

WPROWADZENIE DO PREDYKCJI Z WYKORZYSTANIEM SZTUCZNYCH SIECI NEURONOWYCH I METOD STATYSTYCZNYCH

Monika Nawrocka, the.monkas@gmail.com,
 Miłosz Drozd, miłosz880509@gmail.com
 Adam Maszczyk, a.maszczyk@awf.katowice.pl
 Artur Gołaś, a.golas@awf.katowice.pl



STRESZCZENIE

Podjęcie statystyczne umożliwia prowadzenie prognoz zdarzeń lub procesów. Wyróżnia się modele regresyjne liniowe i nieliniowe, modele szeregów czasowych oraz modele neuronowe. Predykcja określa przewidywanie przyszłych cech statystycznych zdarzeń losowych, które można zmierzyć. Wyznacza prognozy dla maksymalizacji.

Korzyści, jakie wynikają z prognozowania, to: porównywanie, grupowanie, analizowanie zmienności, określania trendów oraz wyznaczania prognoz uzyskanych wyników, z wykorzystaniem optymalnego wektora zmiennych niezależnych predyktorów do wyciągania sukcesywnych wniosków.

Słowa kluczowe: predykcja, analiza statystyczna, regresja, optymalizacja, szeregi czasowe, sieci neuronowe

An introduction to prediction with the use of artificial neural networks and statistical methods

ABSTRACT

Statistical approach allows determine predictions of events or processes. It stands out regression models linear and nonlinear, time series models and neural models. Prediction define anticipating the future statistical characteristics of random events that can be measured. Designates forecasts for maximizing.

Benefits that stem from prediction are: comparing, grouping, analyzing of variation, determining the trends and setting forecasts of the results obtained with the use optimal vector of independent variables predictors for drawing successive conclusions.

Key words: prediction, statistical analysis, regression, optimization, time series, neural networks

WSTĘP

We wszystkich dziedzinach wymiernych i wiedzy doświadczalnej napotyka się na wszelkie obserwacje pewnych zdarzeń czy procesów. Prowadzi to do podejmowania prób ilościowego opisu zjawisk, określanych mianem pomiarów statystycznych, które służących do prowadzenia dokładnych ocen i wyciągania rzetelnych wniosków z wyników pomiaru. Dodatkowo nowe technologie i narzędzia statystyczne umożliwiają przypuszczanie występowania pewnych zdarzeń w przyszłości. Metoda ta nazywa się predykcją. Definiowana jest, jako prognozowanie kształtowania przyszłych zdarzeń, procesów, relacji czy cech statystycznych wybranych zdarzeń. Stosuje się również wnioskowanie predycyjne na przestrzeni danego okresu czasu lub bazy danych. Warto zwrócić uwagę na to, że modele predycyjne charakteryzuje mierzalność. Wszystkie policzalne wartości można zmierzyć, grupować, porównywać i tworzyć analizy, które są podstawą modelowania predycyjnego. Najprostszym sposobem jest wcześniejsza analiza dynamiki zmian zmiennych niezależnych na przestrzeni wybranego okresu. Otrzymane wyniki umożliwią wyznaczenie zmiennych na przyszłe okresy. Kluczowym elementem wynikającym z całego procesu analizy statystycznej i predykcji jest symulacja optymalnych zmiennych w przód lub w tył¹.

PROBLEMATYKA

„Przystępując do wyznaczania zmiennych, zagadnieniem kluczowym dla poprawnego ich doboru, jest określenie jak najbardziej precyzyjnego merytorycznego przedmiotu analizy, wielowymiarowego zjawiska, które chcemy mierzyć i ze

¹ N.H. Viet, J. Mańdziuk, *Neural and Fuzzy Neural Networks in Prediction of Natural Gas Consumption*, „Neural, Parallel & Scientific Computations” 2005, no. 13(3-4), s. 265-286.

względu, na które chcemy porównywać obiekty.² Skutecznym sposobem wyznaczenia optymalnego zbioru zmiennych niezależnych służy: modelowanie funkcji czasowej, metoda wyznaczenia wektorów R0 i R1 z analizą regresyjną metodą krokową lub oszacowanie parametrów równań regresji przy dwóch sposobach:

- różne kombinacje zmiennych x_i i każdorazowe wyliczenie błędu resztkowego S_c
- zastosowanie takiej ilości zmiennych x_j , aby zmniejszyć błąd resztkowy S_c . Wszystkie ze zmiennych muszą posiadać istotny współczynnik α_j .

Modelowanie predykcyjne konstruowane jest przy użyciu różnych metod. Proces prognozy obejmuje dwie fazy. Początkowo diagnozuje się przeszłość, a kolejno określa się przyszłość. Pierwszy etap zwykle sprowadza się do budowania modelu (ekonometrycznego, binarnego), który zostaje zweryfikowany i oszacowany. Uzyskanie prognozy to przejście z danych przetworzonych do predykcji. Dane użyte w artykule były przykładowe, a wszelkich obliczeń dokonano z użyciem pakietu STATISTICA 9.1 PL i MS Excel 2013.

