

Maria MRÓWCZYŃSKA¹

DEFORMACJE KONSTRUKCJI KOMINA STALOWEGO W ASPEKCIE ZASTOSOWANIA GRUPOWEJ OBRÓBK DANYCH

Zasadniczym elementem technologii geodezyjnych jest dziedzina przetwarzania informacji, której dynamiczny rozwój wzbogaca klasyczne algorytmy obliczeń numerycznych, stanowiących podstawę finalnego wyznaczenia produktu prac inżynierskich. W kontekście modelowania procesów przemieszczeń i odkształceń pojawia się ciekawy temat przetwarzania informacji bazującego na sztucznej inteligencji, w szczególności na sztucznych sieciach neuronowych, które mają zdolność modelowania bardzo złożonych procesów. Sztuczne sieci neuronowe powstały na podstawie badań prowadzonych w dziedzinie sztucznej inteligencji. Szczególne znaczenie miały prace dotyczące działania systemu nerwowego istot żywych oraz budowy modeli struktur występujących w mózgu. Sztuczne sieci neuronowe ze względu na ich nieliniowy charakter reprezentują wyrafinowaną technikę modelowania i są zaliczane do metod inteligencji obliczeniowej. Funkcje pełnione przez sieć pozwalają uzyskać korzystne rezultaty praktyczne w obszarze takich zagadnień jak: aproksymacja, interpolacja, rozpoznawanie i klasyfikacja wzorców, kompresja, predykcja i wiele innych. Zastosowanie sieci neuronowych wprowadza jednak do rozwiązania trudny do określenia błąd metody, dlatego zauważono konieczność poszukiwania rozwiązań alternatywnych opartych na przetwarzaniu danych empirycznych. Przykładem takiego rozwiązania jest metoda grupowej obróbki danych (ang. *Group Method of Data Handling* –GMDH) należąca do klasy algorytmów ewolucyjnych.

W artykule przedstawiono podstawowe założenia metody grupowej obróbki danych z zasadami budowy i uczenia statycznych sieci neuronowych o wielu wyjściach i jednym wejściu. Sieć GMDH została wykorzystana do modelowania deformacji osi geometrycznej komina stalowego, służącego do odpowietrzania podziemnych zbiorników z gazem, w procesie eksploatacji. Komin jest objęty pomiarami kontrolnymi prowadzonymi podczas jego eksploatacji z częstotliwością co 1 rok.

Słowa kluczowe: sztuczna inteligencja, grupowa obróbka danych, wychylenia od pionu

¹ Maria Mrówczyńska, Uniwersytet Zielonogórski, ul. Z. Szafrana 1, 65-516 Zielona Góra, 683282636, m.mrowczynska@ib.uz.zgora.pl

1. Wstęp

Sztuczne sieci neuronowe znajdują zastosowanie do rozwiązywania wielu problemów z zakresu różnych dziedzin nauki przede wszystkim, ze względu na prostą implementację oraz zdolność aproksymacji bez konieczności formułowania zależności pomiędzy danymi wejściowymi a danymi wyjściowymi [1, 2]. Sieci obarczone są jednak błędem metody, który jest trudny do określenia i wyeliminowania, a wynikającym z arbitralnego przyjęcia struktury sieci. Wykorzystując sieci neuronowe do modelowania skomplikowanych zagadnień błąd ten ma znaczący wpływ na ostateczny rezultat uczenia. Dlatego też zaproponowano rozszerzenie procesu uczenia również na połączenia pomiędzy neuronami. Przykładem takiego rozwiązania może być metoda grupowej obróbki danych (ang. *Group Method of Data Handling* – GMDH), której koncepcja została opracowana przez Iwachnienko [3; 4]. Sieć GMDH należy do grupy sieci samoorganizujących się, a jej struktura, tworzona samoczynnie na podstawie zbiorów danych uczących i testujących, jest strukturą hierarchiczną składającą się z wielomianowych modeli cząstkowych [5]. Taki tok postępowania prowadzi do uzyskania ostatecznej struktury wynikowej sieci pozwalającej na uzyskanie sygnału wyjściowego, który jest najlepszy biorąc pod uwagę przyjęte kryterium identyfikacji. Sieć GMDH zapewnia wysoką dokładność uzyskiwanych wyników oraz praktyczną użyteczność algorytmu [4].


