

Zastosowanie ANFIS w analizie wyników badań gruntów

Ewa Daniszewska

*Katedra Geotechniki i Budownictwa Drogowego, Wydział Nauk Technicznych, Uniwersytet
Warmińsko-Mazurski, e-mail: ewa.dybiec@uwm.edu.pl*

Streszczenie: Adaptacyjny system wnioskowania neuronowo-rozmytego ANFIS (Adaptive Neuro-Fuzzy Inference System) w programie Matlab posłużył modelowaniu i określaniu relacji między prędkością ścinania a parametrami wytrzymałościowymi gruntu. Sprawdzono możliwości i umiejętności narzędzia ANFIS w interpretacji wyników badań trójosiowego ściskania ilów pobranych z okolic Olsztyna. Model neuronowo-rozmyty został zbudowany na podstawie zbioru wartości, którymi dysponowano po szeregu badań eksperymentalnych, łącznie z wartościami parametrów wytrzymałościowych gruntu na ścinanie. Baza danych wykorzystana do modelowania neuronowo-rozmytego składa się z 6 różnych parametrów gruntowych dla każdej z 12 prędkości ścinania stosowanych podczas badań trójosiowych. Umiejętność uczenia zweryfikowano na bazie danych testowych - model neuronowo-rozmyty zbudowany został z zestawów szkoleniowych, a dokładność została zweryfikowana przez zestawy testów, z którymi model miał do czynienia po raz pierwszy. Wyniki z modelu ANFIS nie odbiegały znacznie od tych, które zostały uzyskane bezpośrednio z badań fizycznych. System ANFIS okazał się narzędziem niezwykle uniwersalnym i nieskomplikowanym w obsłudze. Pozwolił uwzględnić wieloaspektowość wzajemnych relacji parametrów gruntowych.

Słowa kluczowe: adaptacyjny system neuronowo-rozmyty, logika rozmyta, trójosiowe badanie gruntu, prędkość ścinania.

1. Wprowadzenie

Podczas badań w aparacie trójosiowego ściskania modelujemy przybliżony przebieg obciążenia gruntu, odpowiadający warunkom naturalnym, co pozwala uzyskiwać wiarygodniejsze wartości parametrów geotechnicznych [1], wykorzystywanych w obliczeniach konstrukcyjnych. Proces rzeczywistych zmian zachodzących w gruncie pod wpływem prędkości przykładanych obciążeń i jego wpływu na dalsze zachowanie się gruntu jest procesem nieliniowym. Parametry gruntowe zmieniają się wraz ze zmianą prędkości ścinania. Podczas badań trójosiowych ważny jest zatem dobór prędkości ścinania gruntu. Prędkość ścinania powinna uwzględniać charakter obciążeń naturalnych, oraz wiele innych niepewności (obiektywnych i subiektywnych) związanych z właściwościami gruntu, z nieokreślonym stanem naruszenia struktury gruntu w czasie pobierania, transportu i przygotowania próbki oraz związanych z parametrami przyjmowanymi przez operatora w czasie badań. Natomiast w aparacie trójosiowego ściskania układy sterowania są liniowe. Jesteśmy w stanie, co najwyżej, tak dobrać przebieg badania, aby uzyskać właściwe działanie w danym punkcie pracy lub w przedziale czasu. Ta konieczność przestrojenia, zmiany przebiegu i metody badania, stały się przyczyną zainteresowania modelem wnioskowania adaptacyjnego.

2. ANFIS

Można wymienić kilka rodzajów systemów neuronowo-rozmytych, które znane są w literaturze pod jedną krótką nazwą ANFIS (Adaptive Neuro-Fuzzy Inference System). System ANFIS jest adaptacyjnym systemem wnioskowania neuronowo - rozmytym, o właściwościach ekwiwalentnych do układów rozmytych, który pozwala na zbudowanie modelu rozmytego o parametrach dostosowanych przez sieć neuronową. Stanowi zatem połączenie pewnej formy zmodyfikowanego lingwistycznie modelu wnioskowania rozmytego z metodami i umiejętnościami uczenia się sztucznej sieci neuronowej.

