

Aproksymacja danych doświadczalnych z badań trójosiowego ściskania gruntu przy użyciu perceptronu wielowarstwowego

Mgr inż. Dariusz Słowiński

Uniwersytet Warmińsko-Mazurski w Olsztynie, Wydział Nauk Technicznych

Celem badań opisanych w artykule jest ustalenie możliwości zastosowania sztucznych sieci neuronowych, zaimplementowanych w zestawie narzędziowym *Neural Network Toolbox* pakietu *Matlab* 7.11.0.584 (R2010b), do uzyskania numerycznego modelu regresyjnego badanego gruntu poprzez aproksymację wyników badań trójosiowego ściskania gruntów. Ocena zgodności wartości parametrów wytrzymałościowych gruntu (ϕ , c) uzyskanych z danych surowych oraz z danych z uzyskanego modelu numerycznego ma w zamierzeniu być również pomocą w ocenie poprawności wykonania badania trójosiowego ściskania gruntów. Badano wpływ zmiany struktury sieci na dokładność dopasowania uzyskanych krzywych do danych z przeprowadzonych badań. W opisie działania narzędzia i zastosowania go do aproksymacji danych doświadczalnych zachowano kolejność etapów przedstawioną w pakiecie *Matlab*.

Wyniki badań laboratoryjnych zawsze obarczone są pewnymi zakłóceniami i szumami. W przypadku badań geotechnicznych niepewności te są związane z jednej strony z ośrodkiem gruntowym, którego istotną cechą jest niejednorodność i zmienność właściwości, z drugiej strony źródłami niepewności są: wykorzystana w badaniach aparatura i metodyka prowadzenia badań [5], kompetencje personelu badawczego, a także – podobnie jak w innych dziedzinach badań w ostatnich czasach – wykorzystanie technologii informacyjnych do generowania i przekazywania danych doświadczalnych. Najczęściej dane pochodzące z eksperymentów mają charakter dyskretny, nie przedstawiają w istocie ciągłego przebiegu badanego procesu, a jedynie jego stany w pewnych odstępach czasu. Każdy z punktów danych doświadczalnych może być obciążony trudnym do oszacowania błędem. Aby zminimalizować szumy i zakłócenia obecne w uzyskanych danych oraz uzyskać ciągły (w pewnym zakresie parametrów) obraz zależności między uzyskanymi danymi, wielu badaczy, wśród nich Tschuschke i Vivatrat (cyt. za [2]), opisało i zastosowało trójstopniową metodę odszumiania danych. Metodę tę wykorzystano do opracowania danych z badań trójosiowego ściskania gruntu, przedstawiając opis jej zastosowania w niniejszym artykule:

- pierwszy etap tej metody, nazwany przez autorów filtrowaniem, służy usunięciu punktów danych wyraźnie odległych od punktów sąsiednich, a będących obrazem zakłóceń w przebiegu badania;
- drugi etap to skracanie danych, polegające na zastępowaniu określonej liczby sąsiadujących punktów jednym punktem o wartości równej średniej wartości zastępowanych punktów danych;
- trzeci etap określono jako wygładzanie danych; pod względem matematycznym chodzi tu o aproksymację otrzymanego z badań zbioru punktów krzywą tak dobraną, aby osiągnąć efekt wygładzenia danych bez nadmiernej utraty informacji zawartej w uzyskanym zbiorze danych.

Aproksymację danych doświadczalnych przedstawioną w dalszym ciągu artykułu wykonano przy użyciu perceptronu wielowarstwowego – jednej z najczęściej stosowanych sztucznych sieci neuronowych.

W kolejnych rozdziałach artykułu opisano badanie trójosiowego ściskania gruntu, którego wyniki następnie odszumiano, oraz zastosowaną sztuczną sieć neuronową (SSN) i jej implementację w pakiecie *Matlab*, a także kalibrację zastosowanego narzędzia i wykonanie aproksymacji danych doświadczalnych.

