

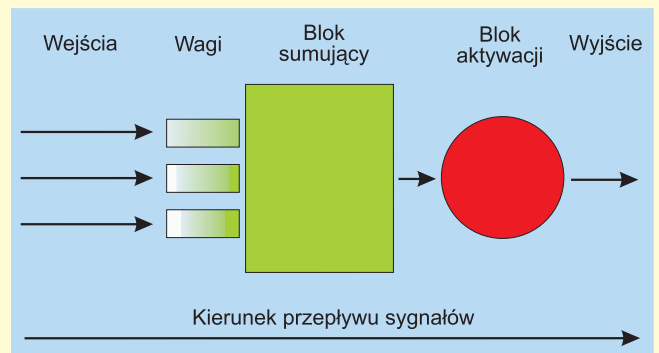
Neurointerpolacja – neuronowa kr Sztuczna inteli modeluje powierzchn

ROBERT OLSZEWSKI

*Matematyka klasyczna skoncentrowała się na równaniach liniowych z poważnego powodu pragmatycznego: nie umiała rozwiązywać nic więcej. W porównaniu z niesfornymi, chuligańskimi błazeństwami typowego równania, równania liniowe są gro-
madą chłopców z chóru kościelnego. (...) Zachowanie równań liniowych – podobnie jak zachowanie chłopców z chóru kościelnego – dalekie jest jednak od typowości.*

Ian Stewart, „Czy Bóg gra w kości?”

Wiele kształtów występujących w naturze jest zbyt złożonych, by móc je opisać w postaci prostych formuł algebraicznych. Praktycznym zastosowaniem wiedzy matematycznej w opisie obiektów i procesów rzeczywistych jest najczęściej modelowanie liniowe. Procedury tej używa się głównie z uwagi na dobrze znaną strategię optymalizacji stosowaną przy konstrukcji modeli tego typu. Jednak wszędzie tam, gdzie nie ma podstaw do aproksymacji liniowej występujących zjawisk i procesów, modele liniowe nie sprawdzają się, prowadząc niekiedy do formułowania niesłusznych opinii o całkowitym braku możliwości matematycznego opisywania takich systemów. Tymczasem jednym ze sposobów modelowania nieliniowego jest wykorzystanie specjalnych programów komputerowych, zwanych sztucznymi sieciami neuronowymi (SSN). Rozwinęły się one w wyniku badań prowadzonych w dziedzinie sztucznej inteligencji, a zwłaszcza prac dotyczących funkcjonowania podstawowych struktur mózgu. SSN mogą być użyteczne w sytuacjach, w których struktura problemu jest słabo rozpoznana, informacje wejściowe niekompletne, a zadowalające są przybliżone wyniki koń-




Rys. 1. Sztuczny neuron (<http://www.nm.prv.pl/>)

cowe. Do sieci neuronowych wprowadza się pewne zmienne wejściowe (czyli dane), zaś jej wyjścia definiują zmienne wyjściowe (czyli rozwiązania). Dlatego też mogą one być stosowane wszędzie tam, gdzie na podstawie pewnych znanych informacji wnioskuje się o pewnych informacjach nieznanach. Zastosowanie sieci neuronowych upowszechniło się dzięki ich właściwościom użytecznym w modelowaniu i obliczeniach. Zalety SSN można ująć następująco:

- pozwalają na stosunkowo proste tworzenie dowolnie złożonych modeli nieliniowych, „ucząc się” na przedstawianych przykładach. Metoda ta nie wymaga przyjmowania a priori żadnych założeń co do kształtu i stopnia nieliniowości tworzonej funkcji regresji,
- charakteryzuje je wysoki stopień odporności na błędy. Informacje, na podstawie których uczymy sieć, mogą być niepełne lub obciążone błędem. Odpowiednio nauczona sieć neuronowa potrafi skutecznie „odfiltrować” szum i prowadzić obliczenia w oparciu o wypadkowe tendencje i trendy,
- właściwie przygotowaną (nauczoną) SSN cechuje zdolność do generalizacji, tj. umiejętność uogólniania zdobytej wiedzy,
- najistotniejsza jest jednak łatwość ich użycia. SSN działają na zasadzie „czarnej skrzynki”: pytanie – odpowiedź. Sieci neuronowe w praktyce same konstruują potrzebne użytkownikowi modele, ponieważ automatycznie uczą się na podanych przez niego przykładach. Proces uczenia sieci zastępuje programowanie. Dzięki temu można rozwiązywać problemy obliczeniowe, nie znając algorytmu, dysponując jedynie testowym zbiorem zawierającym „pytania” i „odpowiedzi”.