System wnioskowania został zastosowany w wielu różnych dziedzinach począwszy od kontroli procesów przetwarzania obrazów, przez oceny i klasyfikacje, do podejmowania decyzji i zarządzania w ekonomii [2]. Natomiast przez geotechników i geologów został użyty dopiero w ostatnim dziesięcioleciu [3, 4, 5, 6, 7]. Przewidywanie zachowań przy użyciu ANFIS zostało niedawno zbadane przez Provenzano et al. [8], a wyniki ich badań mogą zachęcić do wykorzystania ANFIS jako narzędzia wspierającego optymalizację i symulację modelu. Dwa modele opracowane przez zespół kierowany przez Kayadeleną [9] były w stanie nauczyć się złożonych relacji między podstawowymi właściwościami gruntu (np. wielkości poszczególnych frakcji gruntu, granicy płynności, stopnia zagęszczenia) a kątem tarcia wewnętrznego - wyniki uzyskane z implementacji komputerowej okazały się być zbliżone do wyników uzyskanych na drodze eksperymentalnej. Gokceoglu et al. [10] skonstruowali neuronowo-rozmyty model przewidywania modułu deformacji skał. Zespół Rangela (Rangel et al. [11]) zaproponował alternatywną ocenę stabilności tunelu w trakcie budowy przy użyciu właśnie systemu neuronowo-rozmytego. Wyniki skuteczności obu opracowanych modeli wykazały lepsze przybliżenie niż inne, powszechnie stosowane techniki. Przy pomocy ANFIS powstało wiele interesujących prac, godne polecenia są: [12, 13, 14]. ANFIS okazał się równie przydatny w ocenie regionalnej podatności podłoża do powstawania osuwisk [15]. Bardzo ważna publikacja należy do Cabalara, Cevika i Gokceoglu [7]. W pracy przedstawiono modele opracowane w ANFIS dla mieszanki piasku i miki na bazie badań przeprowadzonych w aparacie trójosiowego ściskania. Chociaż techniki logiki rozmytej są szeroko stosowane w aplikacjach inżynierskich, bo od 1980 roku, to do tej pory nie zostały zastosowane w dobieraniu prędkości ścinania gruntów w zależności od zmieniających się parametrów gruntowych podczas badań trójosiowych.

Modele rozmyte posiadają bardzo istotną zaletę – potrzebują znacznie mniej informacji o systemie, aniżeli konwencjonalne modele probabilistyczne. W dodatku informacje te mogą mieć charakter rozmyty, nieprecyzyjny. Adaptacyjny system wnioskowania neuronowo-rozmytego ANFIS wydaje się być odpowiedni do modelowania złożonych problemów, tam gdzie zależność między danymi czynnikami modelu nie jest znana. Stało się to przyczynkiem do wykorzystania systemu neuronowo-rozmytego w rozpoznaniu korelacji wyników badań trójosiowych gruntu.

Głównym celem niniejszej pracy było zbudowanie systemu neuronowo-rozmytego ANFIS na podstawie dostępnych parametrów gruntu. Postanowiono sprawdzić, czy gotowe narzędzie ANFIS działające w programie Matlab, ucząc się, będzie dobierać wartość prędkości ścinania v , nawet wówczas gdy nie posiada kompletnych danych - parametrów gruntowych, których nie było wcześniej w bazie danych.

3. Analiza wyników – obliczenie numeryczne

Adaptacyjny system wnioskowania neuronowo - rozmytego ANFIS, wykorzystany w niniejszej pracy, stanowi model systemu rozmytego z wnioskowaniem rodzaju Takagi-

Sugeno. Szczegółowy opis tej procedury można odszukać w pracy Janga [16], Daniszewskiej [17]. Eksperymentalna baza danych wykorzystana do modelowania neuronowo-rozmytego opierała się na badaniach laboratoryjnych iłu, w tym na badaniach w aparacie trójosiowego ściskania. Jak wykazano, istotny wpływ na uzyskiwane parametry wytrzymałościowe gruntu mają nie tylko zmienne podczas badań trójosiowych i parametry fizyczne danego gruntu, ale także prędkość przyrostu obciążeń w trakcie badania. Bardzo ważne jest, by mając wstępną charakterystykę danego gruntu tak dostosowywać prędkość ścinania, aby mieć wpływ na uzyskiwane wielkości parametrów wytrzymałościowych gruntu. Na wstępie, postawiono zatem problem znalezienia prędkości ścinania v , w zależności od zmiennych parametrów gruntowych: $c, \phi, I_L, w, e, \gamma$ w dopuszczalnych przestrzeniach: $C, \Sigma, \Xi, W, E, \Gamma$:

$$\{c \in C, \phi \in \Sigma, I_L \in \Xi, w \in W, e \in E, \gamma \in \Gamma\} \rightarrow v \quad (2)$$

