

# Umysł w maszynie



**Sieci neuronowe i uczenie maszynowe stały się ważnymi narzędziami pozwalającymi na tworzenie algorytmów podejmujących decyzje w podobny sposób, w jaki robią to ludzie. To właśnie wokół nich buduje się systemy sztucznej inteligencji, których dzisiejsze możliwości jeszcze kilka lat temu uznano by za zbyt entuzjastyczną fantastykę naukową.**

Skok jakościowy w dziedzinie sztucznej inteligencji i uczenia maszynowego, jakiego jesteśmy świadkami, stał się co możliwy właśnie dzięki rozwojowi sieci neuronowych. W szczególności powstanie sieci neuronowych – dysponujących wieloma warstwami umożliwiającymi tzw. głębokie uczenie – pozwoliło na uzyskanie znacznie lepszych wyników w wielu zastosowaniach, o których myśleliśmy jako o typowo „ludzkich”, takich jak rozpoznawanie obrazów i mowy czy prowadzenie sensownej konwersacji. Obecnie sieci neuronowe stanowią jeden z kluczowych obszarów rozwoju sztucznej inteligencji, a ich zastosowanie jest coraz szersze w wielu dziedzinach – od diagnostyki medycznej, przez finanse i marketing, a skończywszy na produkowaniu deepfake’ów zarówno w warstwie tekstowej, jak i audiowizualnej.

Sieci neuronowe i sztuczna inteligencja (termin ten jest dość pojemny i zawiera rozwiązania będące sprytnym



**Piotr Kościelniak**

dziennikarz, popularyzator nauki

wykorzystaniem statystyki, analizy dużych zbiorów danych i uczenia głębokiego) nie są wszakże czymś całko-

wicie nowym. Technologie te rozwijają się w cyklach i – w co może trudno uwierzyć – mają swoje początki jeszcze w latach 40. XX w.<sup>1</sup>

## Zachwyty i rozczarowanie

Sieci neuronowe jako metoda przetwarzania informacji to pomysł dwóch naukowców Uniwersytetu Chicago – cybernetyka i neurofizjologa Warrena McCullocha oraz logika Waltera Pittsa, którzy w 1943 r. zaproponowali matematyczny model funkcjonowania neuronu i sieci neuronowej. Ich artykuł „A Logical Calculus of Ideas Immanent in Nervous Activity”<sup>2</sup> dowodził, że maszyna Turinga może funkcjonować jako model złożony ze skończonej liczby neuronów. Trzy lata później zademonstrowali sieć sztucznych neuronów pozwalającą w ograniczony sposób rozpoznawać obrazy niezależnie od ich orientacji i rozmiarów.

McCulloch i Pitts szybko przenieśli się do MIT, gdzie prowadzili badania nad funkcjami poznawczymi mózgowi istot żywych oraz próbami przeniesienia ich funkcjonowania do świata matematyki i maszyn. To zainteresowanie stykiem neuronauki i technologii komputerowych nie słabło aż do końca lat 60. XX w. Naukowcy tworzyli funkcjonalne modele neuronów (perceptrony), łączyli je w sieci i opracowywali algorytmy uczenia.

Jednak w 1969 r. sieci neuronowe zostały „zabite” jedną książką – „Perceptrons” – napisaną przez Marvinę Minsky’ego i Seymoura Paperta, informatyków specjalizujących się w zagadnieniach sztucznej inteligencji<sup>3</sup>. Wykazali oni istotne ograniczenia ówczesnych sieci neuronowych i prognozowali rozczarowanie tym kierunkiem badań. W tym samym roku odeszli również McCulloch i Pitts, a zatem koncepcja sztucznej inteligencji opartej na modelu funkcjonowania biologicznych neuronów straciła obrońców. Nastąpił potężny kryzys, nazywany nawet „nuklearną zimą sztucznej inteligencji”, a najważniejsze projekty, takie jak rozpoznawanie mowy (prowadzone przez amerykańską DARPA – agencję zaawansowanych projektów obronnych) czy automatyczny tłumacz, były kolejno porzucane.

Zapaść projektów badawczych w dziedzinie sieci neuronowych i głębokiego uczenia trwała aż do lat 80., kiedy naukowcy opracowali wreszcie algorytmy pozwalające na efektywne uczenie się wielowarstwowych sieci neuronowych (przez wsteczną propagację błędów), omijając tym samym ograniczenia wskazane przez Minsky’ego i Paperta.

Na przeszkodzie stanęła jednak technika – ówczesny sprzęt nie był dość wydajny, aby myśleć o praktycznym zastosowaniu nowej technologii. Sami naukowcy w tym czasie starannie omijali w swoich wnioskach grantowych wszystko, co mogłoby się kojarzyć ze skompromitowanym terminem AI, zamiast tego używając określeń „uczenie maszynowe” czy „systemy eksperckie”.