REGRESJA LINIOWA I NIELINIOWA

Sposobem badania obiektów i zjawisk jest prowadzenie eksperymentów w warunkach sztucznych i naturalnych. Przypuszcza się, że używanie funkcji matematycznych jest skuteczne przy opisie współzależności przynajmniej dwóch zjawisk. Wielkościami czy miernikami mogą być zmienne matematyczne (ilościowe), np. funkcja czasu, siły, itd³. „Obok zjawisk, których wzajemny związek jest tak ścisły, że może być uznany za związek funkcyjny, istnieją zjawiska, których związek jest słaby, a przy tym zatarty przez oddziaływanie wielu innych, ubocznych zjawisk, którego w trakcie procesu obserwacji nie dało się wyeliminować.”⁴ Takie zjawisko określa się jako stochastyczne. Zachodzi wtedy, gdy współzależność pomiędzy zmiennymi i zmiana jednej z nich powoduje zmianę rozkładu w pozostałych zmiennych. Wyróżnia się regresje z dwiema zmiennymi lub z trzema, czterema, a nawet większą ilością zmiennych. W przypadku dwóch zmiennych losowych X i Y linia regresji jest linią prostą i, wtedy oznacza regresję zwaną liniową. Sytuacja zmienia się, gdy pojawia się więcej zmiennych. Przy trzech zmiennych otrzymuje się powierzchnie regresji, a przy więcej niż czterech hiperpowierzchni zmiennych. Linia regresji tworzona jest na podstawie punktów, lecz nie leży bezpośrednio na tych punktach. Wyznaczana jest wśród skupiska punktów (wykres rozrzutu)⁵, co przedstawiono poniżej na podstawie danych przykładowych wartości zmiennej 1 i zmiennej 2 w okresie 1-5. Utworzono wykres rozrzutu, zmierzono korelację i utworzono macierz wykresów dla wybranych zmiennych.

Przykład z tabeli nr 1 i rysunku 2. ilustruje wykres rozrzutu liniowy z przedziałem ufności $p=0,95$. Rodzaj wykresu jest zwykły. Punkty znacznie odchylają się od linii regresji. Wnioskuje się, że ocena wartości zmiennej 1 do wartości zmiennej 2 jest słaba i niedokładna. Poszczególne punkty znacznie odchylają się od siebie. Ocena linia regresji jest dokładna wtedy, gdy punkty w mniejszym stopniu odchylają się od siebie. Jednakże najlepszą metodą badania współzależności pomiędzy zmiennymi losowymi jest miara korelacji. Umożliwia, bowiem zmierzenie siły i kierunku współzależności, czy zmienne są skorelowane pomiędzy sobą.

Tabela 1. Wartości liczbowe zmiennej 1 i zmiennej 2 w okresie 1-5.

Okres	Zmienna 1	Zmienna 2
1	4,3	2,4
2	2,5	4,4
3	3,5	1,8
4	4,5	2,8
5	4,7	2,9

Źródło: opracowanie własne.


2 A. Maszczyk, *Analiza i predykcja dynamiki zmienności światowych wyników konkurencji lekkoatletycznych w latach 1946-2011*, Katowice 2013, s. 34.

3 A. Maszczyk, *Analiza i predykcja...*, dz. cyt., s. 32-37.

4 Z. Hellwing, *Regresja liniowa i jej zastosowanie w ekonomii*, Warszawa 1967, s. 10.

5 Tamże, s. 15-20.

Wykres 1. Wykres rozrzutu zmiennej 2 względem zmiennej 1.



Źródło: Opracowanie własne w Statistica 9.1 PL.


Rys 1. Korelacje zmiennej 1 i zmiennej 2.

Korelacje				
Oznaczone wsp. korelacji są istotne z $p < ,05000$				
N=5 (Braki danych usuwano przypadkami)				
Zmienna	Średnia	Odch.std	Zmn1	Zmn2
Zmn1	3,900000	0,905539	1,000000	-0,828267
Zmn2	3,060000	0,773305	-0,828267	1,000000

Źródło: opracowanie własne w Statistica 9.1 PL.

Oznaczone współczynniki korelacji są istotne z $p < 0,05$ i $N=5$.

Rys 2. Wykres korelacji z przedziałem ufności $p=0,95$



Źródło: opracowanie własne w Statistica 9.1 PL.

Największe skupisko przypadków zaobserwowano w przedziale wartości zmiennej 1 i 2 od 2,4-4,3 do 2,9-4,7. Oszacowano wcześniej statystyki podstawowe. Zmienną 1 charakteryzuje średnia 3,9, odchylenie standardowe 0,905, maksimum 4,7 i minimum 2,5. W przypadku zmiennej 2 wartość średniej 3,06, odchylenia standardowego 0,773, maksimum 4,4 oraz minimum 2,4. Duża różnica występuje wyłącznie przy wartości średniej. Współczynnik korelacji $r = -0,8283$, a funkcja przybrała postać: $y(Zm2) = 5,8185 - 0,7073 * x(Zm 1)$. Wystąpiły korelacje silne i ujemne.