Pierwszym krokiem było przyjęcie prędkości ścinania v , w zależności od warunków obciążenia i wstępnych charakterystyk gruntu. Następnym krokiem było wykonanie badania trójosiowego w celu przedłożenia informacji o fizycznych korelacjach między wartością prędkości ścinania v , a ustalonymi parametrami wytrzymałościowymi gruntu. Wytrzymałość badano seriami, 12 razy po 5 próbek dla danej prędkości ścinania. Prędkość przesuwny wynosiła: 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12 mm/h. Model neuronowo-rozmyty został zbudowany na podstawie pełnego zbioru wartości, którymi dysponowano po szeregu badań eksperymentalnych, łącznie z wartościami parametrów wytrzymałościowych gruntu na ścinanie. Założono, że wartość prędkości ścinania v będzie wynikiem wnioskowania rozmytego Fuzzy Inference.


Tabela 1. Baza danych wykorzystana do trenowania w ANFIS

Prędkość ścinania v [mm/h]	Spójność c [kPa]	Kąt tarcia wewnętrznego ϕ [°]	Wilgotność w [%]	Wskaźnik porowatości e	Ciężar objętościowy γ [kN/m ³]	Stopień plastyczności I_L
1	25,42	7,03	32,99	0,91	18,75	0,04
2	35,4	3,10	29,9	0,88	18,56	-0,03
3	37,9	1,94	34,02	0,98	18,23	0,02
4	37,25	1,82	31,33	0,96	18,04	0
5	35,05	3,74	32,69	0,98	18,06	0,01
7	29,29	7,09	32,5	0,97	18,08	-0,03
8	25,38	7,94	32,03	0,97	18,08	-0,02
10	20,04	9,35	32,35	0,92	18,63	0,02
11	18,13	10,36	32,44	0,92	18,63	0,02
12	12,86	11,98	33,95	0,99	18,17	0,06

Tabela 2. Zbiór danych do testowania w ANFIS

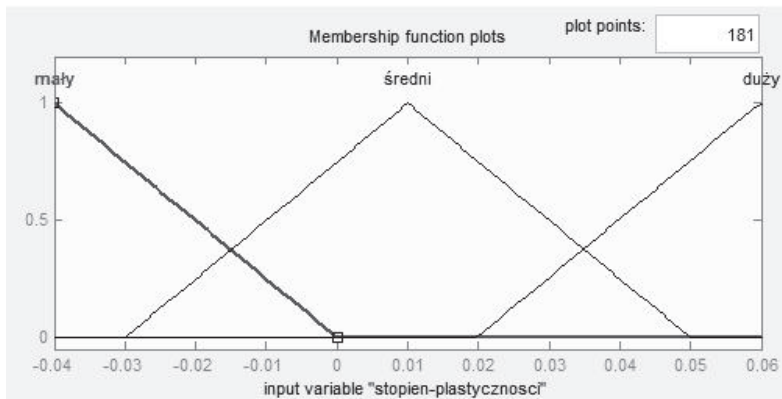
Prędkość ścinania v [mm/h]	Spójność c [kPa]	Kąt tarcia wewnętrznego ϕ [°]	Wilgotność w [%]	Wskaźnik porowatości e	Ciężar objętościowy γ [kN/m ³]	Stopień plastyczności I_L
6	33,44	5,96	31,03	0,95	18,06	-0,03
9	22,4	8,73	30,27	0,93	18,17	-0,04

Przed modelowaniem wyniki badań podzielono losowo na dwa zestawy: szkoleniowe (Tabela 1.) i testowe (Tabela 2.). Aby uniknąć nadmiernego dopasowania, procentowy udział parametrów w obu tych zestawach stanowił odpowiednio 83% danych szkoleniowych i 17% danych testowych, które sprawdzały umiejętność uczenia się modelu neuronowo-rozmytego.