W prezentowanej pracy metoda grupowej obróbki danych została wykorzystana do modelowania deformacji osi geometrycznej komina stalowego służącego do odpowietrzania podziemnych zbiorników z gazem, na podstawie cyklicznie wykonywanych pomiarów począwszy od 2007 roku.

2. Sieć neuronowa GMDH

Zminimalizowanie błędu metody wynikającego z arbitralnie przyjętej architektury sieci na etapie projektowania, można uzyskać poprzez połączenie procesu uczenia z wyznaczeniem optymalnej struktury sieci neuronowej. Metoda grupowej obróbki danych GMDH polega na zastąpieniu całościowego modelu sieci neuronowej strukturą hierarchiczną, która zbudowana jest z wielomianowych modeli cząstkowych. Sama sieć jest konstruowana poprzez łączenie określonej liczby m pojedynczych neuronów (rys. 1) przetwarzających sygnał wejściowy \mathbf{x} w sygnał wyjściowy y zgodnie z zależnością opisaną funkcją przejścia f :

$$y = f(\mathbf{x}) = f(x_1, x_2, \dots, x_m) \quad (1)$$

przy założeniu, że przynajmniej dwa sygnały wejściowe ze wszystkich możliwych x_1, x_2, \dots, x_m stanowią pobudzenie.



Rys. 1. Budowa neuronu typu GMDH (opracowanie własne)

Fig. 1. The structure of a GMDH type neuron (prepared by the author)


Funkcja przejścia (1) nie powinna być zbyt rozbudowana, ponieważ wydłużyłoby to czas uczenia, komplikowało sam proces uczenia oraz nie pozwalało na precyzyjne określenie błędu uczenia. Algorytm dopuszcza różne formy funkcji przejścia f , ale najczęściej funkcja przejścia jest przybliżeniem N -tego stopnia wielomianu Kołmogorowa-Gabóra definiowanego jako [6]

$$y = a_0 + \sum_{i=1}^N a_i x_i + \sum_{i=1}^N \sum_{j=1}^N a_{ij} x_i x_j + \dots \quad (2)$$

gdzie a_0, a_i, a_{ij} są parametrami wielomianu. Przy założeniu, że stopień wielomianu $N=2$, postać funkcji przejścia zapiszemy jako:

$$y = a_0 + a_1 x_1 + a_2 x_2 + a_{11} x_1^2 + a_{22} x_2^2 + a_{12} x_1 x_2. \quad (3)$$

Synteza sieci GMDH polega na iteracyjnym estymowaniu parametrów poszczególnych modeli cząstkowych oraz łączeniu ich za pomocą odpowiednio dobranych metod selekcji (rys. 2). W pierwszej iteracji budowana jest warstwa wejściowa neuronów, które są opisane za pomocą funkcji aktywacji (1) z uwzględnieniem wszystkich kombinacji sygnałów wejściowych x_i .




Rys. 2. Synteza sieci neuronowej typu GMDH (opr. własne wg Korbicz, 2009)

Fig. 2. The synthesis of a GMDH type network (prepared by the author, based on Korbicz, 2009)

Neurony w warstwie wejściowej (rys. 3) są opisane przez funkcje aktywacji zawierające nieznanne parametry wielomianu Iwachnienki, optymalizowane dla każdego neuronu za pomocą metody najmniejszych kwadratów lub innej reguły uczenia [4].