Renesans zainteresowania technologiami sieci neuronowych, nazywany „wiosną AI”, z którym mamy do czynienia od początku XXI w., wynika w równej mierze z postępów technologii i dostępności mocy obliczeniowej – w tym pojawienia się układów GPU doskonale naśladujących węzły sieci neuronowych – co z pierwszymi sukcesami takich rozwiązań, które wreszcie spełniły obietnice sprzed ponad pół wieku. Wydajniejsze układy pozwoliły na budowę skomplikowanych sieci, składających się nawet z kilkudziesięciu warstw, w miejsce dwu-, czy trzywarstwowych sieci z lat 80. Ta głębokość sieci dała początek terminowi „uczenie głębokie”, technice umożliwiającej komputerom rozwiązywanie bardziej złożonych problemów.

## Ojciec perceptron

Zrozumienie istoty funkcjonowania sieci neuronowych wymaga cofnięcia się do lat 40. W 1949 r. kanadyjski neuropsycholog Donald Hebb, nazywany ojcem sieci neuronowych, opisał funkcje komunikacji między neuronami posługując się w pełni biologicznym materiałem („Organizacja zachowań. Teoria neuropsychologii”). Kilka lat później Arthur Samuel z IBM stworzył program do gry w warcaby wykorzystujący algorytmy alfa-beta i minimax. Program „uczył się”, zapamiętując rozegrane pozycje i uzyskane korzyści. To właśnie Samuel jako pierwszy użył terminu „uczenie maszynowe”<sup>4</sup>.

Połączenie tych dwóch koncepcji pozwoliło na stworzenie pierwszego sztucznego neuronu – perceptronu. Zrobił to w 1957 r. Frank Rosenblatt w Cornell Aeronautical Laboratory. Jego perceptron, używany do rozpoznawania obrazów, był urządzeniem elektromechanicznym. Perceptron przyjmował dane wejściowe (binarne) i stosownie do ich

<sup>1</sup> <https://news.mit.edu/2017/explained-neural-networks-deep-learning-0414>

<sup>2</sup> <https://www.cs.cmu.edu/~epxing/Class/10715/reading/McCulloch.and.Pitts.pdf>

<sup>3</sup> <https://direct.mit.edu/books/book/3132/PerceptronsAn-Introduction-to-Computationa>

<sup>4</sup> <https://www.dataversity.net/a-brief-history-of-machine-learning/>

wartości ustawiał pojedynczą wartość wyjściową – również binarną. Jak? Wejściom przywiązano wagi, a wyjście było aktywowane, gdy wartość danych wejściowych po uwzględnieniu wag była wyższa niż zadany próg. Podstawowy perceptron to – w uproszczeniu – urządzenie, które uwzględniając zadane parametry podejmuje decyzję<sup>5</sup>.

Jak to działa? Powiedzmy, że w naszym mieście odbywa się festiwal foodtrucków. To, czy na niego pójdziemy zależy od tego, czy będą tam nasze ulubione hamburgery, czy będzie dobra pogoda i czy nasza partnerka/partner podzielają nasze uwielbienie dla produktów mięsnych. Każdemu z tych warunków możemy przypisać wagi (np. zła pogoda będzie dealbreakerem, natomiast wegetarianizm narzeczonej tylko nieznacznym utrudnieniem). Nadajemy również wartość progową dla całego perceptronu, która określi, czy uwzględniając pogodę, obecność ulubionej knajpy i humor drugiej połowy, powinniśmy odwiedzić festiwal foodtrucków.

Oczywiście to bardzo uproszczony model neuronu, nieoddający nawet częściowo całego procesu decyzyjnego odbywającego się w ludzkim umyśle<sup>6</sup>. Ważne jednak, że regulując wagi i wartość progową, możemy wpływać na decyzje podejmowane przez perceptron.

## Wszyscy lubią warstwy

Perceptron rozpoznawał wprawdzie nieskomplikowane wzory, jednak ambitniejsze zadania pozostawały poza jego zasięgiem. I choć dzięki niemu budowano najprostsze sieci neuronowe, jego konstrukcja nie pozwalała ani na podejmowanie subtelniejszych decyzji, ani na zautomatyzowanie procesu uczenia – wagi i progi nadawane były przez operatora.