Rys. 1. Diagram wejść i wyjść modelu rozmytego

Analizę wyników rozpoczęto od wyboru wstępnej struktury i parametrów regulatora rozmytego, podano liczbę zmiennych wejścia i wybrano wielkość wyjścia systemu. Wartościami wejścia były parametry gruntowe uzyskane podczas badań laboratoryjnych: spójność [Input1], kąt tarcia wewnętrzznego [Input2], wilgotność [Input3], stopień plastyczności [Input4], wskaźnik porowatości [Input5], ciężar objętościowy [Input6]. Wielkością wyjścia była wartość prędkości ścinania [Output1].



Rys. 2. Funkcje przynależności zbioru rozmytego wartości wejścia [Input4] - stopnia plastyczności

Następnie określono zakres sygnałów i wybrano trójkątny kształt funkcji przynależności *trimf* opisującej zbiór rozmyty dla każdej zmiennej wejściowej (Rys. 2). Spośród dostępnych 10 różnych funkcji przynależności wybrano trójkątny kształt *trimf*, jako jedną z najbardziej popularnych i czytelnych funkcji, które oferuje program. Podano zakres funkcji przynależności [Range], stanowiący zakres otrzymanych wielkości poszczególnych sześciu parametrów gruntowych dla całego zakresu wprowadzanych prędkości podczas przeprowadzonych badań trójosiowych. Każda ze zmiennych lingwistycznych została określona trzema funkcjami przynależności NumMFs o następujących nazwach: *mały/mała*, *średni/średnia*, *duży/duża* (Tabela 3.).

Tabela 3. Parametry wejść modelu

Nazwa (Name)	Zakres (Range)	Funkcja przynależności		
		Liczba	Nazwa	Zakres
[Input1] 'spójność'	[12.86 37.9]	MF1	'mała'	[2.844 12.86 22.88]
		MF2	'ś- rednia'	[15.36 25.38 35.4]
		MF3	'duża'	[27.88 37.9 47.92]
[Input2] 'kąt-tarcia- wewnętrznego'	[1.82 11.98]	MF1	'mały'	[-2.244 1.82 5.884]
		MF2	'średni'	[2.836 6.9 10.96]
		MF3	'duży'	7.916 11.98 16.04]
[Input3] 'stopień- plastyczności'	[-0.04 0.06]	MF1	'mały'	[-0.08 -0.04 6.939e-018]
		MF2	'średni'	[-0.03 0.01 0.05]
		MF3	'duży'	[0.0197 0.0597 0.0997]
[Input4] 'wilgotność'	[29.9 34.02]	MF1	'mała'	[28.25 29.9 31.55]
		MF2	'ś- rednia'	[30.31 31.96 33.61]
		MF3	'duża'	[32.37 34.02 35.67]
[Input5] 'wskaźnik- porowatości'	[0.88 0.99]	MF1	'mały'	[0.836 0.88 0.924]
		MF2	'średni'	[0.891 0.935 0.979]
		MF3	'duży'	[0.946 0.99 1.034]
[Input6] 'ciężar- objętościowy'	[18.04 18.75]	MF1	'mały'	[17.76 18.04 18.32]
		MF2	'średni'	[18.11 18.4 18.68]
		MF3	'duży'	[18.47 18.75 19.03]

System ANFIS rozwiązuje problem zgodnie z regułą Takagi-Sugeno:

$$\text{Jeżeli } (x_1 \text{ jest } A_1) \text{ i } (x_2 \text{ jest } A_2) \dots \text{i } (x_n \text{ jest } A_n) \text{ to } y=f(x_1, x_2, \dots, x_n) \quad (2)$$


gdzie: x_1, x_2, x_n – zmienne wejściowe; A_1, A_2, \dots, A_n – zbiory rozmyte, y – zmienna wyjściowa, $f(x_1, x_2, \dots, x_n)$ – funkcja.

W programie Matlab Fuzzy Logic Toolbox funkcja $f(x_1, x_2, \dots, x_n)$ jest wielomianem zerowego lub pierwszego rzędu. Konkluzję n -tej reguły można zapisać w postaci:

$$y = f(x_1, x_2, \dots, x_n) = c_0 + c_1 x_1 + c_2 x_2 + \dots + c_n x_n \quad (3)$$