Kolejnym krokiem jest włączenie nowoutworzonej warstwy do sieci. Jest to poprzedzone procesem selekcji neuronów, który ma za zadanie wyeliminować te elementy, dla których na podstawie przyjętego kryterium stwierdzono zbyt duży błąd przetwarzania $E(y)$. Możemy wyróżnić następujące metody przeprowadzenia selekcji [4]:

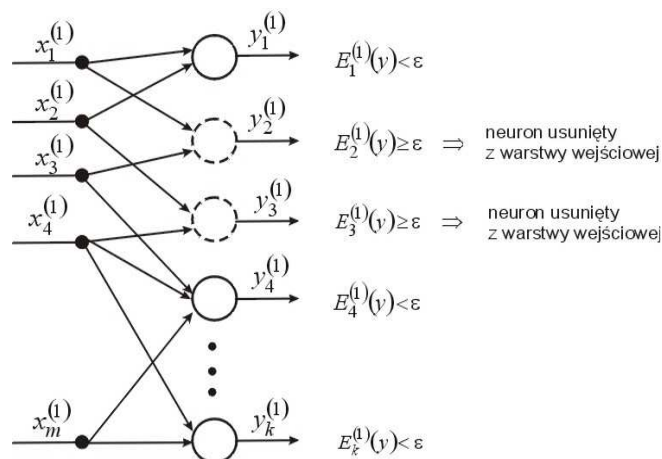
- metoda stałych populacji,
- metoda optymalnych populacji,
- metoda malejących populacji.



Rys. 3. Warstwa wejściowa sieci GMDH (opr. własne wg Duch i inni, 2000)

Fig. 3. The input layer of a GMDH (prepared by the author, based on Duch et al., 2000)

W prezentowanej pracy wykorzystano wszystkie wymienione wyżej procedury selekcji, przy czym najkorzystniejsze wyniki uzyskano z zastosowaniem metody optymalnych populacji, która polega na odrzuceniu tych neuronów, dla których błąd przetwarzania $E(y)$ osiągnął wartości większe od arbitralnie ustalonego progu ε . Ilustracja procesu selekcji neuronów dla metody optymalnych populacji została przedstawiona na rysunku 4.



Rys. 4. Selekcja neuronów w warstwie wejściowej (opr. własne wg. Duch i inni, 2000)

Fig. 4. The selection of neurons in the input layer (prepared by the author, based on Duch et al., 2000)

W drugiej iteracji jako dane wejściowe wykorzystywane są sygnały wyjściowe z warstwy poprzedniej. W taki sam sposób tworzona jest architektura sieci w dalszych warstwach aż zostanie spełnione kryterium optymalności Q_{opt} [7]. Z pośród wielu definicji funkcji kryterium optymalności, w pracy zastosowano kryterium zbieżności definiowane jako [4].

$$Q_{opt} = \frac{\sum_{i=1}^n \left(\bar{y}_i - y_i \right)^2}{\sum_{i=1}^n y_i^2} \quad (4)$$

gdzie: n – liczebność zbioru danych, y – znana wartość sygnału wyjściowego, \bar{y} – estymowana wartość sygnału wyjściowego. Kryterium optymalności Q_{opt} pozwala na wyznaczenie błędu przetwarzania pojedynczego neuronu, co stanowi podstawę

do podjęcia decyzji o jego włączeniu do kolejnej warstwy lub odrzuceniu. Cały proces syntezy sieci GMDH jest kontrolowany poprzez odwołanie się do danych zewnętrznych nie biorących udziału w procesie uczenia, czyli do danych zawartych w zbiorze testowym. Jeżeli liczba danych jest dostatecznie duża można wydzielić również zbiór kontrolny mający za zadanie uzyskanie lepszego rozwiązania końcowego.

