Przewidywanie średnic kolumn iniekcyjnych przy zastosowaniu sztucznych sieci neuronowych

Mgr inż. Maciej Ochmański^{1,2}, dr hab. inż. Joanna Bzówka¹, prof. nadzw. P. Śl., dr hab. inż. Giuseppe Modoni², prof. nadzw. UCSL

¹Politechnika Śląska, Wydział Budownictwa

²Università degli Studi di Cassino e del Lazio Meridionale, Dipartimento di Ingegneria Civile e Meccanica

Iniekcja strumieniowa jest jedną z najbardziej popularnych metod wzmacniania podłoża gruntowego, która z powodzeniem znajduje zastosowanie na całym świecie, jako rozwiązanie różnych problemów geotechnicznych (fundamentowanie, ściany oporowe, tunele itp.). Możliwą alternatywą dla rozwiązania podstawowego (nazwanego systemem jednostrumieniowym), w którym tylko zaczyn cementowy podlega iniekcji, jest zastosowanie współosiowego strumienia powietrza w celu osłony zaczynu cementowego (system dwustrumieniowy) lub zastosowanie wraz z współosiowym strumieniem powietrza strumienia wody w celu wstępnej erozji struktury gruntu (system trójstrumieniowy). Technologia ta cechuje się szerokim spektrum rozwiązań, zarówno w celu zwiększenia wymiarów oraz właściwości mechanicznych kolumn, jak i zwiększenia efektywności wzmacniania [14].

W celu skutecznej aplikacji technologii iniekcji strumieniowej, zarówno gdy służy ona do utworzenia rzędu pojedynczych kolumn (np. [34]) lub do uzyskania ciągłej struktury utworzonej przez częściowo zachodzące na siebie kolumny [2, 16, 21], fundamentalnym aspektem jest kontrolowanie średnicy kolumn poprzez dostosowywanie energii iniekcji do napotkanych warunków gruntowo-wodnych. W przypadku, gdy średnice kolumn są mniejsze niż oczekiwane, co może być wynikiem błędnie dobranych parametrów formowania, utworzona struktura może charakteryzować się obniżoną nośnością lub nieciągłością, a tym samym integralność i funkcjonalność całej konstrukcji może być ograniczona (np. [13, 27, 29]).

W ujęciu ogólnym, średnica kolumn jest zależna od możliwości propagowania tnącego strumienia na dużą odległość od dyszy, co jest określone przez zależność pomiędzy energią podczas iniekcji a oporem ośrodka gruntowego [5]. Energia jest funkcją zależną od składu iniektu, liczby i średnicy dysz, prędkości iniekcji oraz prędkości podnoszenia monitora. Natomiast opór ośrodka gruntowego zależy od zachodzącego mechanizmu pomiędzy strumieniem a ośrodkiem gruntowym, w związku z czym zależy od naprężeń pierwotnych w ośrodku gruntowym [18]. Ze względu na heterogeniczność naprężeń pierwotnych kolumny cechuja się zmiennym przekrojem poprzecznym wraz z głębokością i rzadko kiedy bywają idealnie cylindryczne. W celu uwzględnienia tego aspektu zaproponowano deterministyczną, półprobabilistyczną lub probabilistyczną metodę projektowania (por. [14]). We wszystkich tych przypadkach predykacja średniej wartości średnicy ma ogromne znaczenie.

W przeszłości problem ten rozwiązano przy zastosowaniu różnych podejść. Pierwsze podejścia (np. [4, 7, 10, 12, 41]), bazujące na obserwacjach polowych uwzględniały zależność średnicy od właściwości ośrodka gruntowego i/lub od parametrów formowania. Główne ograniczenia takich empirycznych studiów wywodzą się nie tylko z ograniczonej liczby obserwacji, ale również z nieusystematyzowanej analizy mechanizmów zachodzących podczas iniekcji. Ostatni warunek prowadzi do subiektywnego i niekompletnego wyboru istotnych współczynników oraz do sformułowań pozbawionych ogólności. W celu uzupełnienia tych luk Chu [9], Modoni i in. [35] oraz Ho [24] zaproponowali podejście alternatywne. W celu sformułowania wzorów matematycznych do opisu tych zjawisk, Chu [9], Modoni i in. [35] oraz Ho [24] przeanalizowali mechanizmy zachodzące podczas dyfuzji zanurzonego strumienia oraz zależność pomiędzy strumieniem a gruntem. Funkcje te są podstawowymi komponentami modeli teoretycznych użytych do predykcji średnicy kolumn utworzonych za pomocą systemu iniekcji jednostrumieniowej w gruntach spoistych [9], żwirach, piaskach oraz gruntach zaglinionych [35].

Zapożyczając koncepcję modelu Modoniego i in. [35], Shen i in. [39] sformułowali teoretyczne podejście mające zastosowanie w gruntach spoistych i niespoistych wzmocnionych iniekcją jednostrumieniową, dwustrumieniową oraz trójstrumieniową. Rozszerzenie modelu na iniekcję dwu- i trójstrumieniową było możliwe dzięki ilościowemu określeniu wpływu strumienia powietrza.

Inne podejście zaproponowali Croce i in. [17], którzy ograniczyli matematyczną złożoność modelu Modoniego i in. [35], wymagającą iteracyjnej integracji równań połączonych szeregowo, udowadniając jego równoważność z prostszą następującą funkcją potęgowania:

$$D = A \cdot s^{\alpha} \cdot E_n^{\prime\beta} \tag{1}$$

gdzie średnica kolumny *D* jest powiązana z oporem ośrodka gruntowego *s*, które jest wyrażone przez niezdrenowaną wytrzymałość na ścinanie gruntów spoistych, jako efekt pomiędzy pionowym naprężeniem oraz stycznym kątem tarcia dla gruntów niespoistych) oraz z energią u wylotu dyszy E'_n . Natomiast α i β są to parametry skalibrowane na podstawie danych eksperymentalnych. W powyższym wzorze energia jest wyrażona na jednostkę długości kolumny, co daje możliwość pogrupowania wszystkich istotnych zmiennych formowania w unikalne parametry wyrażone za pomocą następującej zależności:

$$E'_{n} = \frac{1}{2} \frac{m \cdot v_{0}^{2}}{L} = \frac{\pi}{8} \cdot \frac{M \cdot \rho \cdot d^{2} \cdot v_{0}^{3}}{v_{r}}$$
(2)

gdzie:

M, d – odpowiednio liczba oraz średnica dysz,

 ρ – gęstość zaczynu cementowego,

v₀ – prędkość wylotu zaczynu cementowego z dyszy,

 v_r – prędkość podnoszenia monitora.

Croce i Flora [12] przedstawili następującą zależność pomiędzy energią w dyszy a energią w pompie przy uwzględnieniu 10% utraty energii podczas iniekcji:

$$E'_{n} \approx 0, 9 \cdot E'_{p} \qquad E'_{p} = \frac{p \cdot Q}{v_{r}}$$
(3)

gdzie:

p – ciśnienie w pompie,

Q- prędkość przepływu medium iniekcyjnego.

Metodę tę rozszerzono kolejno na strumień iniekcji podwójnej i potrójnej przez Florę i in. [22], którzy zaproponowali następujące, bardziej skomplikowane równania:

– dla gruntów drobnoziarnistych, E'_n w MJ/m oraz q_c w MPa

$$D = D_{ref} \cdot \left(\frac{\alpha_E \cdot \Lambda^* \cdot E'_n}{7, 5 \cdot 10}\right)^{\beta} \cdot \left(\frac{q_c}{1, 5}\right)^{\delta}$$
(4a)

– dla gruntów gruboziarnistych, gdzie E'_n w MJ/m

$$D = D_{ref} \cdot \left(\frac{\alpha_E \cdot \Lambda^* \cdot E'_n}{7, 5 \cdot 10}\right)^{\beta} \cdot \left(\frac{N_{SPT}}{10}\right)^{\delta}$$
(4b)

gdzie:

 q_{c} – opór penetracji stożka w sondowaniu statycznym CPT (wyrażony w MPa),

 $N_{\rm \scriptscriptstyle SPT}$ – liczba uderzeń określonych podczas standardowego testu penetracji (SPT).

 Λ^* jest zależna od wskaźnika cementowo-wodnego Ω obliczonego na podstawie ciężaru medium tnącego ($\Lambda^* = 7,5$ dla $\Omega = 1,16$ dla strumienia wody systemu iniekcji potrójnej). Parametr α określa ilościowo efekt osłaniającego strumienia powietrza w systemie dwustrumieniowym oraz trójstrumieniowym (równy 1 dla systemu jednostrumieniowego, 6 dla systemu dwui trójstrumieniowego), parametry β i δ są wyznaczone na podstawie kalibracji danych z literatury oraz na podstawie doświadczeń własnych autorów ($\beta = 0,2$ oraz $\delta = -0,25$). Ostatecznie, parametr D_{ref} określa ilościowo rolę krzywej uziarnienia, równy 0,5 dla gruntów drobnoziarnistych, 0,8 dla gruboziarnistych bez frakcjami drobnymi oraz 1,0 dla gruntów gruboziarnistych bez frakcji drobnych.

Wpływ frakcji drobnych na opór ośrodka gruntowego na erozję jest potwierdzony przez Shena i in. [39], którzy określili odporność na erozję drobnych i grubych frakcji z uwzględnieniem różnych zmiennych, oraz dokonali korekty oporu gruntów gruboziarnistych przez uwzględnienie współczynnika zależnego od frakcji mniejszych od 75 mm.

