

WYBRANE PRZYKŁADY ZASTOSOWAŃ SZTUCZNYCH SIECI NEURONOWYCH W GEOTECHNICE

Maciej OCHMAŃSKI*, Joanna BZÓWKA

Politechnika Śląska, ul. Akademicka 5, 44-100 Gliwice

Streszczenie: Sztuczne sieci neuronowe (SSN) umożliwiają rozwiązywanie problemów bardzo trudnych lub wręcz niemożliwych wcześniej do rozwiązania. W referacie zostaną przedstawione przykłady zastosowania sztucznych sieci neuronowych do rozwiązań wybranych problemów geotechnicznych. Pierwszy przykład dotyczy wykorzystania sztucznych sieci neuronowych do analizy przemieszczeń dwóch bliźniaczych tuneli wykonanych w technologii SCL (*Sprayed Concrete Lining*). Konstrukcja poddana analizie jest częścią stacji Fővám, czwartej linii metra w Budapeszcie. Analizę przeprowadzono bazując na danych uzyskanych podczas budowy linii metra oraz monitoringu geotechnicznego. W celu analizy opracowano model numeryczny, który posłużył do przeprowadzenia w pierwszej kolejności analizy wrażliwości użytych parametrów modelu konstytutywnego oraz do analizy wstecznej tych parametrów. W przypadku obu analiz posłużono się sztucznymi sieciami neuronowymi, które pokazały łatwość ich zastosowania oraz wiarygodność uzyskanych wyników. W drugim przykładzie przedstawiono sposób przewidywania średnicy kolumn iniekcyjnych. Określenie kształtu kolumn iniekcyjnych, w tym głównie ich średnicy, jest bardzo trudne. Możliwość zastosowania sztucznych sieci neuronowych do określenia średnicy kolumn może w znaczący sposób zoptymalizować metody projektowania kolumn iniekcyjnych. W przykładzie posłużono się obszerną bazą danych zawierającą opis warunków gruntowo-wodnych podłoża, w którym wykonano kolumny iniekcyjne i pomierzone wartości średnic kolumn po ich odsłonięciu. Dane związane z kolumnami iniekcyjnymi zostały wykorzystane do utworzenia sztucznej sieci neuronowej, a następnie do określenia przewidywanych średnic kolumn iniekcyjnych. Uzyskane wyniki charakteryzują się bardzo dobrą zbieżnością z rzeczywistymi wymiarami kolumn. Wykorzystanie sztucznych sieci neuronowych stanowi alternatywę wobec tradycyjnych metod rozwiązywania problemów geotechnicznych.

Słowa kluczowe: sztuczne sieci neuronowe SSN, kalibracja modelu numerycznego, analiza wsteczna, tunel SCL, kolumny iniekcyjne.

1. Wprowadzenie

Celem pracy jest przedstawienie zastosowania Sztucznych Sieci Neuronowych (SSN) do analizy wstecznej tuneli SCL oraz przewidywania średnicy kolumn iniekcyjnych, jako skutecznego narzędzia do analizy zagadnień z dziedziny geotechniki.

Modelowanie numeryczne staje się nieodłączną częścią projektowania geotechnicznego. Niejednokrotnie utworzone modele numeryczne współpracy ośrodka gruntowego z projektowaną konstrukcją generują przeszacowane/niedoszacowane wyniki, co może prowadzić do nieprawidłowego projektowania konstrukcji, a co za tym idzie, do awarii konstrukcji podczas budowy czy jej użytkowania. Racjonalne zatem staje się przeprowadzenie analizy wstecznej opracowanego modelu numerycznego konstrukcji wraz z otaczającym ośrodkiem gruntowym, co jest szczególnie uzasadnione w przypadku, gdy mamy do czynienia

z konstrukcją o wysokiej odpowiedzialności, na przykład stacją metra czy tunelem. Prawdopodobnie określone parametry gruntowe stanowią solidną podstawę i są głównym czynnikiem, który zapewnia poprawność przeprowadzonych prac projektowych z zakresu geotechniki.

Kolumny iniekcyjne są obecnie szeroko wykorzystywane do wzmocnienia słabego podłoża gruntowego. Specyfika techniki iniekcji strumieniowej powoduje, iż dotychczas jeszcze nie opracowano żadnej metody projektowej, która pozwoliłaby na określenie średnicy powstałej kolumny iniekcyjnej. Firmy wykonawcze bazując na własnym doświadczeniu, w odniesieniu do istniejących warunków gruntowo-wodnych są w stanie oszacować w przybliżeniu średnicę kolumny iniekcyjnej. Celowe jest opracowanie metody, która pozwoli na dokładne określenie średnicy kolumny iniekcyjnej na podstawie parametrów formowania kolumny oraz danych gruntowo-wodnych, co w znacznym

* Autor odpowiedzialny za korespondencję. E-mail: maciej.ochmanski@polsl.pl


stopniu poprawiłoby efektywność metody wzmacniania podłoża gruntowego za pomocą kolumn iniekcyjnych.