3. Analiza uzyskanych wyników – przykład liczbowy

Wysmukłe budowle wieżowe charakteryzują się dużą dysproporcją wymiarów, ich wysokość jest dużo większa od wymiarów przekrojów w poprzecznych. Stalowe kominy przemysłowe są lekkie, tanie i łatwe w budowie, lecz ze względu na swoją wiotkość muszą być zabezpieczane przez zastosowanie odciągów lub kratowych ustrojów przestrzennych [8]. Położenie geometryczne osi komina stalowego (emitor przemysłowy) o wysokości 80m wyznaczono metodą otaczających stycznych. Kierunki styczne do ustalonych 7 przekrojów komina zaobserwowano z punktu osnowy pomiarowej za pomocą tachimetru o dokładności nominalnej pomiaru kierunku $m_k = 20^{cc}$. Pomiar wykonano w dwóch położeniach lunety w nawiązaniu do kierunków boków osnowy.


Realizacja numeryczna zadania polegała na wyznaczeniu wartości niewiadomych:

– współrzędnych środków przekrojów (x_s, y_s) ,

– długości promienia r w obserwowanych przekrojach,

z uwzględnieniem charakterystyki dokładności tych parametrów. Wartości niewiadomych wyznaczono metodą najmniejszych kwadratów na podstawie zestawu równań aproksymacyjnych dla każdego obserwowanego przekroju [9], przy założeniu, że błędy obserwacji podlegają rozkładowi normalnemu. Przy takim założeniu i zastosowanej metodzie wyznaczania parametrów, rozkład składowych odchylenia dx, dy podlega rozkładowi normalnemu względem ich wartości oczekiwanych. Odchylenie osi geometrycznej komina p jest określone z błędem wynikającym z obarczonych błędami składowych odchylenia m_x i m_y .


Analizie podano wyniki pomiarów odchylenia od pionu osi geometrycznej komina przeprowadzone w latach 2007-2011. Stosując algorytm GMDH zbudowano optymalną architekturę sieci co pozwoliło na uzyskanie wyników w postaci składowych odchylenia dx, dy . Tak jak zostało wspomniane wcześniej, proces budowy struktury sieci prowadzony jest do momentu aż błąd przetwarzania $E(y)$ zaczyna się zwiększać (rys. 5), wówczas uznajemy, że uzyskana architektura sieci jest optymalna. Na rysunku 6 przedstawiono wyniki działania algorytmu grupowej obróbki danych z wykorzystaniem jako metody selekcji metody optymalnych populacji, charakteryzującej się najmniejszym błędem przetwarzania $E(y)=6,9$ mm. Na rysunkach 7a oraz 7b przedstawiono wyniki działania algoryt-



Rys. 5. Uzyskane wychylenia na podstawie algorytmu GMDH (met. optymalnych populacji)

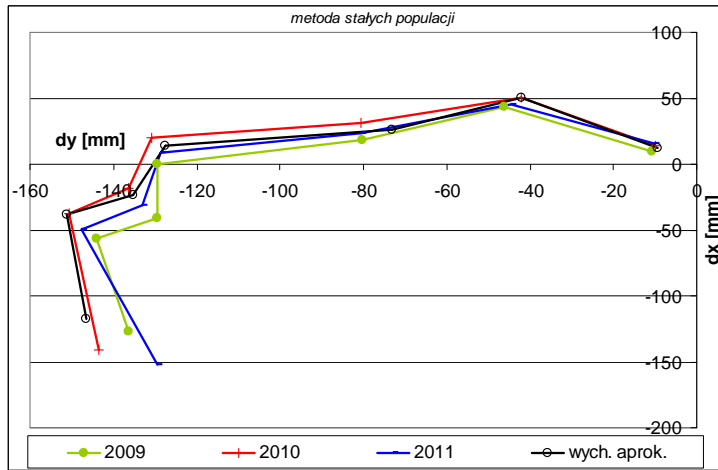
Fig. 5. The deviations obtained from the GMDH algorithm (the method of optimum populations)

mu z wykorzystaniem w procesie selekcji metody stałych populacji (błąd przetwarzania $E(y)=9,8$ mm) oraz metody malejących populacji (błąd przetwarzania $E(y)=10,2$ mm). Na rysunkach 7 i 8 dla ich czytelności zostały przedstawione wychylenia z lat 2009-2011.