racja NMT

gencja nię Ziemi



Rys. 2. Sieć neuronowa GRNN

Zasadniczym elementem systemu SSN jest sztuczny neuron, odwzorowujący podstawowe cechy układu biologicznego. Mózg składa się z komórek nerwowych zwanych neuronami. Pomiedzy nimi znajdują się cieniutkie połączenia, tzw. dendryty i aksony. W powiększeniu fragment mózgu wygląda jak drobna sieć, której węzłami są neurony. W budowie SSN wykorzystywane są sztuczne elementy o luźnej analogii do dendrytów,

aksonów i synaps (to miejsca styków dendrytów i aksonów). Sygnały wejściowe dostarczone do neuronu są odpowiednio przekształcane i przesyłane do kolejnych neuronów tworzących sieć. Pojedynczy neuron można rozpatrywać jako specyficzny przetwornik sygnałów cyfrowych:

- do neuronu dociera pewna liczba sygnałów wejściowych,
- każda wartość wprowadzana jest do neuronu przez połączenie o pewnej wadze,
- dla neuronu określana jest wartość progowa aktywująca ten neuron,
- sygnał reprezentujący łączne pobudzenie neuronu przekształcany jest przez ustaloną funkcję aktywacji.

Poszczególne neurony grupowane są w warstwy tworzące SSN. Warstwa wejściowa umożliwia wprowadzanie danych źródłowych do sieci, tzw. warstwy ukryte służą do ich przetwarzania, zaś warstwa wyjściowa umożliwia wyprowadzenie wyników z sieci. Na wejście każdego neuronu danej warstwy trafia każdy sygnał z warstwy poprzedniej, nie istnieją natomiast połączenia między neuronami należącymi do jednej warstwy. Istotnym problemem jest sposób budowania połączeń strukturalnych pomiędzy warstwami sieci. W praktyce najczęściej stosowane jest połączenie jednokierunkowe, nie zawierające sprzężenia zwrotnego.

Ciała wiedza sieci neuronowej tkwi w wartościach wag synaptycznych tworzących ją neuronów. Zmieniając je, dostaniemy inną sieć. Identyfikując ją do „wyglądu”, lecz o całkiem innym „charakterze”, udzielającą zupełnie odmiennych odpowiedzi na te same pytania. Uczenie sieci polega na iteracyjnym dobraniu takich wartości wag, przy których sieć będzie możliwie najlepiej rozwiązywała dane zadanie. Istnieją dwa typy algorytmów do uczenia sieci neuronowych, które stosowane są w zależności od rodzaju używanej sieci: „z nauczycielem” oraz „bez nauczyciela”.

Stosując uczenie z nauczycielem, należy zgromadzić zbiór danych uczących. Dane te zawierają przykłady wejść oraz odpowiadających im poprawnych wartości wyjściowych. Można powiedzieć, że są to przykłady zadań wraz z rozwiązaniami: zbiór przykładowych danych wejściowych definiuje pewne zadanie, zaś skojarzona z tym zbiorem wartość danej wyjściowej – stanowi rozwiązanie tego przykładowego zadania. Sieć iteracyjnie uczy się wnioskować na temat sposobu rozwiązywania stawianych jej zadań, dokonując analizy przykładowych danych wejściowych i wyjściowych. W ślad za tym zmieniane są wartości wag synaptycznych poszczególnych neuronów.