Metody regresji i korelacji pozwalają w wielu przypadkach na podstawie funkcji czasu prognozować zdarzenia. Predykcja opiera się o wcześniejszą analizę dynamiki zmian zmiennych i przy użyciu linii trendu o postaci liniowej, wykładniczej, wielomianowej potęgowej, logarytmicznej czy średniej ruchomej wyznacza wartości przyszłe. Prognozy można tworzyć na okres w przód lub w tył.

Spotyka się również funkcje nieliniowe, które wymagają przekształceń na postać liniową. Zjawisko takie pojawia się przy zmienności wyników w funkcji czasu. Przekształcenie takiego modelu z wieloma zmiennymi niezależnymi wymaga podstawienia zmiennych, co przedstawiono na wzorze poniżej:

$$m(x) = b_0 + b_1 x + b_2 x^2$$

$$x_1 = x \quad x_2 = x^2$$

Etapem następnym jest estymacja parametrów metodą najmniejszych kwadratów. Służy do tego współczynnik determinacji R^2 :

$$R^2 = 1 - \varphi^2 \quad \varphi^2 = \frac{\sum (Y_i - Y_E)^2}{\sum (Y_i - \bar{Y})^2}$$

φ^2 - współczynnik zbieżności

Y_i - wartość teoretyczna

Y_E - wartość empiryczna

Mając oszacowane parametry struktury stochastycznej modelu regresji, powinno się dobrać postać modelu nieliniowego, bazując na badanych prawidłowościach. Rodzaje postaci modeli nieliniowych to: logarytmiczna, potęgowa lub wykładnicza.

$$y = b_0 x_1^{b_1} x_2^{b_2} \dots x_k^{b_k}$$

Powyższy model nieliniowy ma postać potęgową. Elastyczność zmiennej Y względem zmiennych X_1, X_2, \dots, X_k jest stała.

$$y = b_0 + b_1 \log x$$

Kolejny to model logarytmiczny. Ten rodzaj modelu oznacza, że przyrostowi zmiennej objaśniającej towarzyszą coraz mniejsze przyrosty zmiennej objaśnianej.

$$y = b_0 b_1^x$$

Ostatnią postacią jest model wykładniczy. Jednostkowemu przyrostowi zmiennej objaśniającej odpowiadają coraz większe przyrosty zmiennej objaśnianej⁷.

SZEREGI CZASOWE

Szeregi czasowe dotyczyć mogą „jednej (Y_t) lub wielu (Y_{1t}, Y_{2t}, \dots) zmiennych losowych, przy czym ich realizacje charakteryzują się nieprzypadkowym porządkiem ze względu na kolejność czasu $t=1, 2, \dots, n-1, n$ ”⁸. Dokładniej chodzi o wykrycie relacji, jakie zachodzą pomiędzy zmiennymi losowymi poprzez obserwacje na przestrzeni czasu. Techniki

6 A. Snarska, *Statystyka Ekonometria Prognozowanie. Ćwiczenia z Excelem 2007*, Warszawa 2011, s. 201.

7 A. Maszczyk, *Analiza i predykcja...*, dz. cyt., s. 37-39.

8 A. Luszniwicz, T. Słaby, *Statystyczne Analizy z użyciem pakietu Statistica PL. Szeregi czasowe i prognozowanie*, Warszawa 1999, s. 7.

służące temu procesowi to: wykreślanie trendów, okresowości i reszt. Niezmiernie ważne jest wyrównywanie szeregów czasowych. Metoda takiego wygładzenia opiera się na zwykłych lub scentrowanych średnich ruchomych i funkcjach liniowych lub nieliniowych. Niestety, pierwsza z metod jest mało dokładna, stad definiowana jest, jako techniczna. Druga natomiast jest metodą analityczną i bardziej nadaje się do prognozowania statystycznego. Uzyskane linie trendu i okresowości rzetelniej wyznaczają predykcje⁹.

Występuje podział na jednowymiarowe modele trendów, jednowymiarowe modele procesów z ogólnym liniowym trendem i autoregresyjne modele szeregów czasowych. Najczęściej stosuje się modele autoregresyjne. Typowy model to ARMA i ARIMA w predykcji dyscyplin wymiernych. Dzieje się tak, gdyż przy dużych n one dają największe korzyści prognostyczne. „Okazuje się, że przy założeniu znajomości procesu ARMA, generującego pełne szeregi, prognozy z tych szeregów są, co najmniej tak dobre, jak prognozy z niekompletnych szeregów z systematycznie pomijanymi obserwacjami, o ile tym kryterium porównania był błąd średniokwadratowy predykcji.¹⁰” Równanie modelu ARMA sprowadza się wśród rozważań nad stochastycznymi modelami dynamicznymi klasy liniowej oraz szeregów czasowych. Wykorzystuje się w tym celu model autoregresyjny AR(p) oraz modele o liniowej zależności, lecz z występowaniem różnych okresów, zwane modelem średniej ruchomej MA(q).