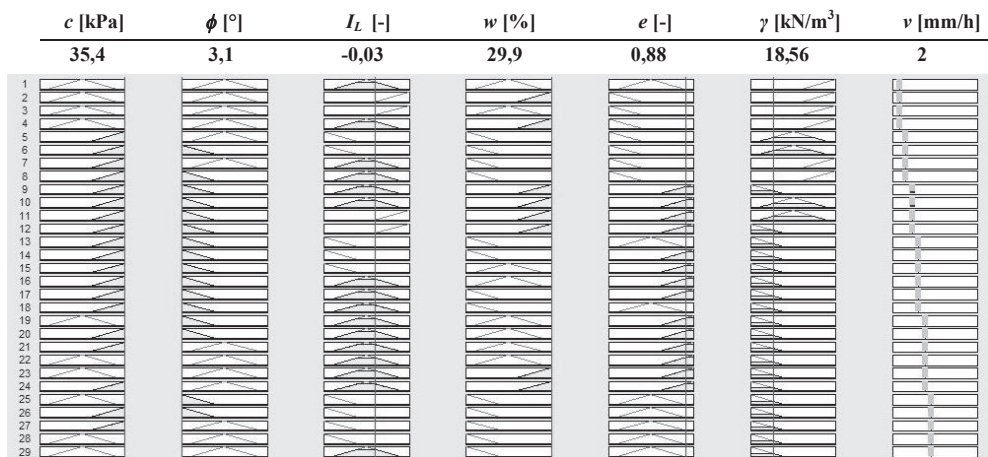
gdzie: $c_0, c_1, c_2, \dots, c_n$ – współczynniki wielomianu.

W ten sposób tworzona jest baza reguł, inaczej nazywana modelem lingwistycznym, który stanowi swoisty zapis sposobu zachowania się sterowanego modelu. Przykład zapisu pojedynczej reguły: „**Jeżeli** (spójność jest mała) **i** (kąt tarcia wewnętrznego jest średni) **i** (stopień plastyczności jest średni) **i** (wilgotność jest średnia) **i** (wskaźnik porowatości jest mały) **i** (ciężar objętościowy jest duży) **to** (prędkość ścinania jest duża)”. W niniejszej pracy określono zbiór 98 instrukcji warunkowych. W procesie uczenia się sieci na zadanych wartościach pomiarowych reguły ulegają modyfikacji. W taki sposób uzyskano samosterujący się regulator rozmyty bazujący na danych pomiarowych rodzaju wejście - wyjście (input - output) (Rys. 3.).




Rys. 3. Wizualizacja regulatora rozmytego

Na rysunku (Rys. 4.) zaprezentowano sposób wnioskowania obrazujący działanie zbudowanego regulatora rozmytego. Po wprowadzeniu do systemu wartości wszystkich parametrów gruntowych, takimi jakimi dysponowano po serii badań fizycznych, regulator dopasował prędkość ścinania (tutaj $v = 2$ [mm/h]). Wynik ten jest zgodny z tym co zostało wprowadzone na wejściu systemu. Jest to wyłącznie sprawdzenie i potwierdzenie poprawnego działania systemu.

Rys. 4. Sposób wnioskowania systemu ANFIS. Prędkość $v = 2$ [mm/h] dla parametrów gruntowych uzyskanych w ATS przy prędkości $v = 2$ [mm/h]

Zdaniem autora, obserwacja zmienności proponowanej prędkości ścinania - wielkości wyjścia modelu ANFIS (gwiazdki, Rys. 5), jest warta uwagi ze względu na zgodność z wartościami prędkości ścinania zadaną podczas badań w aparacie trójosiowego ściskania (kółeczka, Rys. 8.). Otrzymane wyniki świadczą o możliwościach systemu do jednoczesnej analizy wielu czynników (1) wpływających na ostateczny wynik.



Rys. 5. Wyniki uzyskane podczas szkolenia na danych uczących

Natomiast umiejętność uczenia się regulatora zweryfikowano na bazie danych testowych (Tabela 4), z którymi model miał do czynienia po raz pierwszy.