OPIS WYKONANIA BADANIA TRÓJOSIOWEGO ŚCISKANIA GRUNTU

Badanie trójosiowego ściskania przeprowadzono na próbkach ilów w stanie plastycznym, uzyskanych z prób NNS pobranych z okolic Klebarka Wielkiego, woj. warmińsko-mazurskie. Badanie prowadzono metodą UU (bez wstępnej konsolidacji i bez odpływu wody w trakcie badania) w zmodernizowanym [6] aparacie trójosiowego ściskania typu norweskiego, wyposażonym w system automatycznej akwizycji danych rejestrujący w czasie rzeczywistym zmiany wysokości próbki Δh , pionową siłę działającą na próbkę P , ciśnienie w komorze trójosiowej σ_3

oraz ciśnienie w porach próbki U . Po uwzględnieniu wymiarów próbki są obliczane w systemie i umieszczane w zestawie danych wartości naprężenia głównego σ_1 i odkształcenia względnego próbki ε_1 . Moment ściska próbki wyznaczono przy zastosowaniu kryterium maksymalnej wartości dewiatora naprężenia $\sigma_1 - \sigma_3$. Przeprowadzono trzy kolejne badania przy deklarowanych ciśnieniach w komorze trójosiowej σ_3 , równych 50 kPa, 100 kPa oraz 150 kPa i stałej prędkości posuwu stołu $v = 2$ mm/h. Dla każdego wykonanego badania uzyskano zapisany w postaci cyfrowej zestaw danych. Uzyskane dane interpretowano metodą ścieżek naprężenia.

Surowe dane z badań poddano dwóm pierwszym etapom procedury odszumiania danych: filtrowaniu i skracaniu. W przypadku badań trójosiowego ściskania gruntu filtrowanie danych umożliwia usunięcie punktów o ujemnej wartości parametru przedstawiającego zmniejszenie wysokości próbki pod wpływem przyłożonego obciążenia pionowego. Odczyty takie pojawiają się sporadycznie w początkowej fazie badania trójosiowego i spowodowane są dopasowaniem układu: próbka umieszczona w komorze – trzpień komory trójosiowej – czujnik odczytujący zmiany wysokości próbki. Procedurę skracania natomiast zastosowano jako przygotowanie do zmiany dziedziiny danych (w przypadku badań w aparacie trójosiowego ściskania z układem automatycznej akwizycji danych sygnały z sensorów rejestrowane są w funkcji czasu, zaś zależności obrazujące przebieg badania przedstawiane są w zależności od odkształcenia względnego ε_1).

Interpretację wyników wykonanych badań trójosiowego ściskania gruntów przeprowadzono dwukrotnie: pierwszy raz, wykorzystując dane niewygładzone, i powtórnie, korzystając z tych samych danych poddanych aproksymacji sztucznymi sieciami neuronowymi z pakietu *Matlab*. Wyniki uzyskane z danych nieaproxymowanych potraktowano jako dane referencyjne, porównując do nich wyniki uzyskane z danych wygładzonych.

Tabl. 1. Zestawienie informacji o danych niewygładzonych z badań trójosiowego ściskania

Lp.	Liczba punktów danych	σ_3 [kPa]	min. σ_1 [kPa]	maks. σ_1 [kPa]	$\Delta \sigma_1$ [kPa]	$\Delta \varepsilon_1$ [%]
1	2	3	4	5	6	7
1	4951	50	110,6760	149,7483	39,0723	6,2730
2	4308	100	131,9396	212,5530	80,6134	5,4890
3	7273	150	172,7253	268,7354	96,0101	9,4550

Tabl. 2. Zestawienie wyników badań trójosiowego ściskania gruntu uzyskanych z danych niewygładzonych oraz aproksymowanych metodą ruchomej średniej

Parametr wytrzymałościowy gruntu	Metoda aproksymacji danych		Różnica wartości [°] / [kPa]	Różnica wartości [%]
	Brak aproksymacji	Ruchoma średnia		
1	2		3	4
Kąt tarcia wewnętrzny ϕ [°]	5,6769	5,6862	0,0093	0,16
Spójność c_u [kPa]	36,4816	36,4122	-0,0694	-0,19

W tabl. 1 zestawiono informacje charakteryzujące uzyskane z poszczególnych badań dane. W kolumnie 2. pokazano liczbę punktów danych z poszczególnych badań, w kolejnej kolumnie przedstawiono wartość ciśnienia w komorze trójosiowej σ_3 podczas każdego z badań, zaś w kolumnach 4 ÷ 6 pokazano zakres wartości naprężenia σ_1 w czasie poszczególnych badań. W kolumnie 7. zaprezentowano zakres rejestrowanego odkształcenia względnego badanej próbki (nie jest on tożsamy z wartością ε_1 ściska próbki).