$$r_t = \phi_1 r_{t-1} + \phi_2 r_{t-2} + \dots + \phi_p r_{t-p} + \varepsilon_t,$$

W model AR(p) liczbę składników procesu należy ograniczać do najważniejszych generujących dane z jak najmniejszą ilością parametrów. Charakteryzuje się długotrwałym wpływem na szoki stochastyczne. Następnie mierzy się szeregi czasowe MA(q).

$$r_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q}$$

Otrzymane wyniki z modelu AR(p) i MA(q) można łączyć, aby uzyskać najlepszą oszczędność uporczywości skoków reprezentowanych przez składnik losowy (ε) na stopy zwrotu (r)¹¹.

$$r_t = \phi_1 r_{t-1} + \varepsilon_t + \theta_1 \varepsilon_{t-1}$$

Proces połączenia składników autoregresyjnych i składników średniej ruchomej w konsekwencji prowadzi do utworzenia autoregresyjnego modelu średniej ruchomej rzędu p i q , jako ARMA(p, q)¹².

SIECI NEURONOWE

Sieci neuronowe odwzorowują odtwarzanie możliwości mózgu ludzkiego przy stosowaniu sztucznych środków. Wszystkie składniki sieci stanowią siatkę węzłów (neuronów) i ich połączeń. „Neurony wykonują sumowanie i nieliniowe odwzorowanie sygnałów.¹³” Połączenia neuronów mogą wystąpić ze sprzężeniem zwrotnym lub bez niego. Wiadomo, że gdy nie występuje połączenie zwrotne, to sieci reagują od razu na pobudzenie. W przypadku połączeń zwrotnych sieć wymaga czasu na udzielenie odpowiedzi. Można wtedy obserwować dynamikę funkcjonowania sieci w czasie.

Modelowanie oparte o sztuczne sieci neuronowe przede wszystkim służy do określania architektury. Cykl ten prowadzony jest na podstawie specyfikacji charakterystyki neuronów, początkowych wartości wag (liczbowe oddziaływanie połączeń) i wyboru metody uczenia się, czyli (trenowania) sieci. Definiuje on pewną klasę algorytmów matematycznych. „Istnieje wiele różnych metod uczenia określających, kiedy i w jaki sposób zmieniają się wagi połączeń pomiędzy neuronami.¹⁴”

Ze względu na różną specyfikę, sposób uczenia się czy wielkości sieci istnieje wiele trudności przy wyborze architektury sieci neuronowej. Jednakże są oprogramowania, które oferują użytkownikowi wybór optymalnej sieci do preferowanych parametrów. Wyróżnia się takie modele, jak¹⁵:

9 M. Nawrocka, *Zbornik z medzinárodnej vedeckej konferencie - Atletika 2014: Analysis of Dynamics ports result changes in 20 km race-walking*. Banska Bystrica [Slovakia] 2014, s. 276-288.

10 W. Milo, *Szeregi czasowe*, Warszawa 1990, s. 178.

11 R. Czyżycki, R. Klóska, *Ekonometria i prognozowanie zjawisk ekonomicznych w przykładach i zadaniach*, Szczecin 2011, s. 250-270.

12 W. Milo, *Szeregi...*, dz. cyt., s. 175-179.

13 J. Żurada, M. Barski, W. Jędruch, *Sztuczne sieci neuronowe*, Warszawa 1996, s. 13.

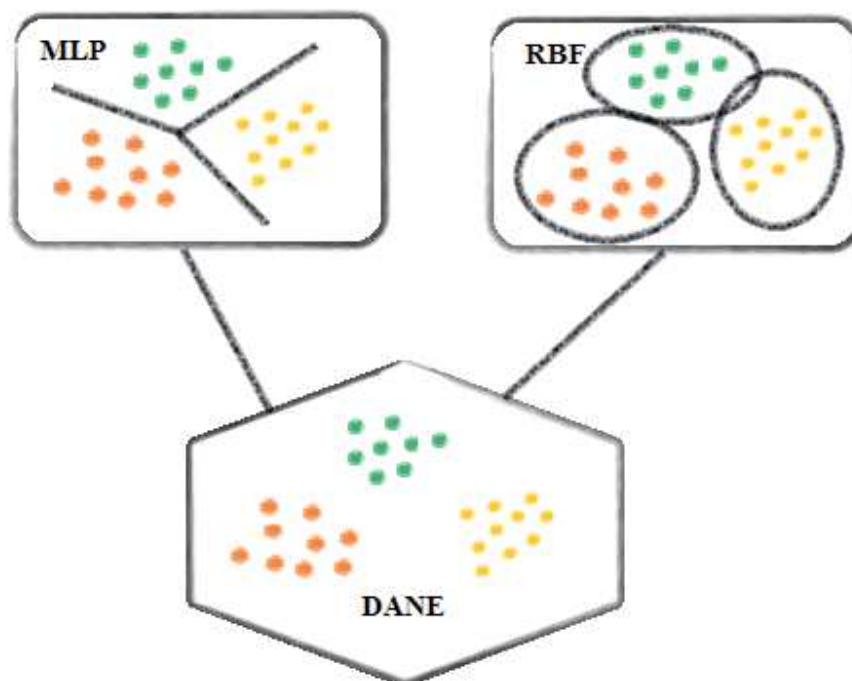
14 Tamże, s. 15.

