

Andrzej Zawisza

Neuronowy model do prognozowania ceny nowego produktu

Przedsiębiorstwo, rozważające możliwość wprowadzenia nowego produktu/usługi na rynek, we wstępnej fazie analiz opłacalności przedsięwzięcia musi oszacować m.in. cenę rynkową potencjalnego produktu, za jaką będzie on oferowany klientom i przez nich akceptowany, a następnie powinno odnieść ją do przewidywanych kosztów produkcji, dystrybucji i oczekiwanych zysków. Jeżeli planowany produkt nie jest zupełną nowością na rynku, jego cena powinna być kształtowana nie tylko przez wartość funkcjonalną proponowanych rozwiązań, ale i przez pozycję przedsiębiorstwa na rynku oraz ceny stosowane przez przedsiębiorstwa konkurencyjne, oferujące podobne produkty/usługi.

Narzędziem ułatwiającym rozwiązanie tego problemu może być model cenowy produktu/usługi, który w swym działaniu będzie uwzględniał zarówno cechy użytkowe, jak i czynniki związane z konkurencyjnym otoczeniem. Są to informacje trudne do sparametryzowania i przedstawienia w formie analitycznego opisu przy zastosowaniu klasycznych metod modelowania, w myśl których do istniejących danych, metodą prób i błędów, dobiera się formułę najlepiej opisującą rzeczywistość w ramach przyjętych ograniczeń. O jakości wypracowanego w ten sposób modelu decyduje m.in. wiedza badacza (znajomość narzędzi analitycznych, służących budowie i ocenie funkcjonowania modelu), jego doświadczenie i intuicja. W związku z tym, modele budowane klasycznie nie opisują rzeczywistych zależności między parametrami, a odpowiadają jedynie przyjętym *a priori* wyobrażeniom o ich charakterze.

Alternatywnym rozwiązaniem, ściśle związanym z postępem prac nad problemami sztucznej inteligencji, może być użycie sieci neuronowej, której struktura i właściwości są formowane automatycznie na podstawie rzeczywistych danych wejściowych i wyjściowych. Oznacza to, że realizowana przez sieć neuronową formuła wiążąca parametry wejściowe i wyjściowe jest tworzona bez potrzeby ustalania wstępnych założeń, dotyczących występujących zależności. Zadaniem budującego model jest jedynie przygotowanie zestawu danych w formie zbiorów D i X , gdzie każdy z elementów należących do D i X jest odpowiednio wielowymiarowym wektorem d_i żądanej odpowiedzi modelu na dane wejściowe x_i . W interakcyjnym procesie „uczenia się” współczynniki wewnętrzne sieci zostają dopasowane w ten sposób, aby dla każdego i zminimalizować

rozbieżność między odpowiedzią sieci y_i przy wymuszeniu x_i , a oczekiwaną, idealną odpowiedzią d_i .

Podstawowym elementem składowym sieci jest neuron, który realizuje pojedynczą funkcję:

$$y = f\left(\sum_{j=1}^n w_j x_j\right)$$

gdzie n jest liczbą sygnałów wejściowych x , a współczynniki wagowe w_j pozwalają regulować ich wpływ na odpowiedź neuronu. Kombinacje wartości współczynników wagowych mają decydujące znaczenie dla właściwości neuronu i całej sieci. Najczęściej stosowane w praktyce funkcje f to funkcja skokowa, liniowa i sigmoidalna:

$$f(x) = (1 - e^{-x}) / (1 + e^{-x})$$


Sieć neuronowa jest zestawem neuronów odbierających sygnały z zewnątrz (z wejścia) lub z wyjść innych neuronów i przekazujących swoją odpowiedź do otoczenia (na wyjście) lub innym neuronom. Każdemu z połączeń w sieci odpowiada indywidualny współczynnik wagowy w . Przykładowa struktura sieci została przedstawiona na rys. 1. W ogólnym przypadku nie ma ograniczeń na liczbę neuronów wejściowych, wyjściowych, liczbę poziomów pośrednich i liczbę neuronów w każdym z nich.

Sieć neuronowa, jako całość, realizuje skomplikowaną funkcję analityczną, wynikającą z istnienia dużej liczby neuronów, połączeń między nimi i przypisanych im współczynników wagowych. Zapamiętywanie informacji w strukturze sieci neuronowej następuje przez modyfikację wartości współczynników wagowych w procesie uczenia. Im większa jest liczba zróżnicowanych danych wykorzystywanych w procesie uczenia, tym bardziej ogólna jest charakterystyka sieci, tzn. tym pełniej odpowiada ona rzeczywistym zależnościom wiążącym dane wyjściowe z wejściowymi.