W tabl. 2 przedstawiono wartości parametrów wytrzymałościowych gruntu (kąt tarcia wewnętrzny ϕ i spójność c) uzyskane w wyniku interpretacji danych niewygładzonych, oraz – dodane w celu umożliwienia oceny jakości aproksymacji sztucznymi sieciami neuronowymi – wyniki pochodzące z interpretacji danych wygładzonych metodą ruchomej średniej [4].

ZASTOSOWANIE SIECI NEURONOWEJ *fitnet* PAKIETU MATLAB DO APROKSYMACJI DANYCH DOŚWIADCZALNYCH

Miara dopasowania krzywej aproksymującej do danych

Jako miarę dopasowania uzyskanej krzywej aproksymującej do danych doświadczalnych zastosowano błąd średniokwadratowy (MSE – *mean squared error*), obliczany według wzoru [1]:

$$MSE = \frac{1}{N} \sum_{k=1}^N e^2(k) \quad (1)$$

gdzie:

N – liczba punktów danych,

e – wektor błędu dopasowania; jego elementy są równe różnicy wartości punktów aproksymowanych i odpowiadających im punktów należących do krzywej aproksymującej.

W przypadku, gdy wartość błędu = 0, każdy punkt krzywej aproksymującej pokrywa się z punktem danych. Oznacza to całkowity brak wygładzenia danych, a zatem brak redukcji poziomu szumów i zakłóceń zawartych w otrzymanych danych oraz niebezpieczeństwo braku możliwości ciągłego różniczkowania danych, co może powodować problemy przy stosowaniu narzędzi matematycznych do dalszej analizy danych. Z kolei zwiększająca się wartość błędu dopasowania oznacza coraz większe wygładzenie danych, które jednak przy zbyt wysokiej wartości błędu związane jest z coraz większą utratą informacji zawartej w danych. Oszacowanie właściwej wartości błędu dopasowania (stopnia wygładzenia danych) pozostaje w dużym stopniu kwestią doświadczenia i intuicji badacza.

W opisywanej analizie starano się uzyskać jak najbardziej precyzyjne dopasowanie uzyskanej krzywej aproksymującej do danych, stąd konfiguracja zastosowanych sieci neuronowych miała na celu uzyskanie jak najniższych wartości błędu MSE. Chęć czytelnej przedstawienia porównania wartości parametrów wytrzymałościowych gruntu uzyskanych z danych surowych i aproksymowanych wymusiła przedstawienie w tabl. 1, 2, 5 i 6 wartości parametrów σ_1 , ε_1 , ϕ oraz c z dokładnością do czterech miejsc po przecinku, mimo że w praktyce inżynierskiej takie wyniki przedstawione z dokładnością do jednego miejsca po przecinku uznaje się za wystarczające.

Przygotowanie danych

Przed prezentacją danych sieci neuronowej poddano je operacjom filtrowania i skracania danych. Opracowywany zbiór musi być odpowiednio liczny, zaś rozrzut wartości danych wejściowych i wyjściowych powinien wypełniać cały zakres możliwych do uzyskania w badaniu wartości. Ze względu na wykorzystywaną do uzyskania wartości kąta tarcia wewnętrznego ϕ i spójności c_u zależność $q = f(p)$, gdzie $q = (\sigma_1 - \sigma_3)/2$, zaś $p = (\sigma_1 + \sigma_3)/2$, w pierwszym rzędzie rozważano możliwość przedstawienia sieci wzorców w układzie: dane wejściowe – p , dane wyjściowe – q . Jednak analiza zbioru danych wykazała, że ze względu na bardzo szybki przyrost wartości naprężenia głównego σ_1 w początkowej fazie badania (rys. 1a) we wszystkich trzech badaniach, przedstawienie danych w układzie $q = f(p)$ powoduje brak pokrycia pełnego zakresu wartości zarówno przez dane wejściowe, jak i przez dane wyjściowe (rys. 1b). Prezentacja takiego zbioru danych sieci powodowała, że w zakresie nieciągłości danych przebieg uzyskanej krzywej aproksymującej zupełnie nie odpowiadał danym aproksymowanym (rys. 1c).