Tabela 4. Porównanie wyników prędkości ścinania uzyskanych z badań fizycznych v [mm/h] i w ANFIS v^* [mm/h] dla zbiorów danych uczących oraz testowych

v	1	2	3	4	5	6	7	8	9	10	11	12
v^*	5,81	2	3	4,4	5	7,19	7,95	7,25	8,48	8,01	9,78	12

gdzie: v [mm/h] – prędkość ścinania gruntu uzyskane z badań eksperymentalnych,

v^* [mm/h] - prędkość ścinania gruntu uzyskane z ANFIS

Wyniki z modelu ANFIS (wielkości prędkości ścinania v^*) nie odbiegają znacznie od tych, które zostały uzyskane bezpośrednio z badań fizycznych, oprócz wyniku pierwszego, dla $\text{Output}_1(v)=1$ [mm/h]. Powodów takiego stanu rzeczy może być wiele, m. in. bardzo nieliniowa zależność między parametrami. Zdaniem autora przyczyną rozbieżności wyników jest to, że dla wartości początkowej nie została trafnie określona wystarczająca liczba reguł z powodu ograniczenia możliwości wykorzystania zmiennych lingwistycznych. Zatem, aby lepiej rozumieć prawidłowości i móc na drodze obserwacji i porównań wyjaśnić choćby takie sytuacje jak powyżej, wymagana jest znacznie większa liczba badań laboratoryjnych oraz komputerowych.

4. Podsumowanie

Operowanie gotowym narzędziem oprogramowania komputerowego ANFIS z wbudowanym systemem neuronowo-rozmytym, jest współczesnym sposobem modelowania niepewności, mogącym radzić sobie z tak złożonym, zmiennym i często niejednorodnym materiałem, jakim jest grunt. Integracja geotechniki z technologią informacyjną pozwala przewidywać i podejmować decyzje inteligentniej, wykorzystując rozmytą optymalizację wielokryterialną, rozumowanie rozmyte a zarazem technikę obliczeń inteligentnych przy wykorzystaniu doświadczenia inżynierskiego (rządzonego zasadami nie tylko logicznymi). Wynika to z faktu, że w trakcie budowy układu rozmytego czy neuronowo-rozmytego można zawrzeć w nim wiedzę eksperta.

Okazuje się, że integracja badań eksperymentalnych wykorzystujących najnowszą aparaturę badawczą wraz z modelowaniem numerycznym, w którym stosowane są zasady logiki rozmytej w połączeniu z doświadczeniem inżynierskim jest możliwe. Co więcej, takie podejście jest niezwykle pomocne, aby uzyskiwać lepsze wyniki w trudnych i złożonych analizach zależności parametrów gruntowych. ANFIS ma zdolność uzupełniania brakującej wiedzy eksperta i umiejętność uczenia się i tworzenia nowych reguł. Jest zatem odpowiednie

dzią na poszukiwanie gotowego narzędzia, które pozwala na analizę obszernych i skomplikowanych baz danych w kompleksowy sposób. Stwarza możliwość stosowania metod rozmytych w geotechnice w przypadku rozpatrywania zadania złożonego czy niedokładnie określonego, ze skomplikowanymi współzależnościami, zbyt złożonymi, by je analizować metodami tradycyjnymi. Warto jednak podkreślić, że taka metoda jest doskonałym uzupełnieniem badań fizycznych, lecz nie jest ich zamiennikiem.