Zaproponowane przez Shena i in. [39] oraz Florę i in. [22] metody przedstawiają najbardziej aktualne oraz kompletne narzędzia do predykcji średnicy kolumn iniekcyjnych. Jednakże, pomimo solidności przedstawionej koncepcji, metoda przedstawiona przez Shena i in. [39] nie jest bezpośrednia oraz łatwa do praktycznego zastosowania.

Z drugiej strony zależności przedstawione przez Florę i in. [22] są matematycznie mało skomplikowane oraz są kalibrowane na znacznie szerszym zbiorze danych (zmienne zawarte we wzorze (3) są relatywnie łatwe do określenia). Funkcję potęgowania we wzorach (4a) i (4b) rozszerzono na system iniekcji dwustrumieniowej i trójstrumieniowej bez jakiejkolwiek analizy zachodzących procesów fizycznych oraz skalibrowano w zakresie "standardowych" warunków (średnice, energie oraz opór ośrodka gruntowego użyte przez autorów nie są zbyt wysokie).

W artykule przeanalizowano możliwość zastosowania narzędzi do pozyskiwania danych w celu zwiększenia pewności predykcji oraz ograniczenia roli założeń wstępnych. Zależności pomiędzy średnicą kolumn, właściwościami ośrodka gruntowego oraz parametrami formowania są określane poprzez zastosowanie sztucznych sieci neuronowych (SSN). Stanowią one atrakcyjne rozwiązanie w celu określenia zachowania się skomplikowanego systemu [25] dzięki zdolności do gromadzenia zmiennych oraz ich wzajemnych relacji w celu aproksymacji uniwersalnych funkcji, zdolności do pomijania błędnych danych oraz odporności na brakujące dane eksperymentalne. Główną zasadą działania SSN jest budowa sieci powiązań pomiędzy przyczyną a skutkiem, podobnie jak ma to miejsce w ludzkim mózgu, np. uczenie się na podstawie wcześniejszych obserwacji i ich adaptacja w celu późniejszej reakcji. Ukryta korelacja pomiędzy zmiennymi wejściowymi a wyjściowymi jest określona poprzez proces uczenia kodu komputerowego przy wykorzystaniu zbioru obserwacji, który w uproszczony sposób naśladuje system nerwowy organizmów żywych.

Na przekór początkowo podejrzliwego i niechętnego nastawienia inżynierów, wynikającego głównie z charakteru SSN, który można nazwać "czarną skrzynką", były one z powodzeniem zastosowane do rozwiązania różnych problemów geotechnicznych, w tym m. in. do modeli konstytutywnych (np. [1]), nośności pali (np. [8]), analizy wstecznej złożonych systemów (np. [37]).

W przedstawianym przykładzie główne zasady działania oraz możliwości sztucznych sieci neuronowych scharakteryzowano wstępnie w celu zdefiniowania stopnia złożoności odpowiedniego dla niniejszej aplikacji SSN. Korzystając z wyżej przedstawionych studiów, określono zestaw podstawowych zmiennych w celu ilościowego oszacowania efektu iniekcji strumieniowej w prostej i kompletnej formie. Kolejno, w celu nauczenia SSN zebrano dużą liczbę danych eksperymentalnych z literatury, które uwzględniają system jedno-, dwu- i trójstrumieniowy dla różnych warunków gruntowo-wodnych. Różne możliwe struktury sieci neuronowych każdorazowo przetestowano w celu określenia poziomu jakości predykcji, znalezienia najbardziej efektywnych parametrów oraz porównania z alternatywnymi metodami.

SZTUCZNE SIECI NEURONOWE

Zasady podstawowe

Sztuczna sieć neuronowa (SSN) jest uproszczonym matematycznym opisem bardzo szerokiego i złożonego układu nerwowego organizmów żywych [32]. Przez analogię, głównym celem SSN jest naśladowanie zachowania się układu nerwowego, zaczynając bezpośrednio od obserwacji, np. bez narzuconych z góry ograniczeń. Kolejno, poprzez wykorzystanie połączeń pomiędzy wejściem a wyjściem może być ona użyta do predykcji przyszłych zjawisk. Cel ten jest osiągnięty poprzez opis zjawiska podlegającego analizie w postaci zmiennych wejściowych i wyjściowych oraz przez wybór najbardziej odpowiedniej architektury sieci oraz kolejno uczenia SSN przy wykorzystaniu wcześniej zgromadzonych obserwacji zjawiska, którego odpowiedź jest znana.

Jednostki obliczeniowe są zbudowane z neuronów, które przeprowadzają proste obliczenia. Każdy neuron przetwarza przychodzącą informację oraz kolejno przekazuje ją do następnego neuronu, jak przedstawiono to na rys. 1. Sygnał wejściowy x_i w pierwszej kolejności jest przemnażany przez wagę synaptyczną w_{ki} , kolejno wartość progowa w_{k0} jest dodana w celu wzmocnienia lub obniżenia znaczenia sygnału. Wszystkie przemnożone w ten sposób sygnały wejściowe przez odpowiadają-



Rys. 1. Budowa sztucznego neuronu

ce im wagi są zsumowane, następnie suma ta jest przetworzona przez uprzednio zdefiniowaną funkcję aktywacji, która określa zachowanie neuronu. Neurony, które tworzą sieć neuronową, są pogrupowane w sekwencję warstw; pierwsza warstwa służy do wprowadzenia zmiennych wejściowych. Jedna lub więcej warstw pośrednich (tzw. ukrytych) służy do przetwarzania danych, natomiast ostatnia warstwa zarządza zmiennymi wyjściowymi. Warstwy ukryte w zależności od studiowanego problemu mogą być pogrupowane w różny sposób zależny od wybranej architektury sieci neuronowej. Od pierwszej i prawdopodobnie najprostszej architektury – sieci jednokierunkowej, gdzie informacje są przekazywane tylko w jednym kierunku bez cykli oraz pętli, aż po różnorodne znaczniej bardziej złożone algorytmy (np. sieci radialne, sieci rekurencyjne itp.) przeznaczone do opisywania bardziej złożonych związków pomiędzy zmiennymi.

Architektura użytej SSN

Średnica kolumny wykonanej przy użyciu iniekcji strumieniowej jest zależna od szeregu parametrów technologicznych oraz od właściwości ośrodka gruntowego. Bazując na liście zmiennych, przedstawionych na rys. 2, można wywnioskować, że jest możliwa duża liczba kombinacji. Dane eksperymentalne potrzebne do ustalenia zależności powinny odtworzyć możliwie wiele warunków w celu ustalenia zależności średnicy od różnych zmiennych oraz ich wzajemnych powiązań. Pomimo coraz większej ilości artykułów ostatnio opublikowanych przez różnych autorów dostępność szczegółowych danych w dalszym ciągu nie jest duża i wystarczająco udokumentowana.

W celu uproszczenia struktury sieci neuronowej oraz w celu uzyskania maksimum korzyści z dostępnych informacji zredukowano liczbę zmiennych wejściowych (rys. 2). Zaczynając od parametrów technologicznych iniekcji strumieniowej, pominięto prędkość obrotową monitora. Prędkość ta ma wpływ na niejednorodność strumienia medium, jednakże ma ona stosunkowo niewielki wpływ na wymiar kolumny. Inne zmienne nazwane odpowiednio: prędkość iniekcji v_0 oraz gęstość ρ , liczba *M* oraz średnica *d* dyszy, a także prędkość podciągania monitora v_r połączono w uprzednio zdefiniowaną energię u wylotu dyszy (E'_n zdefiniowana przez wzór (2)). Zmienne te, których podstawową rolę przeanalizowało kilku różnych autorów [17, 22] mają wiele zalet uwzględniających możliwość ich przedstawienia w prostszej formie uwzględniającej rolę wyżej wymienionych zmiennych. Dodatkowo, za pomoca wzoru (3), korzystając z ciśnienia oraz prędkości przepływu w pompie, można w łatwy sposób określić rolę wymienionych zmiennych.

Ostatni aspekt dotyczący iniekcji strumieniowej to rola strumienia powietrza otaczającego medium tnące w systemie dwui trójstrumieniowym. W artykule jego rolę uwzględniono przez proste rozróżnienie na system jedno-, dwu- i trójstrumieniowy, np. uwzględniając system iniekcji jako dodatkową zmienną wejściową do sieci neuronowej. W ten sposób uwzględniono obecność powietrza jako zmienną "włączona-wyłączona", bez wprowadzania zależności od prędkości przepływu (lub ciśnienia) strumienia powietrza, co z drugiej strony wiadomo, że jest istotnym aspektem [39].

Rolę ośrodka gruntowego uwzględniono przez rozróżnienie pomiędzy gruntem drobnoziarnistym i gruboziarnistym oraz podzielenie drugiej kategorii na dwie mniejsze (gruboziarnisty z frakcjami drobnymi i bez frakcji drobnych), zależne od ewentualnej obecności frakcji drobniejszej w gruncie gruboziarnistym. Założenie to postawiono w odniesieniu do analiz Modoniego i in. [35], którzy zaobserwowali różne mechanizmy tnace gruntów spoistych i niespoistych oraz zauważyli redukcję możliwości erozyjnej strumienia w gruntach gruboziarnistych wskutek obecności frakcji drobnych [22, 39]. We wszystkich wymienionych przypadkach opór ośrodka gruntowego na strumień iniektu określono jako liczbę uderzeń podczas standardowego testu penetracji N_{SPT}. Chociaż parametr ten nie reprezentuje najlepszej możliwej opcji dla gruntów spoistych, wykorzystanie jednakowego (unikalnego) wskaźnika opisującego opór dla wszystkich rodzajów gruntu był podyktowany potrzebą uproszczenia struktury sieci neuronowej (liczba zmiennych wejściowych).