Sztuczne Sieci Neuronowe (SSN) zdobywają coraz większą popularność w zagadnieniach typowo geotechnicznych, między innymi dzięki łatwości ich stosowania oraz dobrej jakości otrzymywanych wyników. Jednak należy pamiętać o pewnych ograniczeniach, które sprawiają, że SSN nie mogą być zastosowane do opisywania każdego napotkanego zjawiska ze względu na nie dość precyzyjne wyniki oraz na brak „rozumowania” wieloetapowego (Bartman, 2012).

2. Sztuczne sieci neuronowe

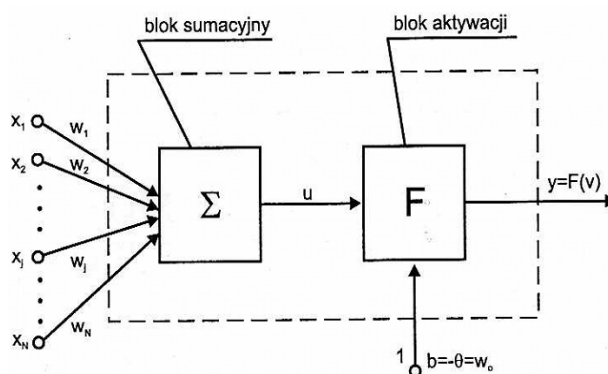
Sztuczne Sieci Neuronowe (SSN) są uproszczonym matematycznym opisem naturalnego układu nerwowego organizmów żywych. Stanowią one alternatywę dla tradycyjnych statystycznych metod analizy danych. SSN zostały z powodzeniem zastosowane między innymi do prognoz giełdowych, badań psychiatrycznych, prognozy cen, analiz spektralnych, czy chociażby w geotechnice do określania parametrów zagęszczenia gruntów niespoistych (Sulewska, 2009).

Podstawowym elementem SSN są sztuczne neurony, które odpowiadają za interpretację, modyfikację oraz dalszą propagację sygnału wejściowego. Uproszczony schemat pojedynczego neuronu pokazano na rysunku 1.



Rys. 1. Schemat neuronu (www.wpclipart.com)

Każda sieć neuronowa może składać się z wielu neuronów pogrupowanych w różną liczbę warstw. W modelach informatycznych ich liczba zależna jest od rodzaju użytej sieci neuronowej, liczby danych wejściowych oraz poziomu skomplikowania procesu podlegającego opisowi. Matematyczny model sztucznego neuronu przedstawiono na rysunku 2. Zasada działania sztucznego neuronu polega na przekazie sygnału wejściowego przez więzy o odpowiednich wagach, blok sumacyjny oraz blok aktywacji, co w efekcie prowadzi do jego modyfikacji w sygnał wyjściowy.



Rys. 2. Model sztucznego neuronu (Waszczyszyn, 1999)

Każdy sygnał wejściowy przedstawiony jako x_i jest przemnażany przez wagę w_i połączenia między sygnałem wejściowym a blokiem sumacyjnym. Wszystkie sygnały wejściowe przemnożone przez odpowiadające im wagi są sumowane w bloku sumacyjnym. Następnie sygnał jest przekształcany przez funkcję aktywacyjną w tak zwany blok aktywacji w finalny sygnał wyjściowy. Funkcje aktywacyjne mogą przybierać postać różnych funkcji matematycznych, od najprostszej funkcji liniowej aż po na przykład sigmoidalną bipolarną (Waszczyszyn, 1999). Działanie sztucznego neuronu może być opisane (Bartman, 2012) za pomocą wzoru:

$$y = F\left(\sum_{i=1}^n w_i x_i\right) \quad (1)$$

gdzie: F jest funkcją aktywacji, x_i jest sygnałem wejściowym, w_i jest wagą sygnału wejściowego, i jest liczbą zmiennych wejściowych, $i = 1, \dots, n$, a y jest sygnałem wyjściowym.

SSN podlegają procesowi uczenia, który dopasowuje wagi wejść poszczególnych połączeń oraz parametry zadeklarowanych funkcji aktywacji każdego neuronu. Istnieje wiele algorytmów uczenia. Poniżej przedstawiono przykładowe metody (Haykin, 1999):

- wstecznej propagacji błędów (*back propagation*),
- zmiennej metryki,
- Levenberga-Marquardta,
- gradientów sprzężonych (*conjugate gradient*).

Podczas procesu uczenia sztucznej sieci neuronowej, istnieje możliwość tak zwanego „przeuczenia” sieci. Aby zapobiec „przeuczeniu” należy zastosować odpowiedni algorytm (Bishop, 1995), na przykład wczesnego zatrzymania (*early stopping*). Z procesem uczenia związane jest próbkowanie zbioru danych, czyli pobieranie losowe próbek. Poniżej przedstawiono niektóre z metod próbkowania danych (Haykin, 1999):

- losowe próbkowanie (metoda Monte Carlo),
- sprawdzian krzyżowy,
- metoda bootstrap.