15 N. H. Viet, J. Mańdziuk, *Prediction of natural gas consumption with feed-forward and fuzzy neural networks*, 6th International Conference on

- sieci perceptronowe wielowarstwowe (MLP) jednokierunkowe,
- sieci o radialnych funkcjach bazowych (RBF),
- sieci rekurencyjne typu: Hopfieldda, maszyna Boltzmanna, rezonansowe sieci ART i sieci BAM; ze sprzężeniem zwrotnym,
- sieci komórkowe samoorganizujące się mapy cech Kohonena.

W artykule zwrócono szczególną uwagę na sieci jednokierunkowe perceptronowe i o radialnych funkcjach bazowych. Porównując sieci RBF i MLP, można dostrzec, że różnią się onesposobem działania. Sieć RBF tworzy lokalne obszary pomiędzy klasyfikacją obszarów, a MPL wielowymiarową przestrzeń – hiperpłaszczyznę (obszary globalne). Okazuje się, że jest to mniej dokładna metoda, gdyż część stworzonych podobszarów pozostaje nieskończona. MPL jest metodą uczenia sieci poprzez dyskryminację, a dokładniej aproksymację stochastyczną. RBF cechuje zupełnie inne podejście. Uczenie jest rozumiane jako problem aproksymacji, najlepszego dopasowania (rekonstrukcji) hiperpowierzchni do danych wejściowych.

Rys 3. Schemat podziału przestrzeni danych w sieci MLP i RBF.



Źródło: opracowanie własne.

Rysunek ilustruje rozdział danych na hiperpowierzchnie. Można, więc uznać, że jest to kombinacja liniowa wprowadzonych danych. Charakteryzuje się strukturą modułową. Zestawienie neuronów może być w różnych układach. Jednakże w większości przypadków stosuje się warstwy neuronów. Stwierdza się, że sieci MLP są mniej dokładne od RBF. Wynika to z tego, że rozkład danych nie jest rozrzucony (połączenia lokalne).

Sieci o radialnych funkcjach bazowych i perceptronowych mają zastosowanie w aproksymacji. Określa to proces szukania rozwiązań dla danych uzyskanych metodami empirycznymi. Zakłada się, że metody te obarczone są błędem statystycznym. Rozwiązania szukane są na podstawie znanych już rozwiązań dla skomplikowanych zdarzeń czy funkcji. Sieci RBF charakteryzują rozwiązania aproksymacji nieparametrycznej. Natomiast MLP stosuje metodę aproksymacji stochastycznej. Znając teorie modeli jednokierunkowych, można przytoczyć typowy wzór sieci o radialnych funkcjach bazowych:

Artificial Neural Networks and Genetic Algorithms (ICANN'03), Roanne, France, Springer-Verlag, Wien 2003, s. 107-114.

$$f(\mathbf{x}; \mathbf{w}, \mathbf{p}) = \sum_{i=1}^M w_i G_i(\mathbf{x}, \mathbf{p}_i).$$