A gdyby tak połączyć wiele perceptronów w sieć w taki sposób, aby wyjście jednego z nich było wejściem kolejnych? Pierwsza warstwa (tzw. wejściowa) podejmowałaby bardzo proste, zgrubne decyzje. Druga i kolejne warstwy (przyjęło się nazywać je warstwami ukrytymi) przyjmowałaby na wejściu informacje z pierwszej warstwy, co pozwalałoby podejmować decyzje subtelniejsze, na wyższym poziomie abstrakcji. Każda kolejna warstwa perceptronów umożliwiałaby jeszcze głębszą – i bardziej abstrakcyjną – analizę. Dane te trafiałyby do ostatniej warstwy (wyjściowej), która podawałaby ostateczną odpowiedź na zadany problem.

Takie podejście niewiele różni się od konwencjonalnych bramek logicznych. Ale jeśli algorytm mógłby samodzielnie dobierać wagi poszczególnych sygnałów wejściowych i progi aktywacji dla sztucznego neuronu?

Powiedzmy, że mamy sieć perceptronów, którą chcemy nauczyć rozpoznawania odręcznie zapisanego znaku (rozpoznawanie obiektów to jedno z pierwotnych zastosowań sieci neuronowych i algorytmów uczenia maszynowego). Taka sieć powinna samodzielnie dobierać wartości wag i progów aktywacji, aby osiągnąć poprawny wynik. Sieć rozpoznająca zapisaną cyfrę „8” jako „3” wymagałaby stopniowej modyfikacji parametrów, aby osiągnąć pożądany efekt. Niewielka, iteracyjna zmiana wag i progów, prowadząca do coraz doskonalszych rezultatów, oznaczałaby, że sieć „uczy się”. Tyle, że w przypadku klasycznego perceptronu, który operuje na wartościach zero-jedynkowych, takie stopniowe dopasowanie parametrów byłoby bardzo trudne. Dlatego znacznie bardziej funkcjonalny byłby sztuczny neuron akceptujący nie tylko zera i jedynki, lecz wszystkie wartości między 0 i 1 (co określane jest jako neuron sigmoidalny).

W jaki sposób jednak zautomatyzować zmiany parametrów sieci, czyli uruchomić „uczenie się” sieci neuronowej? Podstawową metodą dobierania wag jest algorytm propagacji wstecznej wymuszający zmianę wag i progów, aby otrzymać pożądany wynik na wyjściu. O tym, jak bardzo algorytm będzie zmieniać wagi perceptronów w sieciach wielowarstwowych, decyduje współczynnik uczenia. Jeżeli będzie zbyt mały, uczenie się sieci będzie trwać bardzo długo. Jeżeli zbyt duży – możemy przeoczyć właściwe rozwiązanie. Wykorzystanie propagacji wstecznej do uczenia sieci neuronowych zaproponował Geoffrey Hinton w 1986 r. – podczas krótkiej „odwilży” w nuklearnej zimie sztucznej inteligencji.

W praktyce na początku treningu sieci neuronowej wagi i progi aktywacji są ustalane losowo. Dane dostarczane są do warstwy wejściowej, a wynik odczytywany w warstwie wyjściowej. Następnie są porównywane z oczekiwanym efektem, a algorytm na nowo dobiera parametry sieci. Ponieważ parametry te są odkrywane przez sieć automatycznie, w rzeczywistości nie wiemy, jakie wartości sprawiają, że sieć neuronowa wykonuje zadanie poprawnie.

## Z nauczycielem czy bez?

Opisywany tu podaje dwa założenia. Pierwsze – że rozważamy jednokierunkowe sieci neuronowe (tzw. sieci feedforward). To taki rodzaj sieci neuronowych, w których informacja jest podawana tylko w jednym kierunku – nie ma żadnej pętli pozwalającej na sprzężenie zwrotne. Mają one kilka zalet, takich jak prostota i szybkość działania. Jednakże oznacza to również, że nie radzą one sobie z bardziej złożonymi zadaniami, takimi jak rozpoznawanie mowy. W takich sytuacjach niezbędne są bardziej

<sup>5</sup> <http://neuralnetworksanddeeplearning.com/index.html>

<sup>6</sup> <https://home.agh.edu.pl/~horzyk/lectures/biocyb/BIOCYB-SieciNeuronowe.pdf>

zaawansowane wielowarstwowe sieci neuronowe – tzw. rekurencyjne, które dopuszczają sprzężenie zwrotne, uwzględniając kontekst. W tym sensie bardziej przypominają organizację mózgu żywej istoty<sup>7</sup>.

To oczywiście nie wszystkie typy sieci neuronowych. Istnieją również m.in. sieci konwolucyjne (zaprojektowane z myślą o analizie obrazu, w tym twarzy i ruchu), generatywne (potrafiące wytwarzać obrazy, dźwięk czy tekst) czy transformatory (doskonale radzące sobie z przetwarzaniem języka naturalnego, ChatGPT opiera się właśnie na tej architekturze).