W sieciach neuronowych zasadnicze staje się określenie generowanego przez nie błędu. Istnieje wiele różnych metod do jego określania. Poniżej przedstawiono niektóre z miar błędów sieci neuronowych (Tadeusiewicz i Lula, 2003):

- błąd średniokwadratowy MSE (*Mean Squared Error*),

- średni błąd bezwzględny MAE (*Mean Absolute Error*),
- pierwiastek z uśrednionego błędów kwadratowego RMS (*Root Mean Squared error*),
- iloraz odchyłeń RSD (*Ratio of Standard Deviations*).

Należy również spojrzeć krytycznie na SSN, ponieważ nie nadają się one do rozwiązywania wszystkich problemów, między innymi, ze względu na to, że są mało precyzyjne, co wynika z tego, że operują one pojęciami rozmytymi oraz nie charakteryzują się „rozumowaniem” wieloetapowym (Bartman, 2012).

3. Analiza wsteczna tuneli SCL

W celu sprecyzowania parametrów geotechnicznych modelu konstytutywnego użytego do opisu właściwości ośrodka gruntowego przeprowadzono analizę wrażliwości, po czym wykonano analizę wsteczną.

Model numeryczny MES tuneli SCL wraz z otaczającym ośrodkiem gruntowym będących częścią stacji Fővám, 4 linii metra w Budapeszcie, przygotowano za pomocą programu Midas GTS. Trójwymiarowy model wykonano przy wykorzystaniu czterowęzłowych, czworosiennych elementów 1-go rzędu (dla elementów 3D). Natomiast do utworzenia modelu samej obudowy tuneli posłużono się płaskimi elementami trójwzłowymi 1-go rzędu. Zdyskretyzowana siatka MES składa się z około 100 000 elementów skończonych. Geometria wraz z etapami budowy analizowanego obiektu została wiernie odtworzona, co wraz z możliwie najdokładniej zamodelowanymi warunkami gruntowo-wodnymi (na przykład liczne uskoki), zapewniło odpowiednią charakterystykę przemieszczeń, jak i naprężeń ośrodka gruntowego. Siatkę MES wygenerowaną dla całego modelu numerycznego (tunele SCL wraz z otaczającym ośrodkiem gruntowym) przedstawiono na rysunku 3a, a dla obudowy tuneli SCL na rysunku 3b.

Do opisanego zachowania się podłoża gruntowego użyto modelu konstytutywnego Coulomba-Mohra, z parametrami (E, c, ϕ) uzyskanymi z licznych badań (Geovil Ltd., 2005), między innymi takich jak badania samowiercącym presjometrem. W modelu numerycznym uwzględniono zmianę parametrów gruntowych (E, c) wraz z głębokością. Do opisanego zachowania się obudowy tuneli posłużono się najprostszym modelem konstytutywnym – liniowo-sprężystym, jednocześnie stosując metodę hipotetycznego modułu Younga (HME). Metoda ta uwzględnia zmianę wartości modułu Younga E torkretu wraz z czasem. Jest to obecnie najpopularniejsza metoda uwzględniająca zmianę parametrów torkretu. Parametry torkretu przyjęto jak dla SpC25/30/III/J2/XC4/XA1/GK8 (ÖVBB, 2004).

Dodatkowo uwzględniono proces zamrażania gruntu nad budowanymi tunelami, jak i stosowaną iniekcję

w celu zapewnienia np. stabilności czoła tunelu, poprzez lokalną zmianę parametrów materiałowych elementów skończonych.

Wyżej przedstawiony model numeryczny MES posłużył do przeprowadzenia analizy wrażliwości oraz analizy wstecznej parametrów modelu konstytutywnego Coulomba-Mohra. Analizę wrażliwości przeprowadzono w celu określenia wpływu poszczególnych parametrów (E, c, ϕ) użytego modelu konstytutywnego opisującego ośrodek gruntowy na przemieszczenia obudowy tunelu (D_x, D_z). Natomiast analizę wsteczną przeprowadzono w celu sprecyzowania w/w parametrów tak, aby wartości przemieszczeń obudowy tuneli otrzymane z analizy numerycznej były możliwie bliskie wartościom przemieszczeń rzeczywistych, uzyskanych w wyniku monitoringu inklinometrycznego.