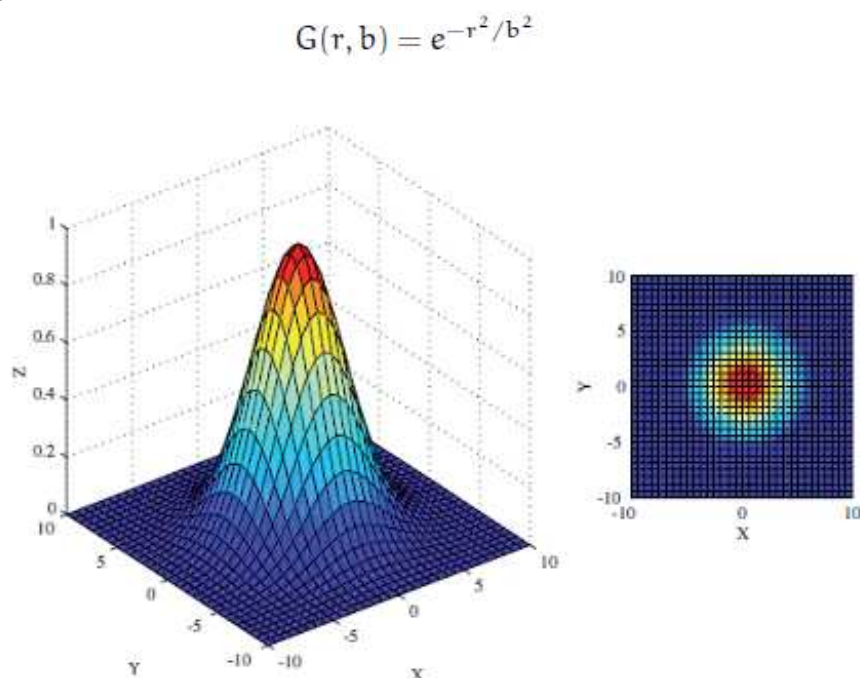
M – liczba neuronów warstwy ukrytej

$G_i(x, p_i)$ – funkcja i-tego neuronu warstwy ukrytej (jedna z radialnych funkcji bazowych)

p_i – parametry adaptowalne i-tych neuronów warstwy ukrytej

Wyróżnia się radialne funkcje, takie jak: gaussowska, sferyczna, potęgowe i sklejane¹⁶. Zlokalizowane są wokół jednego centrum. Najpopularniejszą z wymienionych jest funkcja gaussowska, która jest najprostszą z funkcji lokalnych. Cechuje ją separacja różnych komponentów. Nie stanowi problemów w użyciu z innymi miarami. Przybiera postać zdefiniowaną poniżej:

Rys 4. Funkcja gaussowska.



Źródło: www.statsoft.pl

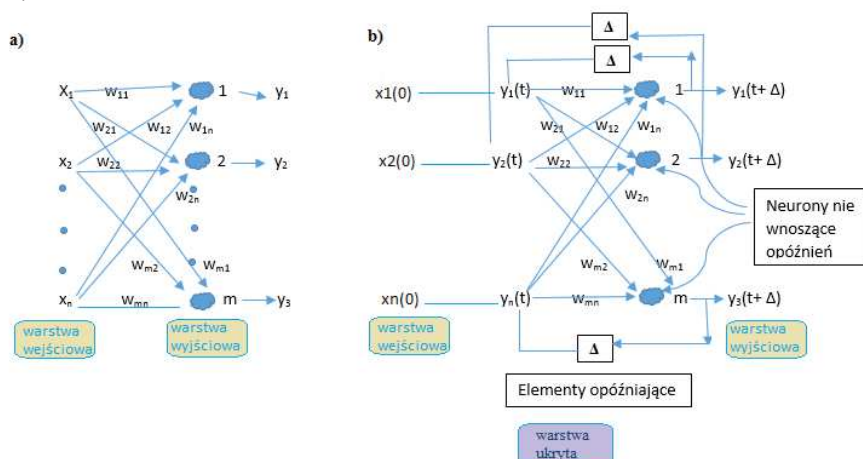
Jednowarstwowe modele neuronowe o jedno lub wielowarstwowymi połączeniami to jedno z typów sieci. Drugie to rekurencyjne sieci dyskretne lub gradientowe Hopfielda. Posiadają sprzężenie zwrotne i są jednowarstwowe tak jak wyżej omówione sieci RBF i MPL. Stosowane są przy rozwiązywaniu problemów optymalizacyjnych i mają charakter dysypatywny (dynamika stochastyczna)¹⁷. „Układ dynamiczny przetwarza informację zawartą w stanach początkowych, wymuszonych w chwili $t=0$ inicjującym sygnałem wejściowym.¹⁸” Znaczący to, że układ może zmieniać się i dążyć do różnych atraktorów. Definiuje stan końcowy, do którego dąży zbiór stanów początkowych. Poniżej przedstawiono różnice w sieci jednokierunkowej ze sprzężeniem zwrotnym i bez niego.

¹⁶ K. Mossakowski, J. Mańdziuk, *Neural networks and the estimation of hands' strength in contract bridge*, „Lecture Notes in Artificial Intelligence” 2006, vol. 4029, s. 1189-1198.

¹⁷ J. Mańdziuk, *Hopfield-type Neuron Networks. Theory and application examples*, Warsaw 2000, s. 41-45.

¹⁸ J. Żurada, M. Barski, W. Jędruch, *Sztuczne...*, dz. cyt., s. 161.

Rys 5. Typologia sieci neuronowych. a) jednokierunkowa bez sprzężenia zwrotnego, b) jednokierunkowa ze sprzężeniem zwrotnym.



Źródło: opracowanie własne.

Model jednowarstwowej sieci ze sprzężeniem zwrotnym (model Hopfielda) zakłada, że „macierz wag jest symetryczna, tzn. $w_{ij}=w_{ji}$ oraz, co widać na rys. 3b), że wyjście dowolnego neuronu połączone jest poprzez multiplikatywne wagi z wejściami pozostałych neuronów, ale nie jest połączone z jego własnym wejściem.¹⁹”

WNIOSKI

Stwierdza się, że w każdej dziedzinie nauk wymiernych prowadzone są prognozy, które, jak już wspomniano w poprzednich częściach artykułu, wymagają obliczeń opartych o metody statystyczne i narzędzia predykcyjne. Korzyści, jakie z tego wynikają, to w szczególności wyznaczanie prognoz uzyskanych wyników z wykorzystaniem optymalnego wektora zmiennych niezależnych – predyktorów do wyciągania sukcesywnych wniosków.