Uwzględniając wszystkie te uproszczenia, warstwa wejściowa jest scharakteryzowana przez cztery zmienne, dwie charakteryzują parametry technologiczne iniekcji (system iniekcji oraz E'_n), dwie pozostałe (rodzaj gruntu oraz N_{SPT}) określają wpływ ośrodka gruntowego (rys. 2).

Użyta architektura sztucznej sieci neuronowej jest określona jako sieć jednokierunkowa z jedną unikalną warstwą ukrytą. Wyboru tego, który pozwala na zauważalne uproszczenie algorytmu obliczeniowego [30], dokonano, biorąc pod uwagę fakt, że współczynniki (właściwości ośrodka gruntowego oraz parametry technologiczne iniekcji strumieniowej) są niezależne od siebie. Jako funkcję aktywacji wybrano funkcję sigmoidalną zdefiniowaną w bazie użytego kodu komputerowego [3], której użyto w celu scharakteryzowania zachowania się neuronów, gdyż cechuje się ona stale dodatnią pochodną oraz jej zastoso-



Rys. 2. Architektura użytej sztucznej sieci neuronowej

wanie powoduje uniknięcie niestabilnej konwergencji problemu.

Liczbę neuronów w warstwie ukrytej oraz podział danych uczących na dane użyte do kalibracji i walidacji określono na podstawie analizy parametrycznej, np. poprzez przeprowadzenie analizy z różnymi kombinacjami powyższych parametrów oraz sprawdzeniu, która daje najlepszą jakość predykcji. korelacje zaproponowane przez Lunne i in. [28] były użyte do przejścia z niezdrenowanej wytrzymałości na ścinanie, wyznaczonej w testach laboratoryjnych, na wartość oporu stożka sondy CPT. Korelacji zaproponowanych przez Robertsona i in. [38] oraz Ismael i Jeragh [26] użyto do przejścia z danych uzyskanych z CPT na wartości SPT.

UCZENIE SZTUCZNYCH SIECI NEURONOWYCH

Dane eksperymentalne

Zdefiniowaną sztuczną sieć neuronową nauczono na podstawie 131 obserwacji zgromadzonych z literatury, które są przedstawione w tabl. 1 ÷ 3. Każdy z rozważanych przypadków odnosi się do badań polowych, których właściwości ośrodka gruntowego (uziarnienie oraz wytrzymałość na ścinanie), parametry technologiczne iniekcji strumieniowej (w dyszy badź w pompie) oraz średnice kolumn określono. W odniesieniu do wcześniej opisanej struktury sieci neuronowej dane podzielono na trzy główne kategorie: dla systemu iniekcji jednostrumieniowej (50 danych w tabl. 1), dwustrumieniowej (43 dane w tabl. 2) oraz trójstrumieniowej (38 danych w tabl. 3). W każdej z tablic wzmocnienie ośrodka gruntowego przeprowadzono w gruntach drobnoziarnistych, gruboziarnistych z frakcją drobną (lub bez frakcji drobnej), dla każdego przypadku określając: energię w dyszy, zmierzoną średnicę oraz liczbę uderzeń podczas testu SPT. W niektórych przypadkach ostatnią wielkość określili bezpośrednio autorzy, w pozostałych przypadkach określono, wykorzystując zależności podane w literaturze. W szczególności

Optymalizacja architektury sztucznej sieci neuronowej

Przy definicji sztucznej sieci neuronowej istnieje pewien margines swobody. W szczególności liczby neuronów tworzących warstwę ukrytą oraz podział danych do uczenia na dane do kalibracji i walidacji jeszcze nie zdefiniowano. W celu rozwiązania tego problemu bez wprowadzania subiektywnych założeń oraz w celu optymalizacji jakości predykcji, sprawdzono różne możliwe rozwiązania, aby znaleźć najbardziej optymalne zestaw parametrów, które dają najmniejszą różnicę pomiędzy wartościami przewidzianymi a zmierzonymi.

Dla każdej próby określono poziom korelacji pomiędzy pomierzonymi a przewidzianymi wartościami, porównując każdą n zmierzoną średnicę z tabl. 1 ÷ 3 z wartością przewidzianą odpowiadającym zmiennym wejściowym (parametry technologiczne iniekcji oraz właściwości ośrodka gruntowego) nauczonej sieci neuronowej na pozostałych (n - 1) danych. Ostatecznie błąd średniokwadratowy *MSE* (ang. *Mean Squared Error*) obliczono w następujący sposób, aby zapewnić wskaźnik opisujący jakość predykcji:

$$MSE = \frac{1}{n} \sum_{i=1}^{n} (D_{i_{przewidziane}} - D_{i_{przewidziane}})^{2} [m^{2}]$$
(5)

Tabl. 1. Dane wykorzystane do uczenia sieci neuronowej (system iniekcji jednostrumieniowej)