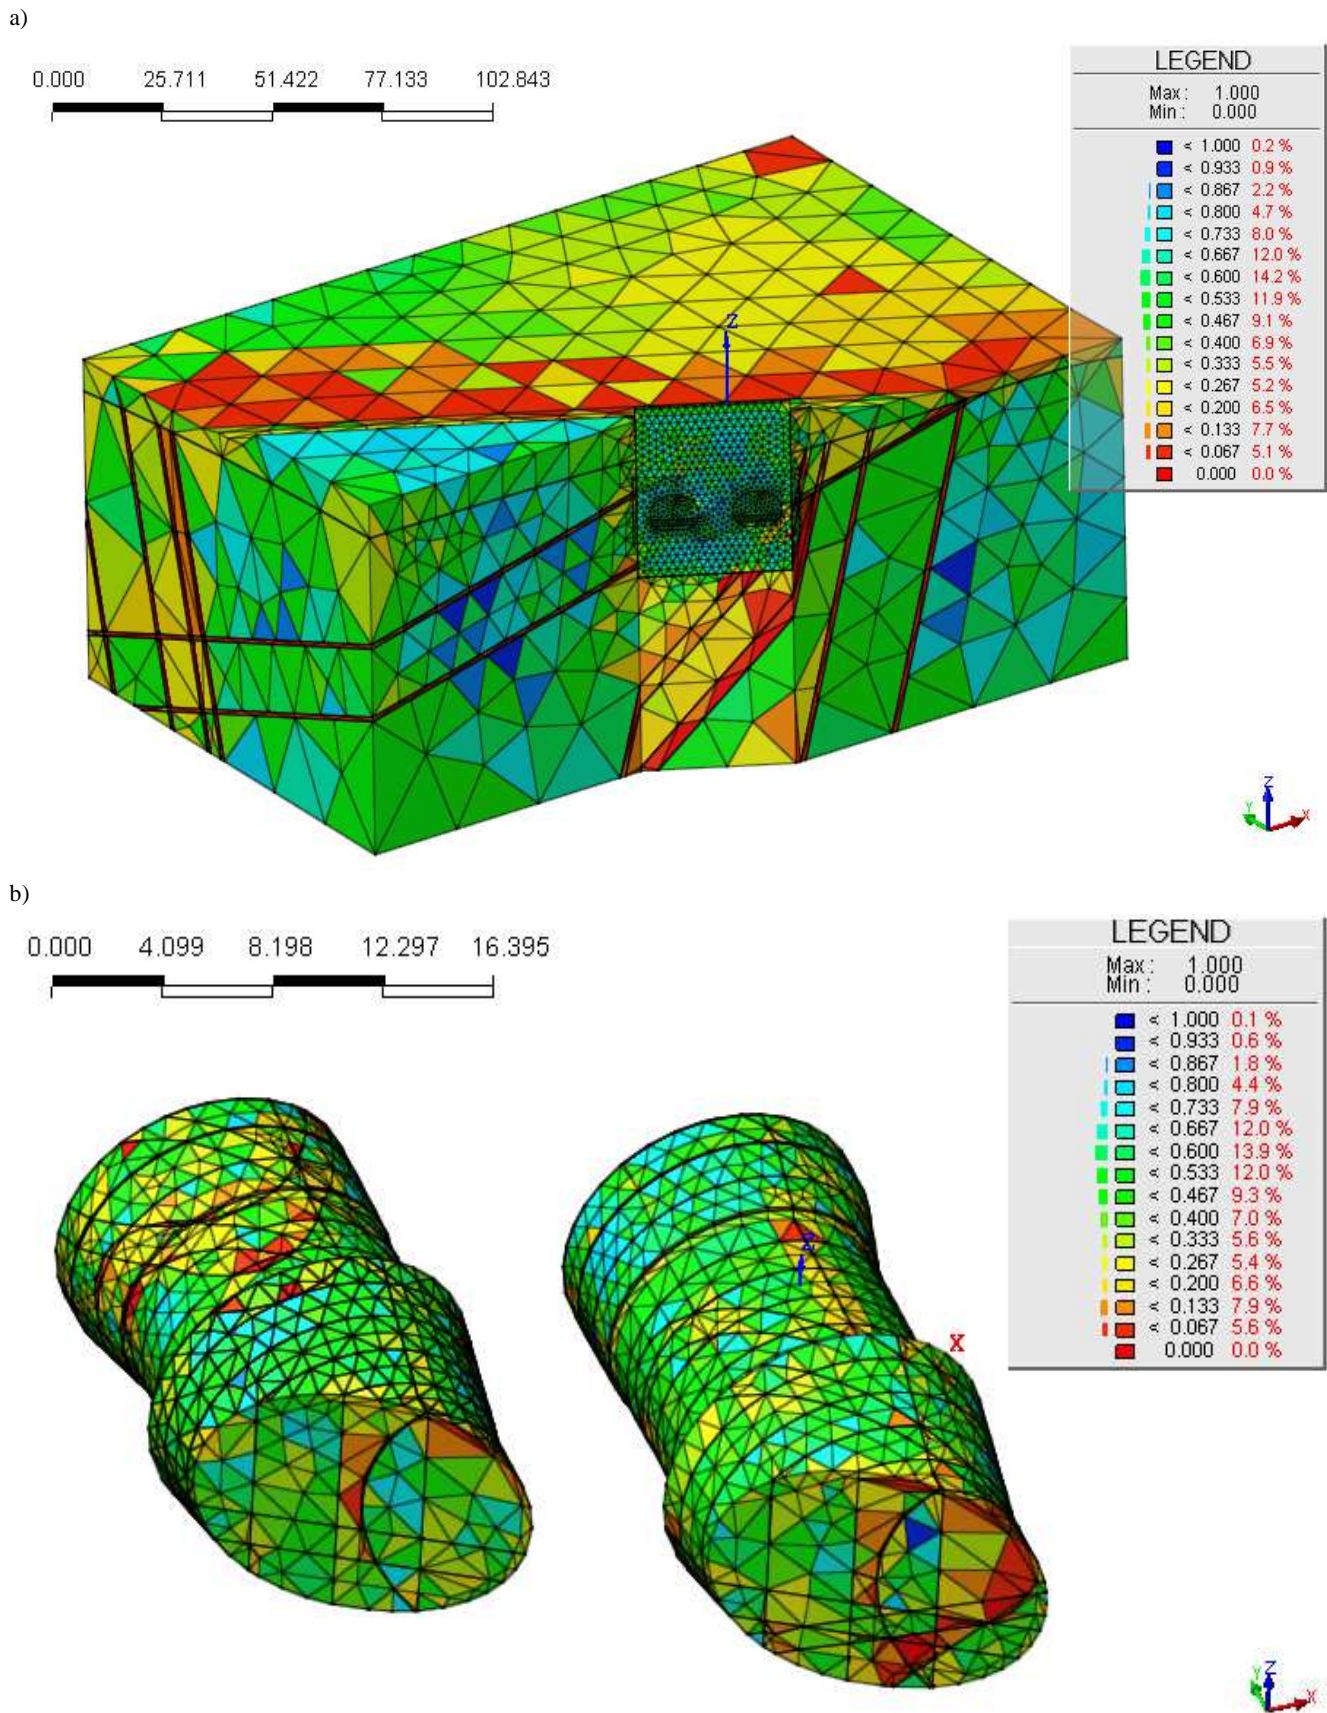
W analizie wrażliwości, za dane wejściowe posłużyły współrzędne węzłów elementów skończonych obudowy tuneli (x, y, z) oraz ich przemieszczenia (D_x, D_z). Natomiast, jako dane wyjściowe sieci neuronowej posłużyły parametry modelu konstytutywnego Coulomba-Mohra (E, c, ϕ), które zmieniają się wraz z głębokością. Dane wejściowe (przypadki) zostały odpowiednio podzielone na dane służące do oceny sieci – 60%, do walidacji – 15%, zaś pozostałe dane – 25% – posłużyły do testowania sieci. Do utworzenia sieci neuronowej opracowano skrypt w programie MATLAB. Poniżej przedstawiono architekturę utworzonej sieci neuronowej:

- liczba danych wejściowych (przypadków) – 5022;
- liczba parametrów opisujących węzeł siatki MES (x, y, z, D_x, D_z) – 5;
- zmienne wyjściowe (E, c, ϕ) – 3;
- model sieci 5-15-3, co oznacza sztuczną sieć neuronową jednokierunkową o 5 wejściach, jednej warstwie ukrytej o 15 neuronach i warstwie wyjściowej o 3 neuronach.

Utworzona sieć neuronowa posłużyła do oceny wrażliwości parametrów modelu Coulomba-Mohra (E, c, ϕ) na zmiany współrzędnych węzłów siatki elementów skończonych na podstawie wzoru (2) (Lippmann, 1987):


$$css_j = \left[\frac{1}{ND} \sum_{i=1}^{ND} \left(\left(\frac{\delta y'_i}{\delta b_j} \right) b_j \omega_{ii}^2 \right)^2 \right]^{\frac{1}{2}} \quad (2)$$

gdzie: css_j jest przeskalowaną złożoną wrażliwością parametru j , b_j jest parametrem j podlegającym analizie, y_i jest i -tą obliczoną wartością, $i = 1, \dots, 5022$, $\delta y'_i / \delta b_j$ jest wrażliwością i -tej obliczonej wartości w odniesieniu do parametru j , j jest liczbą parametrów (E, c, ϕ), $j = 1, 2, 3$, a ω_{ii} jest wagą i -tej obserwacji.




Rys. 3. Wygenerowane siatki (Ochmański, 2012; Ochmański i Bzówka, 2012a): a) dla całego modelu; b) dla tuneli SCL

W wyniku analizy otrzymano wrażliwości poszczególnych parametrów modelu konstytutywnego opisującego ośrodek gruntowy na przemieszczenia obudowy tunelu, które przedstawiono na rysunku 4 dla tunelu północnego oraz na rysunku 5 dla tunelu południowego.



Rys. 4. Wrażliwość parametrów gruntowych (E , c , ϕ) modelu Mohra-Coulomba na uzyskiwane przemieszczenia ośrodka gruntowego dla tunelu północnego (Ochmański, 2012; Ochmański i Bzówka, 2012b)



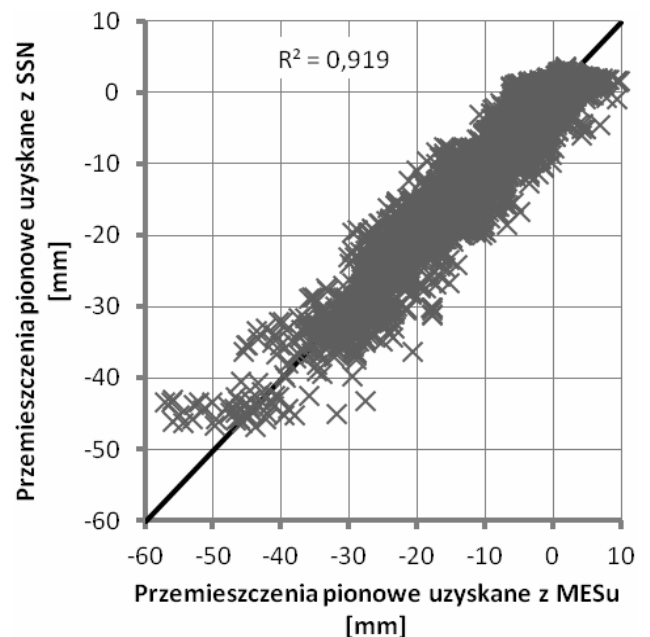
Rys. 5. Wrażliwość parametrów gruntowych (E , c , ϕ) modelu Coulomba-Mohra na uzyskiwane przemieszczenia ośrodka gruntowego dla tunelu południowego (Ochmański, 2012; Ochmański i Bzówka, 2012b)