W rezultacie zdecydowano się na utworzenie dla każdego badania i przedstawienie sieci dwóch zbiorów danych: $z1s = \sigma_1(\epsilon_1)$ i $z2s = \sigma_3(\epsilon_1)$, a następnie utworzenie wektorów q i p umożliwiających uzyskanie wartości badanych parametrów gruntu z wygładzonych danych. Rozwiązanie to wyeliminowało występującą jednocześnie w danych wejściowych i wyjściowych wzorców nieciągłość wartości i pozwoliło na stabilne i przewidywalne zachowanie sieci. Spowodowało jednocześnie konieczność utworzenia sieci o dwóch zbiorach wyjściowych dla każdego badania trójosiowego (σ_1 i σ_3).


We wszystkich utworzonych sieciach zachowano domyślnie proponowany przez sieć podział prezentowanych zestawów danych na trzy zbiory: treningowy (70%) całego zestawu danych, walidacyjny (15%) i testowy (15%). Mając na uwadze zachowanie dobrej zdolności otrzymanych sieci do uogólniania danych, zdecydowano, że dla poszczególnych badań i badanych sieci stosunek liczby wzorców uczących P do liczby parametrów sieci (LPS)

$$k = \frac{P}{LPS} \quad (2)$$

nie powinien być mniejszy od 30. Pozwoliło to na określenie dla poszczególnych badań maksymalnej liczby neuronów w warstwie ukrytej.


Utworzenie sieci

Wykorzystana w niniejszych badaniach SSN może być uruchomiona z poziomu linii komend *Matlaba* poleceniem *fitnet* lub poprzez uruchomienie graficznego kreatora (*nftool*). Powoduje to utworzenie w pamięci *Matlaba* obiektu przechowującego strukturę sieci (domyślna nazwa: *net*) wraz tymi domyślnymi parametrami, które mogą być przypisane sieci bez prezentacji danych. Liczba wejść oraz liczba wyjść pustej sieci ustawione są na 1, liczba warstw na 2 (ukryta z 10 neuronami o sigmoidalnej (*tansig*) funkcji aktywacji i wyjściowa z 1 neuronem o liniowej (*purelin*) funkcji aktywacji).




Rys 1. Nieciągłość wartości danych uczących i jej konsekwencje w działaniu sieci

- a) dane uczące przedstawione jako zależność $\sigma_1 = f(\epsilon_1)$
- b) dane uczące przedstawione jako zależność $q = f(p)$
- c) dane uczące (surowe) i ich aproksymacja siecią neuronową



Rys. 2. Ograniczenie liczby parametrów sieci ze względu na liczbę wzorców uczących dla sieci o jednej warstwie ukrytej



Rys. 3. Schemat sieci neuronowej *fitnet* (rysunek na podstawie zrzutu ekranu pakietu *Matlab*)
 w – wektor wag neuronów danej warstwy, b – wektor wartości progowych (bias) neuronów danej warstwy

Badania prowadzono równolegle dwoma sposobami. Pierwszy polegał na utworzeniu jednego obiektu SSN *fitnet* o pojedynczym wektorze danych wejściowych ε_1 i dwóch wektorach wyjściowych σ_1 i σ_3 , aproksymującego dane z wszystkich trzech badań trójosiowych. Struktura tej sieci nie podlegała modyfikacjom podczas przetwarzania wszystkich prezentowanych da-

nach. Sieć była zbudowana z jednej warstwy ukrytej z 20 neuronami i warstwy wyjściowej z 2 neuronami. Funkcją trenującą sieć była funkcja *trainlm*. Taka struktura sieci ($LPS = 82$) zapewniła zachowanie dla poszczególnych badań i badanych sieci stosunku P/LPS nie mniejszego od 30.