# Zódós Sudum przyskalu Narwag puntu Kławig puntu <t< th=""><th></th><th colspan="2">4</th><th></th><th></th><th>Energia u wylotu dyszy</th><th>Średnica</th></t<>		4				Energia u wylotu dyszy	Średnica			
1 Burnot i Santaro [0] Ru Matzari (Whichy) Participacesepsy SW 106 CP 10 4.2 0.0 3 Cocci in [17] Rarcelona (Hiopania) Participacesepsy SW 106 CP 20 1.3 0.9 7 Cocci in [17] Rarcelona (Hiopania) piack 2wirowy SW 106 CP 20 1.3 0.9 7 Cairsano (Wochy) Treato (Wochy) pinek 2wirowy SM 10< CP	#	Zródło	Studium przypadku	Nazwa		a gruntu	Klasyfikacja USCS	N_{SPT}	$ \begin{array}{c} E'_n \\ [MJ/m] \end{array} $	<i>D</i> _{<i>a</i>} [m]
2 Croce in [15] Polescen (Whedy) 2 14.6 12.0 14.6 1.0 4 Second (Hispania) Paradon (Micchy)	1	Bianco i Santoro [6]	Rio Matzeu (Włochy)			żwir piaszczysty		10	8,2	0,97
3 Color Col	2	Croce i in [15]	Polcevera (Włochy)			zagęszczony	GW lub GP	20	14,6	1,20
4 6 6 6 7 7 Croce i in [17] 7 Barcelona (lisepana) br refacij 0 br refacij 0 br refacij 0 br	3		Toleevera (Wideliy)			żwir piaszczysty		20	13,2	1,10
3 3 20 <td>4</td> <td></td> <td></td> <td></td> <td></td> <td></td> <td></td> <td>34</td> <td>16,8</td> <td>0,84</td>	4							34	16,8	0,84
2 Control 1 International (International) 1	5	Croce i in [17]	Barcelona (Hisznania)		bez	niasek żwirowy	SW lub SP	28	20.3	0,76
8 0 34 29.4 1.04 9 Flora in .[2] Caivano (Wlocky) Treato (Wlocky) Tre	7	7	Dareciona (miszpania)		frakcji drobnej	plasek Zwiłówy	5 W 100 51	23	20,5	1.08
9 10 Cavano (Wlochy) rank 11 10.9 1.11 10 Tenio (Whochy) rank Milel SP 2.8 1.5.2 1.00 11 Pack Aurony SM leb SP 2.8 1.5.2 1.00 12 Pack Aurony SM leb SP 2.8 0.66 0.66 13 Pack Aurony SM leb SP 1.5 1.5.4 0.69 14 Pack Aurony Pack Aurony 1.5 1.5.4 0.69 15 1.5.4 0.69 1.5 1.5.4 0.69 16 Pack Machy Pack Machy 1.5 1.5.4 0.69 16 Pack Machy Pack Machy 1.5 1.5.4 0.69 18 Pack Machy Pack Machy 1.5 1.5.4 0.60 18 Pack Machy Pack Machy 1.5 1.5.4 0.60 12 Case Intima (Wachy) Pack Machy 1.5 1.5 1.5 0.5.4 12 Case Intima	8				urcondj			34	29,4	1,04
101 101 Trento (Wlochy) gruno- starnisty plasek 2wirowy SM hb SW 28 15.2 1.00 111 15 9 0.66 131 Cocc i Flora [11] Vesavio (Wlochy) r faceja 15 15 15 15 0.96 16 Namilo P. (A (Wlochy) r faceja 16 15 18.8 0.96 17 Tornaghi S. Benedetto (Wlochy) r faceja 200 201 16 15 18.4 0.60 18 7.4 0.60 18 7.4 0.60 20 Flora in (22) Castellamare (Wlochy) 201 201 113 11.5 0.83 21 Flora in (22) Castellamare (Wlochy) Singnur SM 10 0.71 0.30 22 Incass (Wlochy) Singnur Indep (N) Singnur 10 0.63 10 0.63 23 Greace in [17] Singgur Indep (N) Sin	9	Flora i in [22]	Caivano (Włochy)			piroklastyczny pył i piasek żwirowy	SM	14	16,9	1,11
11 12 13 13 14 14 15 Croce i Flora [11] Vesuvio (Wlochy) Vesuvio (Wl	10	1 Ioiu I III. [22]	Trento (Włochy)	grubo-		piasek żwirowy i pył żwirowy	SM lub SP lub SW	28	15,2	1,00
12 14 14 15 Croce i Flora [11] Vesuvio (Wlochy) Vesuvio (Wlochy) 2 15 15.8 0.60 16 S. Beredento (Wlochy) Vesuvio (Wlochy) 15 13.4 0.60 16 Vesuvio (Wlochy) Vesuvio (Wlochy) 15 13.4 0.60 17 S. Beredento (Wlochy) Vesuvio (Wlochy) 15 13.3 0.71 19 i Petimaroli [20] Maralio E. (A) (Wlochy) 2 18 14.4 0.70 10 Croce i In [11] Maralio E. (Mlochy) 10 21.6 0.78 11 Pitos E. (Plasty) Pitos Plasty 10 11.6 0.63 12 Flora in [22] Castellamare (Wlochy) Singapur 2 10 7 0.39 23 Tornaghi Veralio P. (D) (Wlochy) Singapur 2 10 7 0.39 24 iPetimorol [42] Singapur Veralio P. (D) (Wlochy) 13 10 7 0.30 25 Oneo Nit (Algeria) Netret Plasty Plaisysty <td< td=""><td>11</td><td></td><td></td><td>ziarnisty</td><td></td><td></td><td></td><td>15</td><td>9</td><td>0,66</td></td<>	11			ziarnisty				15	9	0,66
13 16 16 16 16 16 16 16 16 16 16 16 16 16	12					· 1	CUV CM	15	18,8	0,96
11 15 13 0.71 16 15 13.3 0.71 17 Tornaghi Varallo P. (A) (Wlochy) 15 23.5 0.69 18 Tornaghi Varallo P. (A) (Wlochy) 18 7.4 0.60 19 Petrinaroli [42] Castellamare (Wlochy) 20 18 7.4 0.60 20 Tornaghi Mazzo (Wlochy) piask pylasty 18 14.4 0.71 21 Flora i in [22] Castellamare (Wlochy) piask pylasty 10 21.6 0.78 22 Tornaghi Varallo P. (B) (Wlochy) Singapar piask pylasty 10 21.6 0.78 23 Tornaghi Varallo P. (B) (Wlochy) Singapar miskchoptasyczny pylasty 10.4 0.61 26 Qued Nil (Algeria) Singapar 10 7.2 0.40 31 11.5 0.43 0.42 10 7.7 0.47 27 7 7 0.47 0.50 10	13	Croce i Flora [11]	Vesuvio (Włochy)			zagęszczony piasek pylasty i żwirowy	SW-SM lub SP-SM	15	13,4	0,09
16 0 0 15 23,5 0.95 17 17 13 15 23,5 0.95 19 iPetinaroli [20] Varallo P. (A) (Wlochy) Zavi z piaskiem Natskiem Natskiem <td< td=""><td>15</td><td></td><td></td><td></td><td></td><td>15</td><td></td><td>15</td><td>13,3</td><td>0,71</td></td<>	15					15		15	13,3	0,71
17 S. Bendetto (Wicely) Varial 0 P (A) (Wicely) Mazz (Wicely) Casilmatice (Wicely) doba Mazz (Wicely) Casilmatice (Wicely) doba Singapu bit marginal pisack pylasy pisaty pisaty pisaty S. Bendetto (Wicely) (Mazz (Wicely) Disaty pisaty pisaty S. Bendetto (Wicely) (Mazz (Wicely) Disaty pisaty pylasy pisaty S. Bendetto (Wicely) (Mazz (Wicely) (Mazz (Wicely)) doba Singapu disaty pisaty pisaty pisaty S. Bendetto (Wicely) (Mazz (Wicely) (Mazz (Wicely)) Mazz (Wicely) (Mazz (Wicely) Maz (Wicely) (Maz (Wicely) Mazz (Wi	16				z frakcją			15	23,5	0,95
18 Tornaghi i Pettinaroli [42] Varallo P. (A) (Wlochy) Casalmaioeco (Wlochy) Paze? (Wlochy) picksty piroklastyczny piask plasty SM ub GC-GM 18 14,4 0,70 21 Flora i in. [22] Castellamare (Wlochy) plasty mic Second plasty 13 11,5 0,83 22 Arczzo (Wlochy) Yanallo P. (B) (Wlochy) rezzo (Wlo	17		S. Benedetto (Włochy)		drobną	luźny piasek pylasty		8	7,2	0,69
19 17 ethnaroi 18 14,4 0,70 20 Casalmaioco (Wochy) piasck pylasty 10 21.6 0,78 21 Flora in [22] Casalmaioco (Wochy) piasck pylasty 10 21.6 0,78 22 Arczo (Wochy) Varalo P. (B) (Wochy) piasck pylasty 13 11,5 0,39 24 i Petinaroli [42] Varalo P. (B) (Wochy) Singapur 20 1.0 0,72 0,39 25 Oued Nil (Algeria) piskkem? 10 9.7 0,39 26 mickkoplastyczny pilasty mickkoplastyczny 10 0,7 0,39 27 Qued Nil (Algeria) varty pyl piasty 10 7.2 0,40 30 Martine P. (B) (Wochy) Singapur ister pylasty 10 7.2 0,40 31 Good Nil (Algeria) Singapur ister pylasty 10 7.2 0,40 32 Singapur Martine Pylasty 10 7.7 0,42 33 <t< td=""><td>18</td><td>Tornaghi</td><td>Varallo P. (A) (Włochy)</td><td></td><td></td><td>żwir z piaskiem</td><td></td><td>18</td><td>7,4</td><td>0,60</td></t<>	18	Tornaghi	Varallo P. (A) (Włochy)			żwir z piaskiem		18	7,4	0,60
20 Casamaceo (Woony) piaske pylasky noo 60 km 10 21,6 0,78 21 Flora in [22] Castellamare (Woohy) if if if 0.63 if 0.63 if 0.78 0.78 22 Arczzo (Wlochy) Arczzo (Wlochy) if if if 0.63 if 0.63 0.63 24 i Petinaroli [42] Singapur Qued Nil (Algeria) if if 0.64 0.7 0.39 25 Qued Nil (Algeria) Qued Nil (Algeria) if 0.66.7 0.39 26 Mickoplastyczny pyliasty if 0.66.7 0.39 27 Qued Nil (Algeria) Arczer (Moone) if 0.66.7 0.39 30 Grossen in [17] Barcelona (Hiszpania) drobnoziamisty if if 0.66.7 0.39 33 Grossen in [17] Barcelona (Hiszpania) drobnoziamisty if if 0.43 0.43 36 Grossen in [17] Barcelona (Hisz	19	1 Pettinaroli [42]	Mazzè (Włochy)			pylastym	SM lub GC-GM	18	14,4	0,70
21 Flora i in. [22] Castellamare (Wiecly) Int. 5 0.83 22 Narezzo (Wiecly) Varallo P. (B) (Wiecly) platwarty py liasty Narezzo (Wiecly) Int. 5 0.63 23 Tornaghi i Petimaroli (42) Varallo P. (B) (Wiecly) Singapur Int. 5 0.63 26 Qued Nil (Algoria) Qued Nil (Algoria) Platyczny il pylasty Niekonastyczny 2 10.8 0.64 27 Qued Nil (Algoria) Pistyczny il pylasty Niekonastyczny 2 10.8 0.64 28 Force i in. [17] Barcelona (Hiszpania) drobnoziarnisty Ind 7 0.47 0.39 33 Gorce i in. [17] Barcelona (Hiszpania) drobnoziarnisty ii Ind 7.7 0.47 34 Ind Ind 7.7 0.47 0.59 35 Ind Ind Ind 7.7 0.47 36 Ind Ind Ind 0.40 13 0.40 37 Croce i in. [17]	20		Casalmalocco (włocny)			plasek pylasty		10	21,6	0,78