Optymalizacja w znaczeniu ogólnym stosowana jest do osiągnięcia maksymalizacji. Użycie jej w celach naukowych prowadzi do symulacji komputerowej optymalnych zmiennych na podstawie danych wsadowych.

W badaniach Maszczyka udowodniono, że modelowanie regresyjne na światowej czołówce lekkoatletów sprawdza się przy optymalizacji zmiennych i tworzeniu linii trendu osiąganych wyników sportowych²⁰. Umożliwiło to wyznaczenie predyktorów wyników sportowych. Istnieje również szereg badań, w których wyróżnia się inne równie skuteczne metody modelowania optymalizacyjnego. Takim przykładem jest programowanie matematyczne. W literaturze wojny dowiedziono, że obejmuje ono zbiór metod zaliczanych do badań operacyjnych i optymalizacyjnych. Udziela także odpowiedzi na zagadnienia dotyczące zarządzania decyzyjnego oraz zjawisk gospodarczo-społecznych. Programowanie matematyczne obejmuje m.in. działy: liniowe i nieliniowe, dyskretne, dynamiczne itd²¹, dlatego metody te są powszechnie stosowane do prowadzenia analiz. Tak samo jak modelowanie regresyjne sprawdzają się przy wyznaczaniu predyktorów, tworzeniu trendów liniowych czy badaniu związków pomiędzy zmiennymi.

Odwołując się do psychologii, można przytoczyć badania nad osobowością ludzką, co oznacza stworzenie układu powiązań danych zachowań z cechami osobowości. W badaniach przeprowadzonych przez Read, Monroe, Brownstein, Yang, Chopra i Mille uczono sieci neuronowe na podstawie cech osobowościowych, a mianowicie: towarzyski, nieśmiały, przekonana, pragnąc, pracowita, leniwy względem celów, jakich badani oczekują, jakich unikają i zasobów, jakimi dysponują²². Celem badań były symulacje, jakie zachowania odzwierciedlają określone cechy osobowościowe. Również Checa1, Rodríguez-Bailón i Rosariouczyli sieci neuronowe, jako systemy temperamentalne do oznaczenia neuropoznawczych struktur samokontroli u nastolatków i studentów²³. Na podstawie informacji pewnych wzorców zachowań psychologicznych Michael, Posner i Ro-

19 Tamże, s. 163.

20 A. Maszczyk, *Analiza i predykcja...*, dz. cyt., s. 247-248.

21 A. Wojna, *Predykcja ekonometryczna oraz modelowanie stochastyczne. Część I*, Koszalin2007 s. 18-20.

22 S. J. Read, B. M. Monroe, A. L. Brownstein, Y. Yang, G. Chopra, L. C. Miller, *A Neural Network Model of the Structure and Dynamics of Human Personality*, „Psychological Review” 2010, Vol. 117(1), s. 61-92.

23 P. Checa, R. Rodríguez-Bailón, M. R. Rueda, *Neurocognitive and Temperamental Systems of Self-Regulation and Early Adolescents' Social and Academic Outcomes*, „Mind, Brain and Education” 2008, Vol. 2 (4), s. 177-187.

thbart wykazali, że łączenie sieci neuronowych z indywidualnymi różnicami doświadczeń działań ludzkich, jak i kulturowych stanowi efektywne wykorzystania przy analizie prawidłowego rozwoju. Dowiedziono, że podejście sieciowe w naukach psychologicznych stanowi podstawę do przewidywania i zrozumienia zachowania człowieka w jego różnych formach²⁴.

PODSUMOWANIE

Wdrożenie predykcji i zaawansowanych metod statystycznych umożliwia prowadzenie prognoz pewnych zdarzeń i procesów bez ograniczeń do modeli liniowych z jedną zmienną. Prognostyczne analizy okazują się bardzo ważne do wyznaczania kierunków rozwoju lub przewidywania wyników działań.

Wszystkie metody wyznaczania predykcji i analiz statystycznych prowadzą do symulacji optymalnych zmiennych. Istotną metodą optymalizacji jest również programowanie matematyczne, a m.in.: programowanie liniowe i nieliniowe, dyskretne, dynamiczne i stochastyczne. „Ze względu na treść rozpatrywanych problemów programowania matematycznego często jest ono zaliczane do badań operacyjnych, natomiast odrębne jego części traktowane są jako działy badań operacyjnych.”²⁵ Zastosowanie jest szerokie, a w szczególności obejmuje udzielanie odpowiedzi na zagadnienia ekonomiczne.