Kolejnym krokiem było przeprowadzenie analizy wstecznej. Jako dane wejściowe SSN posłużyły współrzędne (x , y , z) oraz odpowiadające parametry gruntowe (E , c , ϕ) węzłów siatki elementów skończonych obudowy tuneli, a jako dane wyjściowe sieci neuronowej przemieszczenia pionowe (D_z) tychże węzłów uzyskane z MES. Dane wejściowe podzielono w sposób analogiczny jak przy analizie wrażliwości, czyli 60% danych do uczenia sieci, 15% do walidacji, zaś pozostałe 25% do testowania sieci. Poniżej przedstawiono architekturę utworzonej sieci neuronowej:

- liczba przypadków uczących – 5022;

- liczba parametrów opisujących węzeł siatki MES, przyjęto $\phi = \text{const} - (x, y, z, E, c) - 5$;
- zmienna wyjściowa – pionowe przemieszczenia węzłów siatki (D_z) – 1;
- model sieci 5-15-1, co oznacza sztuczną sieć neuronową jednokierunkową o 5 wejściach, jednej warstwie ukrytej o 15 neuronach i warstwie wyjściowej o 1 neuronie;
- metoda próbkowania – Monte Carlo, co oznacza SSN z losowo wybranymi danymi do walidacji, uczenia i testowania przy założeniu stałej wielkości zbiorów.


Korelacje wartości przemieszczeń pionowych otrzymanych z MES z wartościami przemieszczeń pionowych otrzymanych za pomocą sztucznej sieci neuronowej na potrzeby analizy wstecznej przedstawiono na rysunku 6.



Rys. 6. Porównanie wartości przemieszczeń pionowych (D_z) otrzymanych z MES z wartościami przemieszczeń uzyskanymi za pomocą SSN dla przypadków testowych (Ochmański, 2012; Ochmański i Bzówka, 2012b): metoda próbkowania – Monte Carlo, R^2 – współczynnik determinacji

Na podstawie przygotowanej SSN wygenerowano parametry modelu konstytutywnego Coulomba-Mohra wykorzystując dane rzeczywistych przemieszczeń uzyskane z monitoringu inklinometrycznego. Proces generowania parametrów był kilkakrotnie powtarzany tak, aby zminimalizować błąd średniokwadratowy (MSE) pomiędzy modelem numerycznym a danymi z monitoringu geotechnicznego.

Przemieszczenia pionowe obliczone za pomocą modelu numerycznego MES przy wykorzystaniu nowo wygenerowanych parametrów przedstawiono na rysunku 7. Porównano tu przemieszczenia uzyskane z monitoringu inklinometrycznego do przemieszczeń z modelu numerycznego MES, przed i po analizie wstecznej. W wyniku analizy wstecznej uzyskane przemieszczenia pionowe modelu numerycznego charakteryzują się wysoką zbieżnością



Rys. 7. Porównanie wartości przemieszczeń pionowych uzyskanych z monitoringu inklinometrycznego z wartościami przemieszczeń pionowych uzyskanymi w wyniku analizy MES (Ochmański, 2012; Ochmański i Bzówka, 2012b): przed kalibracją – MES-1 i po kalibracji – MES-2

z przemieszczeniami uzyskanymi z monitoringu geotechnicznego, co uzasadnia wybór SSN jako narzędzie do kalibracji modelu numerycznego.

4. Przewidywanie średnicy kolumn iniekcyjnych

Jedną z metod wzmocnienia słabego podłoża gruntowego jest zastosowanie kolumn iniekcyjnych. Technika iniekcji strumieniowej na przestrzeni lat potwierdziła, iż może być z powodzeniem stosowana prawie w wszystkich warunkach gruntowo-wodnych, zmieniając strukturę gruntów, co w efekcie prowadzi do zapewnienia nośności oraz zwiększenia bezpieczeństwa projektowanego / modernizowanego / remontowanego obiektu inżynierskiego.

Iniekcja strumieniowa (*jet grouting*) polega na mieszaniu cząstek gruntowych z iniektem (zazwyczaj jest nim zaczyn cementowy) tłoczonym pod wysokim ciśnieniem około 40 MPa.

W wyniku iniekcji strumieniowej powstaje kompozyt gruntowo-cementowy, zwany kolumną iniekcyjną. Można wyróżnić trzy systemy tworzenia kolumn iniekcyjnych:

- jednostrumieniowy (strumień iniektu),
- dwustrumieniowy (strumień iniektu oraz otaczający go strumień powietrza),
- trójstrumieniowy (strumień iniektu, strumień wody wraz z otaczającym go strumieniem powietrza).