Tabl. 3. Sieci – liczebność zbiorów treningowych i zakresy parametrów sieci

Lp.	σ_3 w komórce [kPa]	Dane wejściowe	Dane wyjściowe	Liczba wzorców P	Liczba warstw ukrytych	Liczba neuronów w warstwie ukrytej	Maksym. LPS	Minim. P/LPS
1	2	3	4	5	6	7	8	9
1.1	50 100 150	ε_1	σ_1, σ_3	3466 3015 5091	1	20	82	42,3 36,8 62,1
2.1	50	ε_1	σ_1, σ_3	3466	1 2 3	1 ÷ 25 1 ÷ 8 1 ÷ 6	102 106 110	33,9 32,7 31,5
2.2	100	ε_1	σ_1, σ_3	3015	1 2 3	1 ÷ 24 1 ÷ 7 1 ÷ 5	98 86 82	30,8 35,1 36,7
2.3	150	ε_1	σ_1, σ_3	5091	1 2 3	1 ÷ 41 1 ÷ 10 1 ÷ 7	166 152 142	30,7 33,5 35,8

Drugi sposób polegał na utworzeniu 3 obiektów sieci (po 1 sieci dla każdego z 3 kolejnych badań) o jednym wektorze wejściowym ε_1 i dwóch wektorach wyjściowych σ_1 i σ_3 . W procesie kalibracji sieci zmieniano liczbę parametrów sieci (liczbę warstw ukrytych i liczbę neuronów w każdej warstwie ukrytej), zaś pozostawiono domyślną funkcję trenującą sieć: *trainlm*. Liczebności zbiorów treningowych w poszczególnych zestawach danych oraz zakresy parametrów sieci przedstawiono w tabl. 3

Konfiguracja sieci

Jest to proces dopasowywania rozmiarów węzłów wejściowych i neuronów wyjściowych sieci, funkcji pre- i postprocesingu oraz inicjalizacji wag, który dokonywany jest po prezentacji sieci wzorców na podstawie analizy danych wejściowych i wyjściowych. Może być uruchamiany automatycznie przed rozpoczęciem treningu sieci lub ręcznie poprzez polecenie *configure*. W przeprowadzonych badaniach konfiguracja każdej z sieci była uruchamiana automatycznie przed wywołaniem funkcji trenującej. We wszystkich utworzonych sieciach domyślne funkcje pre- i postprocesingu pozostawiono bez zmian. Pierwsza z nich, *mapminmax*, normalizuje dostarczone dane przed obliczeniami wykonywanymi na nich przez sieć i przywraca je do formatu użytkownika po obliczeniach sieciowych. Druga, *removeconstantrows*, usuwa z zestawu wzorców powtarzające się pary danych wejściowych i wyjściowych. Operacje te optymalizują wykonywane przez sieć obliczenia [7].

Trening i walidacja sieci

Po nadaniu zestawom wag i wartości progowych następuje etap trenowania sieci, czyli przedstawiania jej wzorców: zestawu wartości wejściowych i odpowiadających im poprawnych wartości wyjściowych. Reakcja sieci polega na takiej zmianie wartości wag i progów, by zminimalizować wartość błędu dopasowania danych obliczonych przez sieć do danych wyjściowych wzorców. Właściwie przeprowadzony trening decyduje o poprawnym działaniu sieci. Sieć niedostatecznie wytrenowana będzie generować zbyt wysoki błąd dopasowania (słaba aproksymacja danych uzyskaną krzywą). Sieć przetrenowana

wyprodukuje bardzo dobre dopasowanie (bardzo niską wartość błędu dopasowania) do wzorców, ale utraci zdolności uogólniania, tzn. będzie słabo aproksymować nowe wartości, nieobecne we wzorcach. Jednym ze sposobów zabezpieczenia przed zjawiskiem przetrenowania jest podział danych na zbiór treningowy, służący do nauki sieci oraz zbiory: walidacyjny i testowy. Zbiór walidacyjny umożliwia przerwanie treningu sieci w chwili, gdy błąd dopasowania dla tego zbioru w kolejnych epokach staje się większy od minimalnego osiągniętego dotychczas (nawet, gdy błąd dla zbioru treningowego wciąż się zmniejsza). Zbiór testowy nie jest używany podczas treningu i służy do porównywania modeli działania sieci oraz kontroli poprawności podziału danych na zbiory.