R E K L A M A



OFERTA TYLKO DLA INSTYTUCJI PAŃSTWOWYCH
I URZĘDÓW ADMINISTRACJI PUBLICZNEJ

PLOTER BEZ PRZETARGU

- MUTOH RJ-800 Falcon
- głowica drukująca piezo
 - rozdzielczość 720 x 720 dpi
 - format A0
 - dokładność +/- 0,1%
 - czytelność linii od 0,1 mm
 - prędkość druku poniżej 3 min./A0

PLOTER



za 2.999 euro

Atrium

Opole, tel. (0-77) 458 16 81
Warszawa, tel. (0-22) 751 91 52
<http://www.atrium.com.pl>
help line (0-600) 025 800


Systemy oparte na wykorzystaniu sieci neuronowych znalazły szerokie zastosowanie w tych dziedzinach wiedzy, których przedmiotem badania są zagadnienia predykcji i klasyfikacji, np. ocena wiarygodności kredytowej, sterowanie robotami, przewidywanie wahań kursu akcji giełdowych, atakże nauki o Ziemi. Istnieje wiele typów sieci neuronowych, różniących się strukturą i zasadami działania. Do najczęściej stosowanych należą tzw. perceptrony wielowarstwowe – MLP (*multilayer perceptron*), sieci o radialnych funkcjach bazowych – RBF (*radial basis functions*) oraz sieci realizujące regresję uogólnioną – GRNN (*generalized regression neural network*).

Odpowiednio zaprojektowane i wytrenowane sieci neuronowe pozwalają na modelowanie praktycznie dowolnie złożonych funkcji nieliniowych. W matematycznym modelowaniu fizycznej powierzchni Ziemi szczególnie dobre wyniki osiąga się przy zastosowaniu sieci regresyjnych. Sieci realizujące regresję uogólnioną mają cztery warstwy: wejściową, radialną, regresyjną oraz wyjściową. W sieci GRNN przypadki uczące kopiowane są do neuronów warstwy ukrytej sieci. Dane te służą zarówno do estymacji odpowiedzi sieci dla punktów zbioru uczącego, jak i dla nowych punktów, które w zbiorze uczącym nie występowały. Tworzenie przez sieć wielowymiarowej funkcji regresji polega na tym, iż każdy przypadek zbioru uczącego jest rozważany

jako swoisty „dowód” tego, że powierzchnia budowanej odpowiedzi sieci ma w tym punkcie pewną ustaloną wysokość. Ten punktowy „dowód” jest następnie przez sieć „rozmywany” na okolice punkty przestrzeni.

Autor podjął próbę zastosowania sieci neuronowych jako metody interpolacji powierzchni statystycznych, przede wszystkim zaś numerycznego modelu terenu (NMT). Tworzenie NMT zreguły sprowadza się do uzyskania ciągłej powierzchni statystycznej na podstawie zbioru dyskretnie rozmieszczonych punktów pomiarowych. Najczęściej proces ten realizowany jest przy użyciu metody triangulacji, odwrotnych odległości lub *krigingu*. Jednak zastosowanie odpowiednio dobranej sieci neuronowej także może prowadzić do uzyskania interesujących wyników.

Do badania przydatności stosowania SSN w tworzeniu modelu powierzchni terenu wykorzystano dane cyfrowe US Geological Survey. Jako obszar testowy przyjęto rejon wulkanu św. Heleny leżącego na pograniczu USA i Kanady. Dla obszaru otaczającego kalderę wulkaniczną (10 x 10 km) USGS dysponuje numerycznym modelem terenu o dużej rozdzielczości przestrzennej, opracowanym techniką fotogrametryczną (rys. 4 i 5). W badaniach wykorzystano także dane archiwalne, pozwalające na wizualizację tego obszaru przed erupcją wulkaniczną w 1980 roku (rys. 3).



Rys. 3


Rys. 4

Rys. 3. Wulkan św. Heleny (przed 18 maja 1980 r.)

Rys. 4. Wulkan św. Heleny (po 18 maja 1980 r.)



Rys. 5. Wulkan św. Heleny po wybuchu (dane US Geological Survey)



Rys. 6. Powierzchnia błędu NMT_{źród.} – NMT_{triang.}

Na analizowanym obszarze testowym wybrano 4000 punktów rozmieszczonych w sposób losowy. Dla każdego z nich określono dwa parametry wejściowe: współrzędne płaskie X i Y oraz jeden parametr wyjściowy: wysokość H. Dane te posłużyły do utworzenia czterech modeli terenu: przy zastosowaniu metody triangulacji oraz sieci neuronowych MLP, RBF i GRNN.