Literatura

- 1 Suchnicka H., Wytrzymałość gruntów – opis i badania. XI Krajowa Konferencja Mechaniki Gruntów i Fundamentowania – Gdańsk, 25-27 czerwca 1997, s. 47-74.
- 2 Rutkowski, L. Flexible neuro-fuzzy systems: structures, learning and performance evaluation. Kluwer Academic Publishers, 2004.
- 3 Akgun A., Sezer E.A., Nefeslioglu H.A., Gokceoglu C., Pradhan B. An easy-to-use MATLAB program (MamLand) for the assessment of landslide susceptibility using a Mamdani fuzzy algorithm. Computers and Geosciences, Volume 38, Issue 1, s. 23-34.
- 4 Gokceoglu C., Zorlu K. A fuzzy model to predict the uniaxial compressive strength and the modulus of elasticity of a problematic rock. Engineering Applications of Artificial Intelligence 2004, Vol. 17(1), s. 61–72.
- 5 Gokceoglu, C. A fuzzy triangular chart to predict the uniaxial compressive strength of Ankara agglomerates from their petrographic composition. Engineering Geology 2002, Vol. 66, s. 39–51.
- 6 den Hartog M.H., Babuska R., Deketh H.J.R., Alvarez Grima M., Verhoef P.N.W., Verbruggen H.B. Knowledge-based fuzzy model for performance prediction of a rock-cutting trencher. International Journal of Approximate Reasoning 1997, Vol.16, s. 43–66.
- 7 Cabalar A.F., Cevik A., Gokceoglu C. Some applications of Adaptive Neuro-Fuzzy Inference System (ANFIS) in geotechnical engineering. Computers and Geotechnics Vol. 40, March 2012, s. 14–33.
- 8 Provenzano P., Ferlisi S., Musso A. Interpretation of a model footing response through an adaptive neural fuzzy inference system. Computers and Geotechnics 2004, Vol.31, s.251–66.
- 9 Kayadelen C., Gunaydin O., Fener M., Demir A., Ozvan A. Modeling of the angle of shearing resistance of soils using soft computing systems. Expert Systems with Applications 2009, Vol.36,s.11814–26.
- 10 Gokceoglu C., Yesilnacar E., Sonmez H., Kayabasi A.A. Neuro-fuzzy model for modulus of deformation of jointed rock masses. Computers and Geotechnics 2004, vol. 31, s.375–83.
- 11 Rangel J.L., Iturraran-Viveros U., Ayala A.G., Cervantes F. Tunnel stability analysis during construction using a neuro-fuzzy system. International Journal for Numerical and Analytical Methods in Geomechanics 2005, Vol. 29, s.1433–56.
- 12 Zounemat-Kermani M., Beheshti A.A., Ataie-Ashtiani B, Sabbagh-Yazdi S.R. Estimation of current-induced scour depth around pile groups using neural network and adaptive neuro-fuzzy inference system. Applied Soft Computing 2009, Vol.9, s.746–55.
- 13 Kalkan E., Akbulut S., Tortum A., Celik S. Prediction of the unconfined compressive strength of compacted granular soils by using inference systems. Environmental Geology 2008, Vol.58, s.1429–40.
- 14 Kayadelen C., Taskiran T., Gunaydin O., Fener M. Adaptive neuro-fuzzy modeling for the swelling potential of compacted soils. Environmental Earth Sciences 2009, Vol. 59, s.109–15.
- 15 Pradhan B., Sezer E.A., Gokceoglu C., Buchroithner M.F. Landslide susceptibility mapping by neuro-fuzzy approach in a landslide-prone area (Cameron Highlands, Malaysia). IEEE Transactions on Geoscience and Remote Sensing 2010, Vol.48[12], s. 4164–77.
- 16 Jang, J.S.R. ANFIS: Adaptive-Network-based Fuzzy Inference Systems. IEEE Transactions on Systems, Man, and Cybernetics 1993, vol. 23, s. 665-685.
- 17 Daniszewska E. Zastosowanie adaptacyjnego, neuronowo-rozmytego systemu wnioskowania ANFIS w analizie wyników badania trójosiowego ściskania gruntów. Praca doktorska, Olsztyn 2012.

Application of the ANFIS to analysis of results from soil testings

Ewa Daniszewska

Department of Geotechnics and Road Construction, The Faculty of Technical Sciences, University of Warmia and Mazury in Olsztyn, e-mail: ewa.dybiec@uwm.edu.pl

Abstract: The article was analyzed in order to test applicability and capability of the ANFIS tool used for interpretation of results of triaxial shear tests on loamy soils sampled near Olsztyn. The ANFIS system in the Matlab software programme was used to model and determine relationships between the shear stress and soil resistance parameters in a triaxial shear test apparatus. It has been demonstrated that the achieved shear strength parameters are significantly affected by the variables tested during the triaxial experiments and physical parameters of a given soil sample, but also by the loading increment rate during the tests. It is extremely important to adjust the rate of loading during a test according to the preliminary characterization of a tested ground sample so as to have some control over the obtained ground strength parameters. The neuro-fuzzy model has been constructed based on a set of values obtained after a series of experimental tests, including values of ground shear strength parameters. The database used for the neuro-fuzzy modelling consisted of 6 different ground parameters for each of the 12 shear stress rates applied during the triaxial tests. The learnability was verified on a database composed of the test results – a neuro-fuzzy model was built from learning sets and its accuracy was verified by sets of tests to which the model was applied for the first time. The results obtained from the ANFIS model did not diverge substantially from the ones obtained directly by performing the physical tests. The ANFIS proved to be highly universal and easy to operate. It accounted for the multi-faceted nature of interrelationships between ground parameters.

Keywords: adaptive neuro-fuzzy inference system, fuzzy logic, soil triaxial testing, shear speed.