Każda sieć trenowana była kolejno według podanych w tabl. 3 zakresów liczb warstw ukrytych i neuronów w każdej warstwie ukrytej. Zastosowano funkcję trenującą sieć *trainlm* – funkcję treningową z wsteczną propagacją błędów dostosowującą wartości wag i progów zgodnie z algorytmem Levenberga – Marquardta. Jest to jeden z najszybszych algorytmów optymalizacyjnych, stąd często *trainlm* jest domyślną funkcją trenującą różnych sieci. Wadą jej są większe niż przy innych algorytmach wymagania dotyczące pamięci [7].

W obu sposobach badań, każdej sieci i każdej kombinacji liczby warstw ukrytych i neuronów warstwy ukrytej rejestrowano uzyskany minimalny poziom błędu dopasowania danych (MSE), czas trwania treningu, numer najlepszej epoki (epoki, w której wystąpił błąd MSE uznany za minimalny), a także sposób zakończenia treningu. Kryterium wyboru sieci stanowił osiągnięty podczas treningu minimalny błąd MSE (z uwzględnieniem zagrożenia przetrenowania sieci).

W tabl. 4 przedstawiono najniższe uzyskane wartości MSE dla danych z poszczególnych badań. Prezentowane wartości uzyskano przez jeden obiekt sieci zastosowany do wszystkich danych (I sposób) oraz sieci o 1, 2 i 3 warstwach ukrytych i podanej liczbie neuronów (II sposób). Struktura sieci opisana jest według schematu:

(liczba_wejść)_(liczba_neuronów_warstwy_ukrytej)...._(liczba_wyjść)

W drugim sposobie badań najlepsze dopasowania uzyskano dla wszystkich przeprowadzonych badań trójosiowych przy użyciu sieci o jednej warstwie ukrytej. W przypadku badania przy $\sigma_3 = 50$ kPa była to sieć o 19 neuronach w warstwie ukrytej,


Tabl. 4. Minimalne wartości MSE dla danych z testów trójosiowych

Lp.	Deklarowane σ_3 w komorze [kPa]	Struktura sieci	Jeden obiekt sieci dla wszystkich testów (I sposób)	Zastosowane typy sieci (II sposób)		
		Wartość MSE		Sieci o 1 warstwie ukrytej	Sieci o 2 warstwach ukrytych	Sieci o 3 warstwach ukrytych
1	2	3	4	5	6	7
1	50	Struktura sieci	1_20_2	1_19_2	1_8_8_2	1_5_5_5_2
		MSE	0,0060	0,0056	0,0079	0,0206
2	100	Struktura sieci	1_20_2	1_24_2	1_7_7_2	1_5_5_5_2
		MSE	0,0106	0,0076	0,0128	0,0130
3	150	Struktura sieci	1_20_2	1_40_2	1_9_9_2	1_5_5_5_2
		MSE	0,0236	0,0066	0,0091	0,3196

w przypadku badania przy $\sigma_3 = 100$ kPa – sieć o 24 neuronach i w przypadku badania przy $\sigma_3 = 150$ kPa – sieć o 40 neuronach. Dane aproksymowane tymi sieciami użyto do utworzenia wektorów q i p , służących do uzyskania szukanych wartości parametrów wytrzymałościowych gruntu. Badania przeprowadzone przy użyciu jednego obiektu sieci dały dla danych z poszczególnych badań błędy MSE o większych wartościach niż sieci jednowarstwowe kalibrowane, ale w większości mniejsze niż sieci o dwóch i trzech warstwach ukrytych. Fakt osiągnięcia lepszego dopasowania przez sieci o jednej warstwie ukrytej w porównaniu z sieciami o większej liczbie warstw ukrytych może być tłumaczony przez zjawisko przeuczenia sieci, dotyczące sieci o zbyt wysokiej (w stosunku do rozwiązywanego problemu) liczbie parametrów sieci (warstw i neuronów). Polega ono na osiągnięciu przez sieć bardzo dobrego dopasowania w zbiorze treningowym przy jednoczesnym obniżeniu zdolności uogólniania nabytych doświadczeń. Konsekwencją jest osiąganie gorszych dopasowań dla danych spoza zbioru treningowego [3].

