993.