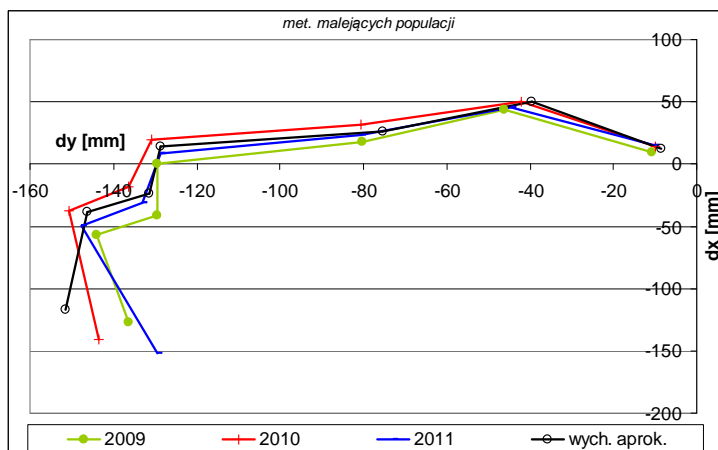
Rys. 6. Uzyskane wychylenia na podstawie algorytmu GMDH (met. optymalnych populacji)

Fig. 6. The results of the operation of the GMDH algorithm (the method of optimum populations)



Rys. 7. Metoda stałych populacji

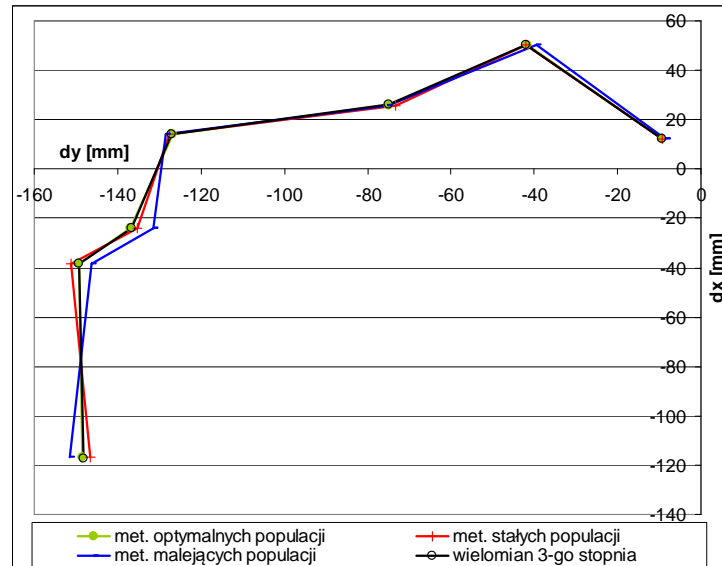
Fig. 7. The method of permanent populations



Rys. 8. Metoda malejących populacji

Fig. 8. The method of decreasing populations

Wyniki aproksymacji z zastosowanie metody grupowej obróbki danych zostały porównane z wynikami uzyskanymi na podstawie aproksymacji wielomianem trzeciego stopnia. Najbliższe wynikom uzyskanym z wykorzystaniem wielomianu trzeciego stopnia są wyniki uzyskane z zastosowaniem jako metody selekcji metody optymalnych populacji (rys. 9).



Rys. 9. Wyniki działania algorytmu z zastosowaniem wybranych metod przeprowadzania selekcji

Fig. 9. The results of the operation of the algorithm with the use of particular selection methods

4. Wnioski

Przedstawiony w artykule algorytm grupowej obróbki danych pozwala na rozwiązywanie problemów, które stanowią ograniczenia dla klasycznych sieci neuronowych. W prezentowanym rozwiązaniu nie ma arbitralnie zakładanej architektury sieci, a sieć GMDH budowana jest w trakcie procesu uczenia co pozwala na poprawę efektywności jej działania. Jednocześnie zastosowanie metod optymalizacji do wyznaczenia parametrów funkcji przejścia prowadzi do parametryczno-strukturalnej optymalizacji sieci neuronowej.