Przykład odsłoniętej kolumny iniekcyjnej wykonanej przy użyciu systemu dwustrumieniowego pokazano na rysunku 8.



Rys. 8. Odsłonięte kolumny iniekcyjne –system dwustrumieniowy (Flora i in., 2012)

Podstawowym parametrem technologicznym formowania kolumny iniekcyjnej jest energia kinetyczna w dyszy przypadająca na 1 mb powstałej kolumny. Jest ona wyrażona (Flora i in., 2013) za pomocą wzoru:

$$E'_n = \frac{\pi}{8} \cdot \frac{M \cdot \rho \cdot d_o^2 \cdot v_o^3}{v_s} \quad (3)$$

gdzie: M jest ilością dysz, ρ jest gęstością zaczynu cementowego w kg/m^3 , d_o jest średnicą dyszy iniekcyjnej w m, v_o jest prędkością początkową iniektu w dyszy w m/s, v_s jest prędkością podciągania monitora podczas formowania w m/s.

Aktualnie najbardziej skomplikowanym i trudnym zagadnieniem jest określenie średnicy kolumny iniekcyjnej przed jej formowaniem. Jednym z podejść jest użycie wzorów empirycznych (Flora i in., 2013) bądź zastosowanie zbiorów rozmytych (Bergschneider, 2002). Zagadnienie to jednak ciągle stanowi wyzwanie dla jednostek projektowych ze względu na poziom jego skomplikowania oraz brak jakichkolwiek wytycznych.

Wykorzystując dane z badań terenowych (Flora i in., 2013) utworzono sztuczną sieć neuronową służącą do przewidywania średnicy kolumn iniekcyjnych. Parametry wejściowe obejmowały:


- parametry charakteryzujące ośrodek gruntowy – N_{SPT} , q_c ,
- energia kinetyczna w dyszy przypadająca na 1 mb kolumny iniekcyjnej – E'_n ,
- system formowania kolumny iniekcyjnej – pojedynczy, podwójny lub potrójny – M .

Dane wyjściowe sieci neuronowej stanowiły wymiary średnic kolumn iniekcyjnych pomierzonych po ich odstonięciu.

Do analizy przewidywania średnicy kolumny iniekcyjnej posłużono się dwuwarstwową jednokierunkową (*feed-forward*) sztuczną siecią neuronową. Jako funkcję aktywacji w pierwszej warstwie (ukrytej) użyto funkcję sigmoidalną bipolarną, natomiast w drugiej warstwie (wyjściowej) funkcję liniową. W celu uczenia sieci neuronowej wybrano metodę Levenberga-Marquardta. Dane wejściowe podzielono odpowiednio na dane służące do uczenia sieci – 60%, do walidacji – 15%, zaś pozostałe dane – 25% – do testowania sieci. Poniżej przedstawiono architekturę utworzonej sieci neuronowej:

- liczba przypadków uczących – 106;
- liczba parametrów opisujących każdą kolumnę (zmienne wejściowe), (N_{SPT} , q_c , E'_n , M) – 4;
- model sieci 4-8-1, co oznacza sztuczną sieć neuronową jednokierunkową o 4 wejściach, jednej warstwie ukrytej o 8 neuronach i warstwie wyjściowej o 1 neuronie;
- metoda próbkowania – sprawdzian krzyżowy, co oznacza SSN uczoną tyle razy ile jest przypadków, za każdym razem pozostawiając dokładnie jeden przypadek do testowania;
- metoda próbkowania – Monte Carlo, co oznacza SSN z losowo wybranymi danymi do walidacji, uczenia i testowania przy założeniu stałej wielkości zbiorów.

Cały proces przewidywania średnicy kolumn iniekcyjnych przeprowadzono pięć razy w celu wyeliminowania błędnie dobranych wag połączeń między neuronami. Korelację pomiędzy przewidzianymi za pomocą SSN wymiarami średnic kolumn iniekcyjnych, a ich pomierzonymi w terenie wartościami przedstawiono na rysunku 9. Przewidziane wartości średnic kolumn iniekcyjnych charakteryzują się wysoką zbieżnością ($R^2 = 0,987$) z ich pomierzonymi w terenie wartościami, co uzasadnia wykorzystanie SSN do przewidywania ich średnic.



Rys. 9. Korelacja przewidzianych przez sztuczną sieć neuronową wymiarów średnic kolumn iniekcyjnych (przypadki testowe) z wartościami pomierzonymi w terenie (metoda próbkowania – sprawdzian krzyżowy, R^2 – współczynnik determinacji)

5. Podsumowanie

W przedstawionych w artykule przykładach zastosowań sztucznych sieci neuronowych pokazano, iż ta niekonwencjonalna metoda opisywania zjawisk oraz rozwiązywania problemów może być z powodzeniem stosowana w geotechnice.