22 Arczzo (Włochy) Varalio P. (B) (Włochy) Zwarty pyl piaszczysty 1 1 0.63 24 i Pettinarol [42] Qued Nil (Algeria) Zwarty pyl piaszczysty 1 0 0.9 26 Qued Nil (Algeria) Qued Nil (Algeria) 1 0 9.7 0.39 27 Qued Nil (Algeria) Więktopiastyczny pyl ilasty 10 9.7 0.39 29 30 Groce i in. [17] Barcelona (Hiszpania) drobnoziarnisty 10 9.7 0.39 31 Groce i in. [17] Barcelona (Hiszpania) drobnoziarnisty ii 10 7.7 0.43 33 36 Ii Ii 0.7 0.43 36 Ii Iii 0.42 10 7.7 0.43 36 Iii Ii	21	Flora i in. [22]	Castellamare (Włochy)			pylasty		13	11,5	0,83
23 Tornaghi Varallo P. (B) (Wlochy) Sampur CL-ML 7 5,9 0,39 0,39 0,39 0,39 0,39 0,39 0,39 0,39 0,39 0,39 0,39 0,39 0,39 0,39 0,39 0,63 0,63 0,63 0,63 0,64 0,65 0,64 0,65 0,64 0,65 0,64 0,64 0,65 0,64 0,65 0,64 0,64 0,65 0,64 0,64 0,65 0,64 0,65 0,64 0,64 0,65 0,64 0,64 0,65 0,64 0	22		Arezzo (Włochy)			z piaskiem		3	14,4	0,63
24 1 Pertunation [42] Singapur plastyczny i pylasty 100 ML 3 9 0,63 25 Qued Nil (Algeria) miękkoplastyczny pył liasty 2 10,8 0,64 26 niękkoplastyczny pył liasty 10 9,7 0,39 28 10 6,7 0,39 29 10 6,7 0,39 30 10 7,2 0,40 31 10 7,2 0,40 32 10 7,4 0,50 33 10 7,4 0,50 34 15 9,3 0,43 35 10 7,7 0,47 15 9,3 0,43 36 15 9,3 0,43 37 Croce in [17] Barcelona (Hiszpania) il Ibd CL-ML 13 16,4 0,57 38 39 13 16,2 0,43 13 16,2 0,43 41 13 12,6 0	23	23Tornaghi24i Pettinaroli [42]	Varallo P. (B) (Włochy)			zwarty pył piaszczysty	CL-ML	7	5,9	0,39
25 Qued Nil (Algeria)	24		Singapur			plastyczny ił pylasty	IUD MIL	3	9	0,63
26 10 9,7 0,39 27 10 7 0,39 28 10 7 0,39 29 10 6,7 0,39 30 10 7,2 0,40 31 10 7,4 0,50 32 10 7,4 0,50 33 10 7,7 0,47 34 15 9,4 0,40 35 10 7,7 0,47 15 9,4 0,40 15 9,4 0,40 15 9,4 0,40 15 9,4 0,40 15 9,4 0,40 15 9,3 0,43 16 15 9,3 0,43 16 13 16,4 0,57 13 16,4 0,57 13 16,2 0,43 13 16,4 0,53 13 16,4 0,53 <td>25</td> <td></td> <td>Qued Nil (Algeria)</td> <td></td> <td></td> <td>miękkoplastyczny pył ilasty</td> <td></td> <td>2</td> <td>10,8</td> <td>0,64</td>	25		Qued Nil (Algeria)			miękkoplastyczny pył ilasty		2	10,8	0,64
27 10 7 0,38 28 10 6,7 0,39 29 10 6,7 0,39 30 10 7,2 0,40 31 10 7,4 0,50 32 10 7,6 0,33 33 10 7,6 0,30 34 10 7,7 0,47 35 10 7,7 0,47 36 15 9,4 0,40 37 Croce in. [17] Barcelona (Hiszpania) ii 15 9,3 0,43 38 10 7,7 0,47 0,50 0,49 0,40 38 15 9,3 0,43 0,50 0,43 0,50 39 13 16,4 0,57 0,49 0,50 0,44 0,53 40 13 12,2 0,40 0,41 0,43 0,50 41 13 11,2 0,41 0,43 0,43 0,43 42 13 12,2 0,40 0,41 0,43 <td>26</td> <td></td> <td></td> <td></td> <td></td> <td></td> <td></td> <td>10</td> <td>9,7</td> <td>0,39</td>	26							10	9,7	0,39
28 10 6,7 0,39 30 31 10 7,2 0,40 31 10 7,2 0,40 32 33 10 7,4 0,50 34 10 7,7 0,47 35 10 7,7 0,47 36 15 9,4 0,40 37 6 15 9,4 0,40 38 15 9,4 0,40 39 15 9,4 0,40 16 9,4 0,40 17 0,43 15 9,4 39 15 15,9 0,49 13 16,4 0,57 13 15,2 0,59 13 21,6 0,54 13 21,6 0,53 13 12,2 0,40 13 12,2 0,40 13 21,6 0,53 13 12,2 0,40	27							10	7	0,38
29 10 7,2 0,40 30 10 7,2 0,40 31 1 10 9,8 0,42 31 1 10 7,4 0,50 33 1 10 7,6 0,53 34 33 1 10 7,7 0,47 35 10 7,7 0,47 36 15 9,4 0,40 37 Croce i in [17] Barcelona (Hiszpania) 16 15 9,4 0,40 38	28							10	6,7	0,39
30 31 31 33 33 33 34 35 36 37 37 36 37 37 38 36 39 37 38 36 39 37 39 39 40 41 41 32 42 33 43 44 45 44 45 44 45 13 49 Davie [19] Turcja	29							10	7,2	0,40
31 33 32 33 33 34 34 34 35 36 36 37 37 Barcelona (Hiszpania) 38 15 39 15 39 13 40 13 41 13 42 13 43 13 44 13 44 13 44 13 44 13 44 13 44 13 44 13 44 13 44 13 44 13 44 13 44 45 13 46 13 47 13 48 13 49 Davie [19] 49 Davie [19]	30							10	9,8	0,42
32 33 34 35 36 37 38 39 39 40 41 42 43 44 45 44 45 44 45 49 Davie [19] 49 Davie [19]	31							10	7,4	0,50
33 34 34 35 36 36 37 6 38 15 39 15 39 15 40 15 41 13 42 13 43 20 44 13 44 13 45 13 46 13 47 13 48 13 49 Davie [19] Turcja	32							10	7,6	0,53
34 35 36 15 9,4 0,40 35 36 15 9,3 0,43 37 Croce i in. [17] Barcelona (Hiszpania) ił 11 15 9,3 0,43 38 39 13 16,4 0,57 13 15,2 0,59 13 20,6 0,64 13 21,6 0,54 13 21,6 0,53 13 21,6 0,54 13 21,6 0,54 13 21,6 0,54 13 21,6 0,53 13 21,6 0,53 13 21,6 0,53 13 21,6 0,53 13 21,6 0,53 13 21,6 0,53 13 11,2 0,44 13 21,2 0,40 13 21,6 0,53 13 21,2 0,40 13	33							10	7,7	0,47
35 36 36 37 37 Croce i in. [17] 38 39 40 13 40 13 41 13 42 13 43 13 44 13 44 13 45 13 46 13 47 13 48 13 49 Davie [19] Turcja	34							15	9,4	0,40
36 37 Croce i in. [17] Barcelona (Hiszpania) if 15 15,9 0,49 38 39 13 16,4 0,57 39 40 13 15,2 0,59 40 13 21,6 0,54 41 13 21,6 0,54 42 13 16,2 0,45 43 13 16,2 0,44 44 13 21,6 0,53 44 13 11,2 0,44 45 13 12,2 0,40 46 13 20,3 0,47 47 13 11,7 0,40 48 13 9,6 0,43 49 Davie [19] Tureja ił zwarty CL-ML lub 4 13,4 0,63	35							15	9,3	0,43
37 Croce i in. [17] Barcelona (Hiszpania) ii Ii Iii Iiii Iiii Iii Iii	36			urobiloz	lannsty		CI	15	15,9	0,49
38 39 13 15,2 0,59 39 13 20 0,64 40 13 21,6 0,54 41 13 28,9 0,50 42 13 16,2 0,45 43 13 11,2 0,44 45 13 21,6 0,53 44 13 12,2 0,40 45 13 12,2 0,40 46 13 20,3 0,47 47 13 11,7 0,40 48 13 9,6 0,43 49 Davie [19] Turcja ił zwarty CL-ML lub 4 13,4 0,63	37	Croce i in. [17]	Barcelona (Hiszpania)			ił	lub CL-ML	13	16,4	0,57
39 13 20 0,64 40 13 21,6 0,54 41 13 28,9 0,50 42 13 16,2 0,45 43 13 21,6 0,53 44 13 21,6 0,53 44 13 21,2 0,44 45 13 11,2 0,44 45 13 12,2 0,40 46 13 20,3 0,47 47 13 11,7 0,40 48 13 9,6 0,43 49 Davie [19] Turcja ił zwarty CL-ML lub 4 13,4 0,63	38						lub CH	13	15,2	0,59
40 13 21,6 0,54 41 13 28,9 0,50 42 13 16,2 0,45 43 13 21,6 0,53 44 13 21,6 0,53 44 13 11,2 0,44 45 13 12,2 0,40 46 13 20,3 0,47 47 13 11,7 0,40 48 13 9,6 0,43 49 Davie [19] Turcja ił zwarty CL-ML lub 4 13,4 0,63	39							13	20	0,64
41 13 28,9 0,50 42 13 16,2 0,45 43 13 21,6 0,53 44 13 11,2 0,44 45 13 12,2 0,40 46 13 12,2 0,40 47 13 11,7 0,40 48 13 9,6 0,43 49 Davie [19] Turcja ił zwarty CL-ML lub 4 13,4 0,63	40							13	21,6	0,54
42 13 16,2 0,45 43 13 16,2 0,45 13 21,6 0,53 13 11,2 0,44 45 13 12,2 0,40 46 13 20,3 0,47 47 13 11,7 0,40 48 13 9,6 0,43 49 Davie [19] Turcja ił zwarty CL-ML lub 4 13,4 0,63	41							13	28.9	0.50
43 13 21,6 0,53 44 13 21,6 0,53 13 11,2 0,44 13 12,2 0,40 13 12,2 0,40 13 12,2 0,40 13 11,7 0,40 13 11,7 0,40 13 9,6 0,43 49 Davie [19] Turcja ił zwarty CL-ML lub 4 13,4 0,63	42							13	16.2	0.45
44 13 11,2 0,44 45 13 11,2 0,44 46 13 12,2 0,40 47 13 11,7 0,40 48 13 9,6 0,43 49 Davie [19] Turcja ił zwarty CL-ML lub 4 13,4 0,63	43							13	21.6	0.53
45 13 11,2 0,44 46 13 12,2 0,40 47 13 11,7 0,40 48 13 9,6 0,43 49 Davie [19] Turcja ił zwarty CL-ML lub 4 13,4 0,63	44							13	11.2	0.44
10 13 12,2 0,40 46 13 20,3 0,47 47 13 11,7 0,40 48 13 9,6 0,43 49 Davie [19] Turcja ił zwarty CL-ML lub 4 13,4 0,63	45							13	12.2	0.40
13 20,3 0,47 47 13 11,7 0,40 48 13 9,6 0,43 49 Davie [19] Turcja ił zwarty CL-ML lub 4 13,4 0,63	46							13	20.3	0.47
13 11,7 0,40 48 13 9,6 0,43 49 Davie [19] Turcja ił zwarty CL-ML lub 4 13,4 0,63	47							13	11 7	0.40
10 13 2,0 0,43 49 Davie [19] Turcja ił zwarty CL-ML lub 4 13,4 0,63	48							13	96	0.43
12 Darie [17] 110/4 0,05	40	Davie [10]	Turcia			ił zwarty	CLARTI	4	13.4	0.63
50 Bianco i Santoro [6] Rio Matzeu (Włochy) pył piaszczysty CH lub MH 10 92 052	50	Bianco i Santoro [6]	Rio Matzeu (Włochy)			pył piaszczysty	CH lub MH	10	9.2	0.52