Zaprezentowane rozwiązanie jest efektywne nawet przy niewielkich i ograniczonych zbiorach danych jakimi są wyniki pomiarów geodezyjnych. Zastosowanie algorytmu GMDH do wyznaczenia składowych odchyłeń od pionu komina przemysłowego, pozwoliło na uzyskanie zadawalających rezultatów zbliżonych do wyników uzyskanych z wykorzystaniem klasycznych metod obliczeniowych.

Literatura

- [1] Bishop Ch.M.: Pattern Recognition and Machine Learning. Springer, New York 2006.
- [2] Osowski S.: Sieci neuronowe do przetwarzania informacji. Oficyna wydawnicza Politechniki Warszawskiej, Warszawa 2000.

- [3] Iwachnienko A.G.: Induktivnyj metod samoorganizacji modelej słożonych system. Naukowa Dumka. Kijów 1982.
- [4] Duch W., Korbicz J., Rutkowski L., Tadeusiewicz R.: Sieci neuronowe. Biocybernetyka i inżynieria biomedyczna, tom 6. Akademicka Oficyna Wydawnicza EXIT. Warszawa 2000.
- [5] Korbicz J.: Sztuczne sieci neuronowe i ich zastosowanie w elektrotechnice i energetyce. Przegląd Elektroniczny R. 85, Nr 9. Warszawa 2009.
- [6] Iwachnienko A.G.: Polynomial theory of complex systems. IEEE Trans. Systems, Man and Cybernetics, Vol.SMC-1, No.4 1971.
- [7] Luzar M.: Przybornik modelowania neuronowego GMDH. Conference Archives PTE-TiS Vol. 28 2010.
- [8] Gocał J.: Geodezja inżynierska – przemysłowa, tom III. Wydawnictwo Akademii Górniczo – Hutniczej. Kraków 2010.
- [9] Czaja J.: Geodezja inżynierska – przemysłowa. Skrypt Uczelniany nr 893 Akademii Górniczo – Hutniczej w Krakowie. Kraków 1983.

THE DEFORMATIONS OF CONSTRUCTION STEEL CHIMNEY IN TERMS OF THE USE OF THE GROUP OF DATA HANDLING

Summary

The field of processing information provided by measurement results is one of the most important components of geodesic technologies. The dynamic development of this field improves classic algorithms for numerical calculations in the aspect of analytical solutions that are difficult to achieve. Algorithms based on artificial intelligence in the form of artificial neural networks, including the topology of connections between neurons have become an important instrument connected to the problem of processing and modelling processes. Artificial neural networks are based on research conducted in the field of artificial intelligence. Of particular importance were the work relating to the operation of the nervous system of living beings and the construction of models of structures that occur in the brain. Artificial neural networks due to their nonlinear character represents a sophisticated modeling technique and are included in the methods of computational intelligence. The functions of the network allow you to get positive results in the area of practical issues such as approximation, interpolation, pattern recognition and classification, compression, prediction, and many others.

This concept results from the integration of neural networks and parameter optimization methods and makes it possible to avoid the necessity to arbitrarily define the structure of a network. This kind of extension of the teaching process is exemplified by the algorithm called the Group Method of Data Handling –GMDH), which belongs to the class of evolutionary algorithms. The article presents a GMDH type network, used for modelling deformations of the geometrical axis of a steel chimney during its operation. The chimney is covered by the control measurements carried out during the operation at intervals of one year.

Keywords: artificial intelligent, group data handling, deviations from the vertical

Przesłano do redakcji: 30.08.2016 r.

Przyjęto do druku: 15.09.2016 r.

DOI: 10.7862/rb.2016.145