Analiza wsteczna modelu numerycznego MES przy wykorzystaniu SSN, szczególnie w przypadku skomplikowanego modelu numerycznego, zawierającego wiele tysięcy elementów skończonych, może być sprawnie przeprowadzona, co w przypadku tradycyjnych metod niejednokrotnie może okazać się wręcz niemożliwe ze względu na wymagane wielokrotne obliczenia. Jednocześnie, w bardzo łatwy sposób można przeprowadzić analizę wrażliwości, która z punktu widzenia projektanta, daje cenne informacje o zachowaniu się ośrodka gruntowego w zależności od doboru parametrów gruntowych czy też innych parametrów, jak na przykład grubości warstwy torkretu czy wpływu iniekcji na przemieszczenia konstrukcji.

Zastosowanie sztucznych sieci neuronowych do przewidywania średnicy kolumn iniekcyjnych stanowi skuteczną, bardzo wydajną oraz łatwą w użyciu metodę.

Wraz z upowszechnieniem się zastosowania SSN w zagadnieniach geotechnicznych SSN mogą alternatywną metodą wymiarowania (przewidywania) średnicy kolumn iniekcyjnych, ze względu na to, iż bazują na rzeczywistych pomiarach średnic tych kolumn

Literatura

- Bartman J. (2012). Sztuczne sieci neuronowe. Prezentacja pobrana z www.neurosoft.edu.pl/jbartman/NTI1.pdf, dnia 20.12.2012.
- Bergschneider B. (2002). Zur Reichweite beim Düsenstrahlverfahren im Sand. *Bodenmechanik und Grundbau*, Bericht – Nr. 24.
- Bishop C. (1995). Neural Networks for pattern recognition. *University Press*, Oxford.
- Flora A., Modoni G., Lirer S., Croce P. (2013). The diameter of single, double and triple fluid jet grouting columns: prediction method and field trial results. *Geotechnique*, (w druku - publikacja udostępniona przez Autorów).
- Geovil Ltd. (2005). Section 1 of Line #4 of the Budapest Metro Summary Expert Opinion on engineering, hydrogeological and geotechnical issues. *Geovil Ltd.*, Szentendre.
- Haykin S. (1999). Neural Networks. A comprehensive foundation. 2nd ed., *Prentice Hall Inc.*, Upper Saddle River.
- Lippmann R. (1987). An introduction to computing with neural nets. *IEEE ASSP Magazine*, Vol. 4, 4-22.
- Ochmański M. (2012). Application of back analysis for Sprayed Concrete Lined tunnels built in complex subsoil conditions. Praca dyplomowa magisterska, *Politechnika Śląska*, Gliwice.
- Ochmański M., Bzówka J. (2012a). Numerical model of SCL tunnels built in complex subsoil conditions. *Architecture, Civil Engineering, Environment – ACEE Journal*, 3/2012, 63-71.
- Ochmański M., Bzówka J. (2012b). Back analysis of SCL tunnels based on Artificial Neural Network. *Architecture, Civil Engineering, Environment – ACEE Journal*, 3/2012, 73-81.
- Sulewska M. (2009). Sztuczne sieci neuronowe w ocenie parametrów zagęszczenia gruntów niespoistych. Studia z Zakresu Inżynierii, nr 64. *Instytut Podstawowych Problemów Techniki PAN*, Warszawa – Białystok.
- Tadeusiewicz R., Lula P. (2003). Sieci neuronowe. Materiały kursowe, *StatSoft Polska*, Kraków.
- Waszczyszyn Z. (1999). Wprowadzenie do sztucznych sieci neuronowych i ich zastosowań w mechanice konstrukcji. W: „Sztuczne sieci neuronowe, algorytmy genetyczne, zbiory rozmyte”, 5-36, red. Gajewski R., *Studio BEL s.c.*, Rzeszów, 5-36.
- ÖVB (2004). Guideline shotcrete. *Österreichische Vereinigung für Beton und Bautechnik (ÖVB)*, Vienna.

SELECTED EXAMPLES OF THE USE OF ARTIFICIAL NEURAL NETWORKS IN GEOTECHNICS

Abstract: Artificial Neural Networks (ANN) allow to solve difficult problems which sometimes are impossible to solve using traditional methods. In the paper the examples of application of Artificial Neural Networks for solving selected problems in geotechnics are presented. First example deals with the use of ANN to analyze two similar tunnels built using SCL technology. The structure of interest is a part of Fővám square station of the 4th metro line in Budapest. Analysis was performed based on the data obtained from geotechnical monitoring and from construction stages. The numerical model was prepared for the purpose of sensitivity and back analyses of constitutive model parameters. In both cases the applications show the possibility and reliability of conducted results. Prediction method of jet grouting columns diameter was presented in the second example. Nowadays, definition of columns geometry and estimation of their diameters are difficult task. Possibility of ANN use for estimation of jet grouting columns diameter can optimize designing method. Wide database of field trial jet grouting columns, corresponding soil properties and their forming parameters with measured values of their diameters were used in the presented example. Data describing jet grouting columns were used for creating ANN and for estimating their diameters. The results are characterized by high correlation level between measured values of columns diameter and their predicted equivalents. The use of Artificial Neural Networks is an alternative method which can allow us to solve complex geotechnical problems. Selected examples confirm that the use of ANN is characterized by high reliability level.