Uzyskane wyniki porównano z danymi źródłowymi USGS. Dla zbioru 1000 losowo rozmieszczonych punktów, które nie były wykorzystywane w tworzeniu NMT, określono średni błąd kwadratowy RMS.

sposób interpolacji	błąd RMS [m]
triangulacja	4,87
MLP	45,44
RBF	26,62
GRNN	5,04

Zgodnie z przewidywaniami najlepsze rezultaty dało zastosowanie klasycznej metody triangulacji, jednakże wyniki neurointerpolacji wykorzystującej sieć GRNN są do nich zbliżone. Sieci o radialnych funkcjach bazowych, a zwłaszcza perceptrony wielowarstwowe dają obraz silnie zgeneralizowany.

Interesujące jest porównanie powierzchni błędu NMT utworzonego metodą triangulacji i neurointerpolacji GRNN. Powierzchnie te uzyskano jako różnicę źródłowego NMT USGS i modelu interpolowanego. Dla metody triangulacji ($NMT_{zród.} - NMT_{triang.}$) rozkład przestrzenny błędów interpolacji ma charakter losowy (rys. 6).

Powierzchnia błędu neurointerpolacji GRNN ($NMT_{zród.} - NMT_{GRNN}$) wykazuje natomiast istotną zależność przestrzenną (rys. 7). Szczególnie widoczne jest to dla obszaru kaldery wulkanicznej, na brzegu której zmienia się znak błędu.

Podobne wyniki uzyskano dla neurointerpolacji GRNN obszaru testowego przed erupcją wulkanu św. Heleny (rys. 8). Rejon północno-wschodni (NE) wykazuje odmienne właściwości w stosunku do rejonu południowo-zachodniego (SW). Zastosowanie try-

wialnego podziału obszaru badań na dwa rejony wzdłuż przekątnej kwadratu pozwala na minimalizację błędu RMS. Uzyskane wyniki są lepsze niż efekt zastosowania klasycznej triangulacji.


sposób interpolacji	błąd RMS [m]	
	SW	NE
triangulacja	4,65	4,87
MLP	40,08	45,44
RBF	15,17	16,62
GRNN	3,75	4,04

Dalsza poprawa dokładności NMT wymagałaby zastosowania sieci neuronowej o większej liczbie parametrów wejściowych. Oprócz dwóch współrzędnych lokalizacyjnych X i Y można rozważyć uwzględnienie zmiennych nominalnych, definiujących np. podłoże geologiczne, typ formy geomorfologicznej lub nawet rodzaj pokrycia terenu. Wymaga to prowadzenia dalszych badań. Wydaje się jednak, że neurointerpolacja numerycznego modelu terenu może stanowić interesującą alternatywę dla klasycznych metod tworzenia NMT.


Dr Robert Olszewski jest adiunktem w Zakładzie Kartografii PW

Źródła:

- Domański R.**, 2000, *Sieci neuronowe – rozpoznawanie możliwości zastosowań*, Warszawa, „Przegląd Geograficzny”, tom 72, z. 4;
- Fausett L.**, 1994, *Fundamentals of Neural Networks*, New York, Prentice Hall;
- Osołowski S.**, 1996, *Sieci neuronowe w ujęciu algorytmicznym*, Warszawa, Wydawnictwa Naukowo-Techniczne;
- Patterson D.**, 1996, *Artificial Neural Networks*, Singapore, Prentice Hall;
- Tadeusiewicz R.**, 1998, *Elementarne wprowadzenie do sieci neuronowych z przykładowymi programami*, Warszawa, Akademicka Oficyna Wydawnicza;
- Artificial neural networks*, <http://hem.hj.se/~de96klda/NeuralNetworks.htm#1>
- Inteligencja obliczeniowa*, <http://www.phys.uni.torun.pl/~duch/neural>.
- Statistica Neural Networks PL*, http://www.statsoft.pl/stat_nn.html
- Sztuczne sieci neuronowe*, <http://www.nrn.prv.pl/>



Rys. 7. Powierzchnia błędu $NMT_{zród.} - NMT_{GRNN}$



Rys. 8. Powierzchnia błędu $NMT_{zród.} - NMT_{GRNN}$