Na rys. 4 przedstawiono przebieg treningu jednej z sieci trenowanej funkcją *trainlm*. Należy zwrócić uwagę na przebiegi krzywych przedstawiających osiągane w kolejnych epokach wartości MSE dla poszczególnych zbiorów. Elementy zbioru testowego nie są używane podczas treningu do korekty wartości wag i progów, zaś wartości MSE uzyskane dla tego zbioru stanowią miarę sprawności działania sieci w każdej epoce na elementach nie należących do zbioru treningowego (zdolność uogólniania). Podobne tendencje przebiegu krzywej zbioru treningowego i testowego świadczą o poprawności dokonanego podziału na zbioru treningowy, walidacyjny i testowy oraz stabilności modelu sieci.

Wartości błędu MSE dla zbioru treningowego malały przez cały przebieg treningu. Przebieg tych zmian jest cały czas porównywany z wartościami MSE dla zbioru walidacyjnego. Wartości MSE dla tego zbioru również malały aż do epoki nr 15. W tej epoce osiągnięto w zbiorze walidacyjnym pewną wartość MSE. Ponieważ podczas kolejnych 6 epok wartości MSE dla zbioru walidacyjnego były wyższe niż w epoce 15, w epoce 21 trening zakończono (stop walidacyjny), mimo ciągłego zmniejszania wartości MSE dla zbioru treningowego. Za wartości optymalne dla działania sieci uznano wartości parametrów z epoki 15 (określonej jako najlepsza epoka). Takie zachowanie funkcji treningowej zabezpiecza sieć przed przetrenowaniem i wynikającym z niego pogorszeniem zdolności do uogólniania nabytej wiedzy.

Rys. 4. Przykład przebiegu treningu SSN *fitnet*

W wyniku aproksymacji danych przeprowadzonej przy użyciu kalibrowanych SSN *fitnet* z pakietu *Matlab* uzyskano wartości kąta tarcia wewnętrznego ϕ i spójności c_u badanych próbek gruntu (rys. 5). Na rys. 6 przedstawiono wartości kąta tarcia wewnętrznego ϕ i spójności c_u uzyskane z danych aproksymowanych jednym obiektem SSN *fitnet*. Wynikami referencyjnymi są wartości kąta tarcia wewnętrznego ϕ i spójności c_u obliczone na podstawie danych nieaproksymowanych (rys. 7). Dla porównania jakości aproksymacji uzyskanych przy użyciu sztucznych sieci neuronowych przedstawiono wartości parametrów ϕ i c_u uzyskanych z danych aproksymowanych metodą ruchomej średniej [4] (rys. 8).

Wartości liczbowe uzyskanych parametrów wytrzymałościowych badanych ilów umieszczono w tabl. 5 (kąt tarcia wewnętrznego ϕ) i tabl.6 (spójność gruntu c_u). Kolumny nr 3 tabl. 5 i 6 zawierają różnice wartości między parametrami otrzymanymi z danych aproksymowanych metodą ruchomej średniej i SSN a parametrami uzyskanymi z danych nieaproksymowanych, wyrażone w odpowiednich jednostkach. Kolumny nr 4 obu tablic zawierają różnice wartości między parametrami otrzymanymi z danych aproksymowanych dowolnymi metodami a parametrami uzyskanymi z danych nieaproksymowanych, wyrażone jako procent wartości referencyjnej.

Otrzymane na podstawie danych aproksymowanych SSN *fitnet* wartości kąta tarcia wewnętrznego ϕ są bardzo zbliżone do wartości referencyjnej parametru (tabl. 2), obliczonej na podstawie niewygładzanych danych.


Otrzymane na podstawie danych aproksymowanych SSN *fitnet* wartości spójności c_u są bardzo zbliżone do wartości referencyjnej parametru (tabl. 2), obliczonej na podstawie niewygładzanych danych.