Drugim założeniem jest przyjęcie modelu uczenia nadzorowanego – operator wie, jaki wynik chce uzyskać. Uczenie sieci w tym modelu często porównywane jest do edukacji szkolnej dziecka, które uczy się rozpoznawać zwierzęta przez zapamiętywanie obrazków i podpisów do nich w książce. W uczeniu nadzorowanym algorytm jest trenowany przez zestaw danych, które mają już przypisaną etykietę (rezultat).

Nienadzorowane samouczenie się maszyn wykorzystuje bardziej niezależne podejście. Komputer uczy się identyfikować złożone procesy i wzorce bez człowieka udzielającego wskazówek – dostarczane dane nie mają etykiet ani zdefiniowanego wyniku. W tym przykładzie dziecko będzie analizować kształty zwierząt samodzielnie, dzieląc je na grupy. W przypadku sieci neuronowej ten podział może obejmować np. grupy zwierząt czworonożnych, ptaków i ryb. Wielowarstwowa sieć neuronowa i uczenie głębokie może ten podział zniuansować – maszyna będzie w stanie odróżnić kaczkę od gęsi<sup>8</sup>.

Trzecim nurtem uczenia maszynowego, wykorzystywanym głównie do gier (w tym gry na giełdzie), jest uczenie przez wzmocnienie, w którym nie przygotowuje się żadnego gotowego zestawu danych do treningu, lecz stara się nauczyć sieć takiego zachowania, aby zmaksymalizować nagrodę (może to być zwrot z inwestycji, czy wygrana w grze komputerowej).

## Od zdrowia i kredytów po poszukiwanie planet

Dziś wykorzystanie sieci neuronowych i uczenia głębokiego wyszło daleko poza poziom eksperymentów, z którymi

mieliśmy do czynienia jeszcze zaledwie kilka lat temu (kto pamięta aferę z systemem Google, który zidentyfikował czarnoskórych ludzi na zdjęciach jako goryle?<sup>9</sup>).

” *Obecnie skrót AI jest niemal obowiązkowy w marketingu dowolnych urzędzeń – od tosterów po telewizory. A sieci neuronowe i algorytmy uczenia głębokiego wykorzystywane są powszechnie w biznesie i nauce.*

Jednym z najczęstszych zastosowań jest przetwarzanie języka naturalnego. Sieci neuronowe są używane do tłumaczenia maszynowego, rozpoznawania mowy i generowania tekstu – z tych rozwiązań korzystamy wszyscy, choćby przez aplikacje zainstalowane w naszych smartfonach. Po sieci neuronowe coraz częściej sięga też medycyna (choć tu pomyłka może być znacznie poważniejsza niż pomylenie człowieka z gorylem). Najczęściej systemy wykorzystujące uczenie głębokie używane są do wsparcia techników i lekarzy w analizie wyników badań obrazowych, a także przygotowania planów leczenia. W związku z postępującą cyfryzacją opieki zdrowotnej, systemy takie używane są też do przetwarzania nieustrukturyzowanych zbiorów danych – jak np. notek lekarza, opisów badań itp. celem archiwizowania ich w systemie informatycznym.

Bardziej niepokojące są zastosowania tych technologii w świecie ubezpieczeń i finansów. Sieci neuronowe są używane do analizy ryzyka kredytowego i przewidywania trendów rynkowych, a także do wyliczania składek ubezpieczeniowych uwzględniających cechy osobnicze i styl życia, wykrywając zależności, których człowiek prawdopodobnie by nie zauważył.

Najciekawsze i najbardziej niezwykłe są jednak próby wykorzystywania sieci neuronowych do prowadzenia działalności charakteryzującej tylko ludzi – badań naukowych. Technologie uczenia głębokiego używane są do sekwencjonowania DNA, identyfikowania białek, modelowania ewolucji biologicznej. A kilka lat temu sieć neuronowa wytrenowana przez Google i NASA do przeglądania obrazów z kosmosu odkryła planetę pozasłoneczną podobną do Ziemi.

<sup>7</sup> [http://www.is.umk.pl/~grochu/wiki/lib/exe/fetch.php?media=zajecia:nn\\_2020\\_1:nn-wyklad.pdf](http://www.is.umk.pl/~grochu/wiki/lib/exe/fetch.php?media=zajecia:nn_2020_1:nn-wyklad.pdf)

<sup>8</sup> <https://home.agh.edu.pl/~horzyk/lectures/ai/SztucznaInteligencja-UczenieG%C5%82%C4%99bokichSieciNeuronowych.pdf>

<sup>9</sup> <https://www.wsj.com/articles/BL-DGB-42522>