Tabl. 2. D	ane '	wykorzystane	do uczenia	sieci neu	ronowei	(system	iniekcii	dwustrur	nieniowei)
1401. 2. 0	unc	"JHOI 2J Stuffe	uo uezennu	Sieci neu	i ono nej -	(b) been	meneji	a maser ar	memo (, ej)

щ.	Źródła	Studium merumodlar			Energia u wylotu dyszy	Średnica			
#	210010	Studium pizypadku		Nazw	a gruntu	Klasyfikacja USCS	$N_{_{SPT}}$ [-]	E'_n [MJ/m]	D _a [m]
51	Modoni i Bzówka [34]	Bojszowy Nowe (Polska)			piasek	SW lub SP	25	4,5	0,80
52							50	17,2	1,00
53		Biandrate (Włochy)		bez	piasek żwirowy i żwir piaszczysty	SW lub SP	50	18,7	1,00
54	Flora i in. [22]			frakcji	philozozysty	lub GW lub	50	21,5	1,00
55				drobnej	piroklastyczny pył	GP lub SM	14	16,1	1,50
56		Calvano (włocny)			i piasek żwirowy		14	21,2	1,70
57	Mauro i Santillan [31]	Kansas (USA)			piasek średni i piasek żwirowy	SW lub SP	24	155	2,30
58							8	18	1,40
59					luźny piasek pylasty		8	24	1,40
60							8	31	1,50
61							10	20,7	1,21
62							10	19,8	1,19
63					piasek pylasty		10	35,1	1,30
64							10	36,9	1,31
65							10	13,5	1,28
66	Tornaghi i Pettinaroli [42]	Casalmaicco (Włochy)	grubo- ziarnisty				10	31,5	1,44
67							10	18,9	1,45
68	8 9 0 1 2						10	34,2	1,63
69							10	34,2	1,69
70							10	40,5	1,67
71							10	73,8	1,93
72				z frakcją		SM .	10	29,7	1,98
73				drobną		SIM	10	62,1	2,04
74							10	30,6	2,17
75							13	9,1	0,90
76							13	17,5	1,20
77							13	15,6	1,20
78							13	20,4	1,40
79	Flora i in. [22]	Castellamare (Włochy)			piroklastyczny piasek pylasty		13	30,3	1,80
80					Ţ, J. W. J		13	42,1	1,60
81							13	49,8	1,80
82							13	26,6	1,80
83							13	49,6	1,80
84							3	7,20	0,95
85	Durgunoglu i in.	Izmir (Tursis)			niacol: nulocti		3	8,80	1,10
86	[20]				plasek pylasty		3	8,50	1,05
87							3	7,20	1,10
88	Tornaghi i Pettinaroli [42]	Venezia (Włochy)			plastyczny pył ilasty		5	18	0,85
89							9	22,2	0,61
90		Pologna (Witz-h-)	drobnoz	ziarnistv	plasty army it 1+	CL lub CL-ML lub	9	26,2	1,02
91	Flora i in. [22]	Bologna (włocny)	aroonoziarnisty		ріазтустну и ругазту	CH lub MH	9	29,8	0,91
92							9	29,8	0,70
93		Sarno (Włochy)			plastyczny ił		7	31,6	0,80

Tabl. 3.	Dane	wykorzystan	e do uczeni	a sieci	neuronowej	(system	iniekcji	trójstrun	nieniowej)
						(~)~		- •J	

щ	Źródła	Studium provinciality			Energia u wylotu dyszy	Średnica			
#	210010	Suunum ріzурацки		Nazwa gruntu			N_{SPT} [-]	E'_n [MJ/m]	D _a [m]
94	Mauro, Santillan				piasek średni i piasek		24	150	3,20
95	[31]	Kansas (USA)		1	żwirowy	CW11 CD	24	270	3,50
96				frakcji		lub SW lub	2	33,5	1,17
97	Nikbakhtan i Osanloo [36]	Shahriar Dam (Iran)		drobnej	piasek i żwir	SP	2	66,8	1,31
98	1 opunice [20]						2	43,2	1,13
99							8	85	1,90
100							8	42	1,65
101							8	25	1,63
102							8	31	1,50
103							8	22,5	1,50
104	Tornaghi					SM lub SW-SM lub	8	22,5	1,22
105	i Pettinaroli [42]	S. Benedetto (Włochy)			lužny piasek pylasty		8	20	1,48
106			grubozi-				8	13	1,45
107			arnisty	z frakcją drobną			8	18	1,60
108	_						8	18	1,40
109							8	15	1,30
110						SP-SM	8	12	1,10
111	Stark i in. [40]	Manhattan, Kansas (USA)			piasek pylasty i piasek średni		12	220	3,00
112					piasek pylasty		10	97	2,32
113		[42] Casalmaiocco (Włochy)					10	97	2,28
114	Tornaghi i Pettinaroli [42]						10	98	2,25
115							10	98	2,02
116							10	87	2,07
117					pył piaszczysty oraz piasek pylasty		33	55,1	2,00
118	Shen i in. [39]	Shanghai (Chiny)					33	63	2,20
119							33	54,7	2,30
120							5	33.5	1,16
121							5	90.2	1,35
122	Nikbakhtan				miękkoplastyczny ił	CLING	5	75.9	1,03
123	i Osanloo [36]	Snanriar Dam (Iran)			lub plastyczny pył	CL IUD ML	5	66.8	1,47
124							5	94.9	1,23
125				• • .			5	43.2	1,09
126			drobnoz	ziarnisty	pył ilasty i ił plastyczny		3	63	2,30
127					zwarty ił pylasty		15	63	0,90
128	01				pył ilasty i ił plastyczny	CL	3	56.7	2,50
129	Shen 1 in. [39]	Shanghai (Chiny)			zwarty ił pylasty	lub CL-ML lub CH	15	56.7	1,00
130					pył ilasty i ił plastyczny		3	54.2	2,80
131	-				zwarty ił pylasty		15	54.2	1,00

gdzie: $D_{i \text{ pomierzone}} - i$ pomierzona średnica z dostępnych danych eksperymentalnych,

 $D_{i,przewidziane}^{Jommizsine}$ – obliczona wartość odpowiadająca wejściu *i* sieci nauczonej na podstawie pozostałych (*n* – 1) danych eksperymentalnych. Ponadto, dane użyte w procesie uczenia do kalibracji i walidacji są losowo wybierane przez kod komputerowy. Wartość $D_{i,przewidziane}$ określono jako średnią z 20-stu iteracyjnie przeprowadzonych obliczeń.

Uwzględniono różne możliwe kombinacje liczby neuronów w warstwie ukrytej oraz procentowy stosunek pomiędzy danymi użytymi do kalibracji i walidacji, obliczając każdorazowo błąd MSE (wzór (5)) dla danych z tabl. 1 ÷ 3. W szczególności liczbę neuronów w warstwie ukrytej określono jako liczbę znajdującą się w zakresie 1 ÷ 4, bazując na rekomendacjach Haykina [23], który stwierdził, że liczba ta powinna znajdować się pomiędzy liczbą zmiennych wejściowych i wyjściowych. Równocześnie zróżnicowano stopniowo procentowy rozkład danych użytych do kalibracji/walidacji pomiędzy 10% a 70%. Z listy wartości błędu MSE przedstawionej w tabl. 4 można zauważyć, że najmniejsza różnica pomiędzy wartościami pomierzonymi a przewidzianymi ($MSE = 0.059 \text{ m}^2$) uzyskano przez sieć neuronowa składającą się z 4 neuronów w warstwie ukrytej (największa możliwa liczba zgodnie z rekomendacją Haykina [23]) oraz podziałem danych eksperymentalnych na 80% dla kalibracji i 20% dla walidacji.

DOKŁADNOŚĆ PREDYKCJI

Stopień korelacji pomiędzy wartościami pomierzonymi a przewidzianymi średnic kolumn poprzez zastosowanie sztucznej sieci neuronowej jest porównany z dwoma wcześniej przedstawionymi metodami sformułowanymi odpowiednio przez Flore i in. [22] oraz Shena i in. [39]. W tym celu dla każdego systemu iniekcji utworzono osobną SSN nauczoną na podstawie danych eksperymentalnych przedstawionych w tabl. $1 \div 3$. Zgodnie z wynikami przedstawionymi w tabl. 4 wybrano liczbę neuronów w warstwie ukrytej, jako równa liczbie zmiennych wejściowych (trzy dla każdej SSN) oraz 80% danych użytych do kalibracji (pozostałe 20% do walidacji) SSN. Porównanie wartości przewidzianych z wartościami pomierzonymi przeprowadzono na zbiorze przedstawionym w tabl. 1 ÷ 3, w którym przeprowadzono eliminację jednej po drugiej obserwacji oraz kolejno predykcję odpowiadającej średnicy wyeliminowanej kolumny przy użyciu SSN nauczonej na pozostałym zbiorze danych.