Tabl. 5. Zestawienie otrzymanych wartości kąta tarcia wewnętrznego ϕ


Metoda aproksymacji danych	Wartość kąta tarcia wewnętrznego ϕ [°]	Różnica wartości [°]	Różnica wartości [%]
1	2	3	4
Ruchoma średnia	5,6862	0,0093	0,16
SSN <i>fitnet</i> kalibrowane	5,6909	0,0140	0,25
SSN <i>fitnet</i> (jedna sieć)	5,7177	0,0408	0,72

Tabl. 6. Zestawienie otrzymanych wartości spójności c


Metoda aproksymacji danych	Wartość spójności c_u [kPa]	Różnica wartości [kPa]	Różnica wartości [%]
1	2	3	4
Ruchoma średnia	36,4122	-0,0694	-0,19
SSN <i>fitnet</i> kalibrowane	36,3587	-0,1229	-0,34
SSN <i>fitnet</i> (jedna sieć)	36,2885	-0,1931	-0,53




Rys. 5 Wartości ϕ i c_u (SSN *fitnet*)



Rys. 7. Wartości ϕ i c_u (dane nieaprosymowane)



Rys. 6. Wartości ϕ i c_u (SSN *fitnet* – jedna sieć)



Rys. 8. Wartości ϕ i c_u (metoda ruchomej średniej)

PODSUMOWANIE

Zbliżone wartości uzyskanych parametrów wytrzymałościowego gruntu oznaczają, że SSN *fitnet* użyta do aproksymacji danych nadaje się do wygładzania wyników badań trójosiowych. Mogą również wskazywać na brak poważnych uchybień w toku przeprowadzonego badania trójosiowego ściskania badanego gruntu. Porównując wyniki osiągnięte za pomocą jednego obiektu sieci dla wszystkich badań i wielu sieci optymalizowanych dla poszczególnych badań, należy stwierdzić, że kalibrowane jednowarstwowe sieci *fitnet* dały lepsze dopasowanie danych (mniejsze wartości MSE dla poszczególnych badań).

Warunkiem prawidłowego zachowania SSN *fitnet* przy aproksymacji danych pomiarowych jest wykonanie, przed prezentacją danych sieci, analizy liczebności danych oraz ciągłości pokrycia zakresu wartości danych wejściowych i wyjściowych wzorców. Należy również przeprowadzić treningi sieci przy różnych parametrach konfiguracyjnych (liczba neuronów warstw ukrytych, liczba warstw, dobór odpowiednich funkcji treningowych).

Ponieważ okazało się, że SSN *fitnet* może być zastosowana do wygładzania danych z badań trójosiowego ściskania gruntu, interesująca wydaje się odpowiedź na pytanie, czy do

wygładzania takich danych można użyć również sztucznych sieci neuronowych wyposażonych w funkcje radialne (sieci RBF). Temu zagadnieniu poświęcone będą kolejne badania.

LITERATURA

1. Bartecki, K.: Sztuczne sieci neuronowe w zastosowaniach, zbiór ćwiczeń laboratoryjnych z wykorzystaniem przybornika *Neural Network* programu *Matlab*. Oficyna Wydawnicza Politechniki Opolskiej, 2010.
2. Lunne T. i in.: Cone penetration testing in geotechnical practice. Blackie Academic & Professional, An Imprint Of Chapman & Hall, 1997.
3. Matlab – podręcznik użytkownika. MathWorks, Natick, USA 2004.
4. Słowiński D., Damicz J., Szymański, L., Tran, C.: Nowoczesne techniki opracowania danych pomiarowych z badań geotechnicznych. Część 2: Zastosowanie aproksymacji wielomianowej i aproksymacji metodą ruchomej średniej do badania trójosiowego ilów. Inżynieria Morska i Geotechnika, nr 6/2011.
5. Tran, C.: A theory of geotechnical uncertainty. Wydawnictwo Politechniki Gdańskiej, 2000.
6. Tran C., Słowiński D., Srokosz P.: Modernizacja klasycznego aparatu trójosiowego typu norweskiego. Inżynieria Morska i Geotechnika, nr 3/2008.
7. Wprowadzenie do sieci neuronowych. StatSoft, Kraków 2001.