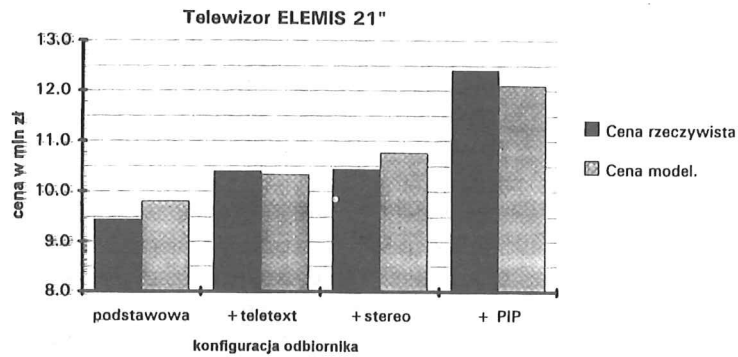
O przydatności sieci neuronowej w modelowaniu decyduje fakt, że poza zapamiętywaniem (nauczona sieć odpowiada na wektory wejściowe X wykorzystane w procesie uczenia zgodnie z żądanymi wektorami D), wykazuje ona również właściwości uogólniające. Oznacza to, że prezentacja na wejściu dowolnego wektora x spowoduje otrzymanie odpowiedzi y zgodnie z wykrytymi podczas nauki regułami.

Jako przykład zastosowania sieci neuronowych do budowy modeli marketingowych, w kontekście

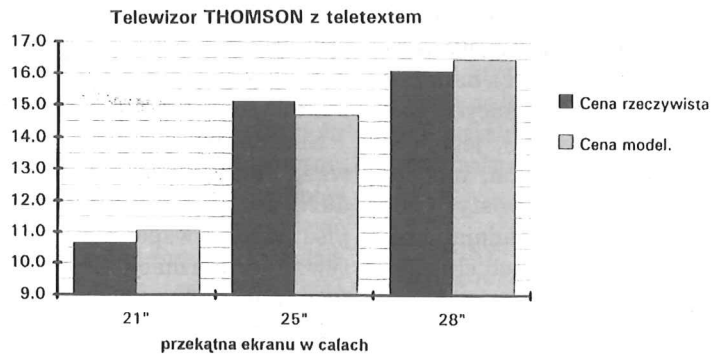





Rys. 1 Przykładowa struktura sieci neuronowej



Rys. 2. Zestawienie wyników działania modelu z wartościami rzeczywistymi przy zmiennej konfiguracji odbiornika



Rys. 3. Zestawienie wyników działania modelu z wartościami rzeczywistymi przy zmiennej wielkości ekranu



Rys. 4 Przykład właściwości uogólniających i wnioskujących sieci neuronowej

problemów ustalania ceny dla nowego produktu, opracowano prosty model neuronowy, wyznaczający cenę odbiornika telewizyjnego na podstawie parametrów określających producenta i wybrane cechy użytkowe.

Ponieważ współcześnie działające firmy stosują podobne technologie i komponenty, przyjęto założenie, że najistotniejszy wpływ na ostateczną cenę telewizora ma jego marka (nazwa firmy i związany z nią *image*), wielkość ekranu i występowanie trzech dodatkowych elementów: teletextu, stereo i PIP. Poza postulatem istnienia zależności między wymienionymi parametrami wejściowymi a ceną odbiornika, nie czyniono żadnych założeń dotyczących jej charakteru. Jako dane wstępne wykorzystane w nauce sieci posłużyły uśrednione ceny z października 1994 r. dla 70 odbiorników telewizyjnych 10 firm; telewizory pochodziły z pięciu łódzkich sklepów oferujących sprzęt RTV, a więc z naturalnego otoczenia klientów. Do budowy modelu neuronowego użyto programu BRAINMAKER v. 2.3 firmy California Scientific Software. W rezultacie otrzymano sieć neuronową o strukturze zawierającej 23 neurony w trzech warstwach. Ogólna liczba współczynników wagowych wyniosła 144. Za funkcję f przyjęto funkcję sigmoidalną o wartościach granicznych 0 i 1.