Na rys. 3 przedstawiono porównanie pomiędzy pomierzonymi wartościami średnic kolumn a ich przewidzianymi odpowiednikami (rys. 3a dla SSN, rys. 3b dla metody Flory i in. [22], rys. 3c dla metody Shena i in. [39]). Zgodność przewidywanych średnic kolumn z wartościami pomierzonymi jest na dobrym poziomie dla wszystkich metod. Jednakże, gdy dla systemu jednostrumieniowego jakość predykcji jest bardzo dobra, odchylenia od linii 1:1 uzyskane dla SSN (rys. 3a) i dla metody Flory i in. (rys. 3b) dla systemu dwustrumieniowego oraz trójstrumieniowego mają tendencję do wzrostu. Tendencja ta – do niedoszacowania średnic dużych kolumn – jest szczególnie wyraźna dla metody Flory i in. [22].

Predykcja przy użyciu metody zaproponowanej przez Shena i in. [39], przedstawiona na rys. 3c, wydaje się lepsza niż dla dwóch pozostałych metod. Należy jednak pamiętać, że zakres sytuacji przedstawionych na rys. 3c jest znacznie węższy niż na rys. 3a i 3b. Predykcja za pomocą SSN i metody przedstawionej przez Florę i in. [22], które korzystają z takich samych zmiennych przetestowano na zbiorze 131 danych (tabl. $1 \div 3$), natomiast metodę przedstawioną przez Shena i in. [39] przetestowano jedynie dla 17 przypadków (dla tych, dla których jest dostępny pełen zestaw parametrów technologicznych iniekcji).



Rys. 3. Porównanie wartości pomierzonych z wartościami przewidzianymi za pomocą: SSN (a), metody Flory i in. [22] (b), metody Shena i in. [39] (c)

Tabl. 4. Błąd *MSE* (m²) obliczony przy różnej liczbie neuronów w warstwie ukrytej oraz przy różnym procentowym stosunku danych użytych do kalibracji w stosunku do walidacji

		Procentowy udział danych do kalibracji/walidacji									
		90/10	80/20	70/30	60/40	50/50	40/60	30/70			
Liczba neuronów w warstwie ukrytej	1	0,126	0,118	0,117	0,117	0,118	0,120	0,120			
	2	0,093	0,092	0,094	0,086	0,091	0,088	0,102			
	3	0,074	0,074	0,074	0,075	0,076	0,083	0,091			
	4	0,064	<u>0,059</u>	0,069	0,079	0,075	0,080	0,084			

Uzyskane wyniki podsumowano w tabl. 5, w której przedstawiono wartości błędów *MSE* obliczonych dla różnych metod predykcji dla różnych systemów iniekcji. Analizę tę przeprowadzono osobno dla systemu jedno-, dwu- i trójstrumieniowego oraz dodatkowo dla wszystkich systemów. W celu lepszego zobrazowania sytuacji określono wiarygodność predykcji za pomocą następującego wzoru:

$$MAPE = \frac{100}{n} \sum_{n} \frac{\left| D_{i_{przewidziane}} - D_{i_{promierzone}} \right|}{D_{i_{promierzone}}} \quad [\%]$$
(6)

W porównaniu do błędu *MSE* średni błąd bezwzględny *MAPE* (ang. *Mean Absolute Percentage Error*) szacuje średnią wartość błędu predykcji.

Porównanie pomiędzy różnymi wartościami wykazuje, że predykcja dla systemu jedno- i dwustrumieniowego jest porównywalnie dobra dla wszystkich metod, z błędem *MAPE* wahającym się pomiędzy 10 i 15%. Takie same wartości uzyskano dla systemu trójstrumieniowego przy użyciu metody Shena i in. [39], ale ze znacznie mniejszą liczbą przeanalizowanych przypadków, co wpływa na ogólność tych wyników. Znaczna różnica w przeciwieństwie do systemu trójstrumieniowego jest pomiędzy SSN a metodą Flory i in. [22]. W pierwszej metodzie otrzymuje się błąd *MSE* i *MAPE* odpowiednio 0,106 m² i 15,5%,

Tabl. 5. Dokładność predykcji dla różnych systemów iniekcji strumieniowej

	System iniekcji	# danych	Błąd średnio- kwadratowy <i>MSE</i> [m²]	Średni błąd bezwzględny <i>MAPE</i> [%]	
	Jednostrumieniowy	50	0,007	11,932	
CON	Dwustrumieniowy	43	0,050	12,967	
3511	Trójstrumieniowy	38	0,106	15,492	
	Wszystkie	131	0,050	13,304	
	Jednostrumieniowy	50	0,008	10,097	
Flora	Dwustrumieniowy	43	0,057	13,532	
(2013)	Trójstrumieniowy	38	0,391	22,788	
	Wszystkie	131	0,135	14,906	
	Jednostrumieniowy	7	0,018	14,652	
Shen	Dwustrumieniowy	4	0,027	11,657	
(2013)	Trójstrumieniowy	6	0,032	13,743	
	Wszystkie	17	0,022	12,830	

w metodzie Flory i in. [22] otrzymuje się błędy równe 0,391 m² i 22,8%.

Wyniki te można wytłumaczyć, biorąc pod uwagę fakt, że relacje proponowane przez Florę i in. [22] charakteryzują się stałą strukturą (funkcją potęgowania) oraz to, że parametry skalibrowano na stosunkowo ograniczonej liczbie danych eksperymentalnych. Dokładność predykcji jest dobra dla tego zakresu (mniejsza niż 1,8 m, w odniesieniu do rys. 3b), podczas gdy ekstrapolacja w kierunku wyższych wartości energii prowadzi do niedoszacowania skuteczności iniekcji strumieniowej. Obserwuje się to szczególnie dla systemu trójstrumieniowego, który jest rozszerzeniem systemu dwustrumieniowego skalibrowanego na znacznie mniejszej liczbie danych eksperymentalnych. W efekcie prowadzi to do zbyt wysokiej (nierealistycznej) wartości oszacowanej energii (patrz (4)), kiedy są pożądane duże średnice kolumn, co znacznie częściej można spotkać w praktyce dla technologii iniekcji strumieniowej.

Predykcję przy zastosowaniu SSN przeprowadzono niezależnie dla wszystkich trzech systemów iniekcji, wykorzystując adaptowalną matematyczną strukturę sieci (neurony adaptują się przez zmianę wag synaptycznych w celu reprodukcji obserwacji) oraz proces uczenia przeprowadzono na większej liczbie danych eksperymentalnych. Wszystkie te warunki wyjaśniają przyczynę większej dokładność predykcji.

ZALECENIA DO PROJEKTOWANIA

Sztuczne sieci neuronowe utworzone przy użyciu opisanej procedury oraz nauczone, bazując na danych przedstawionych w tabl. 1 ÷ 3, wykorzystano do predykcji średnic kolumn iniekcyjnych. Predykcję przeprowadzono dla różnych warunków, uwzględniając najczęściej spotykane przy zastosowaniu technologii iniekcji strumieniowej. Korzystając z uprzedniego podziału, średnice kolumn przewidziano dla systemu jedno-, dwu- i trójstrumieniowego dla zmiennej wartości energii E'_n oraz dla różnego rodzaju gruntów (drobnoziarnisty, gruboziarnisty z frakcją drobną oraz bez frakcji drobnych) ze zwiększającą się wartością N_{SPT}. Predykcję przeprowadzono przy użyciu jednej unikalnej sieci neuronowej dla trzech rodzajów systemów iniekcji, przy uwzględnieniu systemu iniekcji jako dodatkowej zmiennej wejściowej zamiast tworzenia oddzielnej sieci dla każdego z systemu. Mimo tego, że dokładność predykcji jest nieco niższa (błąd MSE równy 0,066 m², podczas gdy dla oddzielnych sieci wynosi 0,050 m²), użycie jednej sieci neuronowej ma zaletę uczenia się równocześnie ze wszystkich dostępnych danych, co w efekcie prowadzi do utworzenia bardziej solidnych korelacji ze zmiennymi wejściowymi wspólnymi dla wszystkich systemów iniekcji. Jest to szczególnie pomocne przy zwiększaniu zakresu możliwego do predykcji dla każdego z systemów iniekcji.

W celu wyeliminowania wpływu przypadkowego doboru danych do kalibracji i walidacji z dostępnej bazy danych podczas procesu uczeniu SSN predykcję średnicy kolumn przeprowadzono wielokrotnie. Ostatecznie, średnice kolumn określono przez uśrednienie 1000 poprawnych wartości charakteryzujących się ciągłym wzrostem wartości średnicy w stosunku do wartości energii kinetycznej E'_n oraz redukcją wartości średnicy wraz z wzrostem wartości N_{spr} . Otrzymane średnice dla systemu iniekcji jedno-, dwu- i trójstrumieniowej dla różnych rodzajów gruntów w zależności od E'_n oraz N_{spr} przedstawiono na rys. 4.

Porównanie pomiędzy trzema wykresami (rys. 4a ÷ 4c) wykazuje, że większe średnice kolumn są uzyskiwane przeważnie w gruntach gruboziarnistych oraz to, że wzrost zawartości frakcji drobnych prowadzi do zmniejszenia uzyskiwanej średnicy kolumn. Dodatkowo, warto zauważyć, że przyjęcie większej energii może prowadzić do zamaskowania wpływu pomiędzy systemem dwu- i trójstrumieniowym oraz do zmniejszenia roli oporu ośrodka gruntowego.

Należy wspomnieć, że oszacowanie średnicy kolumn przedstawione na rys. 4 nie uwzględnia żadnego współczynnika bezpieczeństwa dotyczącego dokładności predykcji. Zgodnie z rys. 3 i tabl. 5 można zauważyć, że istnieje szansa, że wartość pomierzona średnicy będzie mniejsza niż ta przewidziana o 50%. W celu bardziej wiarygodnej predykcji zmienność błędów względnych pomiędzy wartościami pomierzonymi średnic z tabl. 1 \div 3 a odpowiadającym im przewidzianym wartościom przy użyciu SSN jest obliczona według wzoru (7):

$$RE_{i} = \frac{(D_{i_przewidziane} - D_{i_pomierzone})}{D_{i_przewidziane}} \quad i = 1 \text{ do } n \tag{7}$$

gdzie:

n odpowiada liczbie pomierzonych danych.