„Szczególnie obiecujące są zastosowania sieci neuronowych do sterowania nieliniowymi obiektami dynamicznymi. Gromadzenie i zapamiętywanie informacji koniecznej do sterowania jest idealnym zadaniem dla pamięci asocjacyjnej.”²⁶ Polega na tym, że sieć wyłącznie odtwarza wzór postaci obiektu czy sygnału z pamięci zasadniczej. Inaczej określana jest, jako pamięć odtwarzania skojarzeń. Zniekształcony obraz wejściowy sygnału ma tylko naprowadzić na odtworzenie właściwego obrazka. Doskonałość sieci neuronowych wynika ze spojrzenia na całe zjawisko. Korzyści, jakie niesie ze sobą prognozowanie, obejmuje następujące dziedziny naukowe:

- psychologię – wzorce struktur przetwarzania informacji przez człowieka,
- informatykę – sztuczna inteligencja, teoria obliczeń czy symulacja komputerowa,
- elektronikę – układy przetwarzające sygnały, maszyny wykorzystujące elektroniczne układy scalone,
- biologię i fizykę – różnice pomiędzy modelami sieci neuronowych a nieliniowymi układami dynamicznymi,
- matematykę – różnice pomiędzy opisami formalnymi sieci a modelowanie systemów złożonych.

Biorąc pod uwagę szereg zastosowań sieci neuronowych i metod statystycznych w różnych dyscyplinach naukowych, warto wdrażać modelowanie neuronowe, liniowe i nieliniowe w proces badań naukowych.

BIBLIOGRAFIA:

- [1] Barto A.G., *Connectionist learning for control: An overview*, [w:] Miller W. T., Sutton R. S., Werbos P. (red.), *Neural Networks for Robotics and Control*, Cambridge 1990
- [2] Checa P, Rodríguez-Bailón R., Rueda R. M., *Neurocognitive and Temperamental Systems of Self-Regulation and Early Adolescents' Social and Academic Outcomes*, „Mind, Brain, and Education” 2008, Vol. 2 (4)
- [3] Czyżycki R., Klóska R., *Ekometria i prognozowanie zjawisk ekonomicznych w przykładach i zadaniach*, Szczecin 2011
- [4] Hellwing Z., *Regresja liniowa i jej zastosowanie w ekonomii*, Warszawa 1967
- [5] Luszniwicz A, Słaby T., *Statystyczne Analizy z użyciem pakietu Statistica PL. Szeregi czasowe i prognozowanie*, Warszawa 1990
- [6] Mańdziuk J., *Hopfield-type Neuron Networks. Theory and application examples*, Warsaw 2000
- [7] Maszczyk A., *Analiza i predykcja dynamiki zmienności światowych wyników konkurencji lekkoatletycznych w latach 1946-2011*, Katowice 2013
- [8] Michael I., Posner M.I., Rothbart M. K., *Research on Attention Networks as a Model for the Integration of Psychological Science*, „Annual Review of Psychology” 2007, Vol. 58
- [9] Mossakowski K., Mańdziuk J., *Neural networks and the estimation of hands' strength in contract bridge*, „Lecture Notes in Artificial Intelligence” 2006, Vol. 4029
- [10] Nawrocka M., *Zbornik z międzynarodowej vedeckej konferencie - Atletika 2014: Analysis of dynamic sports result changes in 20 km race-walking*, Slovakia 2014
- [11] Snarska A., *Statystyka Ekonometria Prognozowanie. Ćwiczenia z Excelem 2007*, Warszawa 2011
- [12] Read S. J., Monroe B. M., Brownstein A. L., Yang Y., Chopra G., Miller L. C., *A Neural Network Model of the Structure and Dynamics of Human Personality*, „Psychological Review” 2010, Vol. 117(1)
- [13] Wojna A., *Predykcja ekonometryczna oraz modelowanie stochastyczne. Część 1*, Koszalin 2007
- [14] Viet N. H., Mańdziuk J., *Prediction of natural gas consumption with feed-forward and fuzzy neural networks*, 6th International Conference on Artificial Neural Networks and Genetic Algorithms (ICANN'03), Roanne, France, Springer-Verlag, Wien 2003
- [15] Viet N. H., Mańdziuk J., *Neural and Fuzzy Neural Networks in Prediction of Natural Gas Consumption*, „Neural, Parallel & Scientific Computations” 2005, no. 13(3-4)
- [16] Żurada J., Barski M., Jędruch W., *Sztuczne sieci neuronowe*, Warszawa 1996

24 I. Michael, M. I. Postner, M. K. Rothbart, *Research on Attention Networks as a Model for the Integration of Psychological Science*, „Annual Review of Psychology” 2007, Vol. 58, s. 1-23.

25 A. Wojna, *Predykcja ekonometryczna i...*, dz. cyt., s. 24.

26 A. G. Barto, *Connectionist learning for control: An overview. In: Neural Networks for Robotics and Control*, Cambridge 1990, s. 5-56.