Prezentowane wyniki pozwalają ocenić skuteczność uzyskaną podczas uczenia przy modelowaniu odpowiedzi dla wybranego producenta przy ustalonej wielkości ekranu i różnych parametrach użytkowych (rys. 2) i dla różnych wielkości ekranu przy ustalonych pozostałych danych (rys. 3). Wartość bezwzględna błędu jest porównywalna z różnicami cen tego samego telewizora w zależności od sklepu. Wykres na rys. 4 stanowi ilustrację właściwości uogólniających i wnioskujących modelu. W pierwszej grupie danych przedstawiono rzeczywiste relacje cenowe odbiorników o tych samych parametrach użytkowych, ale pochodzących od różnych producentów. Dalsze elementy wykresu pokazują relacje między cenami zamodelowanymi dla odbiorników o parametrach nie występujących wśród danych pierwotnych (a więc „nowych produktów”) w odniesieniu do rzeczywistych cen jednego z producentów. Jak widać, zostają zachowane zarówno relacje między cenami porównywalnych produktów różnych firm, jak i tendencje cenowe związane ze zmianami konfiguracji odbiorników. Wypracowany w powyższy sposób model pozwala na szybkie wyznaczenie orientacyjnej ceny dla produktu stanowiącego uzupełnienie asortymentowe w ofercie przedsiębiorstwa.

Zaproponowana metoda modelowania wykazuje kilka zalet:

■ Model został zbudowany bez konieczności przewidywania charakteru zależności między parametrami wejściowymi a danymi wyjściowymi, co znacznie skraca czas potrzebny na wypracowanie i weryfikację modelu. Czas samych obliczeń (nauki) na

mikrokomputerze 486DX 66 MHz trwa ok. 1 godziny.

■ Tworzenie struktury modelu i ustalanie współczynników wagowych odbywa się automatycznie i nie wymaga znajomości analitycznych metod przetwarzania danych.

■ Podstawą tworzenia modelu neuronowego są „surowe” dane rzeczywiste, co w połączeniu z możliwością realizacji przez sieć neuronową bardzo skomplikowanej funkcji matematycznej pozwala na wyszukiwanie i modelowanie rzeczywiście występujących, a nie domniemyanych zależności.

■ Modyfikacja właściwości modelu, w celu uwzględnienia nowych faktów, może być łatwo dokonana przez „douce” sieci po uzupełnieniu zestawu wektorów wykorzystywanych w procesie uczenia, co może stanowić zadanie niezwykle trudne w przypadku konieczności aktualizacji klasycznego modelu analitycznego.

■ Istnieje duża swoboda w formułowaniu problemu – dobór wektorów wejściowych i wyjściowych ograniczony jest głównie dostępnością danych i możliwością wystąpienia poważnych sprzeczności w procesie nauczania.

Do ograniczeń opisanej metody można zaliczyć następujące fakty:

■ Otrzymywane wartości mają charakter przybliżony, szacunkowy – błąd wprowadzony już w danych wejściowych (uśrednione ceny) wynika z konieczności eliminacji danych sprzecznych i niejednoznacznych. Poza tym cena, po jakiej oferowany jest produkt, zależy również od indywidualnych zapatrywań sprzedawcy.

■ W procesie uczenia sieci wymagana jest stosunkowo duża liczba zróżnicowanych wektorów, pokrywająca w miarę możliwości pełen zakres możliwych rozwiązań i pozwalająca na wykrycie jak najbardziej ogólnych zależności. Jeżeli jako zestaw danych wstępnych posłużą wektory pochodzące jedynie z wybranego fragmentu przestrzeni parametrów, to model będzie sprawnie działał tylko w tym szczególnym obszarze i uwzględni tylko szczególne (lokalne) zależności między parametrami wejściowymi i wyjściowymi (w opracowanym modelu zakres wektorów wejściowych został ograniczony tylko do 10 firm).

Przedstawiony model neuronowy jest prostym przykładem możliwości wykorzystania nowoczesnych metod obliczeniowych w praktyce marketingowej. W związku z niezwykle dynamicznym postępem technicznym i rozwojem badań nad sztuczną inteligencją wydaje się, że zastosowania sieci neuronowych w naukach ekonomicznych będą zdobywały coraz większą popularność, szczególnie w zakresie modelowania i prognozowania zjawisk.

Andrzej Zawisza