Statystyczny rozkład błędów obliczono oraz zamodelowa przy wykorzystaniu funkcji probabilistycznej. Analizę tę przeprowadzono oddzielnie dla systemu jedno-, dwu- i trójstrumieniowego, uzyskując funkcję rozkładu normalnego ze średnim zerem oraz odchyleniem standardowym odpowiednio równym 0,13; 0,17 oraz 0,20. Współczynnik bezpieczeństwa jest wprowadzony kolejno poprzez korektę estymacji średnic z rys. 4 przez przemnożenie przez współczynnik obliczony jako funkcja pożądanego poziomu wiarygodności (*CL*, por. rys. 5a). W szczególności *CL* jest określone jako prawdopodobieństwo, że średnice kolumn są większe niż przewidziane, podczas gdy współczynnik bezpieczeństwa jest równy *SF* = 1 + *RE*, gdzie *RE* jest błędem względnym odpowiadającym *CL* przez skumulowane prawdopodobieństwo funkcji rozkładu normalnego (*F* = 1 – *CL*).

Współczynniki te są przedstawione dla różnych systemów iniekcji, na osi poziomej rys. 5b jako funkcja poziomu wiarygodności potrzebnej do predykcji (przedstawionej na osi pionowej). Relatywna pozycja krzywych dla systemu jedno-, dwu- i trójstrumieniowego odzwierciedla redukcję dokładności przedstawionej przez rozproszenie danych na rys. 3a.

Warto wspomnieć, że współczynniki te wprowadzono w celu określenia niepewności predykcji opartej na danych eksperymentalnych uzyskanych z literatury. Mogą one być oczywiście zredukowane poprzez przeprowadzenie odpowiednich badań





C)



Rys. 4. Średnica kolumn iniekcyjnych przewidziana przy użyciu SSN a) grunty gruboziarniste bez frakcji drobnych; b) grunty gruboziarniste z frakcjami drobnymi; c) grunty drobnoziarniste



Rys. 5. Współczynnik bezpieczeństwa uwzględniający niedokładność predykcji a) definicja; b) współczynniki dla systemu pojedynczego, podwójnego i potrójnego

(testów polowych) dla konkretnego analizowanego przypadku, jak to występuje przy wstępnych badaniach polowych.

WNIOSKI

W artykule przedstawiono potencjał oraz ograniczenia wykorzystania sztucznych sieci neuronowych do zwiększenia poziomu ufności predykcji średniej wartości średnicy kolumn iniekcyjnych. Staranny dobór zmiennych opisujących poruszany problem jest konieczny w celu zrównoważenia stopnia złożoności poruszanego zagadnienia z ilością dostępnych informacji. Zmienne o mniejszym znaczeniu zostały pominięte, a inne zostały połączone. Zostały określone cztery różne zmienne wejściowe, dwie (system iniekcji oraz energia u wylotu dyszy) opisujące charakterystykę technologii iniekcji strumieniowej, pozostałe dwie (rodzaj gruntu oraz N_{SPT}) do określenia wpływu parametrów ośrodka gruntowego.

Z praktycznego punktu widzenia wykorzystanie SSN daje możliwość uwzględnienia dodatkowych danych eksperymentalnych zaczerpniętych z literatury, co niewątpliwie wpływa pozytywnie na dokładność predykcji, a zastosowanie przedstawionych uproszczeń nie wpływa na otrzymywane wyniki. Średni absolutny błąd procentowy na poziomie około $\pm 12\%$, $\pm 13\%$ i $\pm 15\%$ określono odpowiednio dla systemu jedno-, dwu- i trójstrumieniowego.

Porównanie SSN z innymi ostatnio opublikowanymi metodami wykazuje poprawę dokładności predykcji szczególnie dla systemu dwu- i trójstrumieniowego, dla których otrzymuje się wysokie wartości energii. Wyniki te mają szczególne znaczenie dla aplikacji, w których są potrzebne kolumny o dużych średnicach w celu zwiększenia prędkości stabilizacji, co ostatnio jest jednym z najbardziej pożądanych trendów technologii iniekcji strumieniowej.

Rozważając ten problem wykazano, że sztuczne sieci neuronowe są bardziej elastyczne w porównaniu do wzorów i zależności o z góry określonej strukturze. Zależności te muszą być w jakiś sposób odgórnie dostosowane, aby uwzględnić nowe dane, natomiast SSN mają zdolność do uwzględniania nowych informacji poprzez automatyczną adaptację architektury. Dzięki tej właściwości predykcja jest podatna na znaczną poprawę dokładności poprzez dodanie nowych danych eksperymentalnych. Bardziej kompleksowe i szczegółowe raporty z badań polowych z pewnością zmniejszą potrzebę wstępnych założeń, pozwalając tym samym na wyodrębnienie roli każdej poszczególnej zmiennej oraz wyróżnienie ich w korelacjach użytych do predykcji. W szczególności, bardziej złożone określenie roli strumienia powietrza jest wymagane w celu zwiększenia dokładności predykcji dla systemu dwu- i trójstrumieniowego.

Można uznać, że zwiększenie zaufania do narzędzi predykcji stanowi prawdziwe wyzwanie w badaniach technologii iniekcji strumieniowej, co w efekcie będzie prowadzić do świadomego, efektywnego i mądrego wykorzystania potencjału tej technologii.

LITERATURA

1. Agrawal G., Weeraratne S., Khilnani K.: Estimating clay liner and cover permeability using computational neural networks. Proc., First Congress on Computing in Civil Engrg., Washington, USA, 1994, 20-22.

2. Arroyo M., Gens A., Croce P., Modoni G.: Design of jet grouting for tunnel waterproofing, In Viggiani, ed., Proceedings of the 7th International Symposium on the Geotechnical Aspects of Underground Construction in Soft Ground: TC28-IS Rome: London, United Kingdom: Taylor & Francis Group, 2012, 181-188.

3. Beale M. H., Hagan M. T., Demuth H. B.: Neural Network Toolbox[™]. User's Guide. The MathWorks, Inc, 2013.

4. Bell A. L.: Jet grouting, In M. P. Moseley, ed., Ground Improvement: Blackie: Boca Raton, Florida, 1993, 149-174.

5. Bergschneider B., Walz B.: Jet grouting: Range of the grouting jet, In Vanicek et al., eds., Proceedings of the 13th European Conference on Soil Mechanics and Foundation Engineering: Prague, Czech Republic: Czech Geotechnical Society, 2003, 53-56.

6. Bianco B., Santoro V. M.: L'importanza dei campi sperimentale e delle sperimentazioni nella progettazione dei trattamenti colonnari. L'esempio delle fondazioni del viadotto Rio Matzeu della nuova SS. 131 variante nei pressi di Cagliari. Proc. 19th Nat. Conf. of Geotech. Eng., Pavia 1, 1995, 81-88 (in Italian).

7. Botto G.: Developments in the techniques of jet grouting, 12th Ciclo di Conferenze di Geotecnica: Torino, reprint by Trevi, 1985, 81-90.

8. Chan W. T., Chow Y. K., Liu L. F.: Neural network: an alternative to pile driving formulas. Comput. Geotech., Vol.17, No.2, ISSN 0266-352X, 1995, 135-156.

9. Chu E. H.: Turbulent Fluid Jet Excavation in Cohesive Soil, With Particular Application to Jet Grouting: PhD thesis, Massachusetts Institute of Technology, Cambridge, MA: 2005.

10. Covil C. S., Skinner A. E.: Jet grouting: A review of some of the operating parameters that form the basis of the jet grouting process, In Grouting in the Ground: London, United Kingdom: Thomas Telford, 1994, 605-627.

11. Croce P., Flora A.: Jet-grouting effects on pyroclastic soils. Rivista Italiana di Geotecnica 32, No. 2, 1998, 5-14.

12. Croce, P., Flora A.: Analysis of single-fluid jet grouting. Géotechnique, vol. 50, 6, 2000, 739-748.

13. Croce P., Modoni G.: Numerical Modelling of Jet-Grouted Foundations, Fifth European Conference on Numerical Methods in Geotechnical Engineering, Paris, September, 2002, ISBN 2-85978-362-8, 453-458.

14. Croce P., Flora A., Modoni G.: Jet Grouting: Technology, Design and Control. Taylor & Francis Group, London 2014.

15. Croce P., Gaio A., Mongiovì L., Zaninetti A.: Una verifica sperimentale degli effetti della gettiniezione. Rivista Italiana di Geotecnica 28, No. 2, 1994, 91-101.

16. Croce, P., Modoni G.: Design of jet grouting cutoffs. Ground Improvement 10(1), 2005, 1-9.

17. Croce, P., Modoni G., Carletto M. F. W.: Correlazioni per la previsione del diametro delle colonne di jet grouting, Proc. of the XXIV National Geotechnical Conference, "Innovazione Tecnologica nell'Ingegneria Geotecnica", Associazione Geotecnica Italiana, 22-24 June 2011, Napoli, 423-430 [in Italian].

18. Dabbagh A. A., Gonzalez A. S., Peńa A. S.: Soil erosion by a continuous water jet. Soils and Foundations 42(5): 2002, 1-13. 19. Davie J. R.: Jet Grout Columns Support Major Power Plant Structures. Proc. 12th Pan. Conf. on Soil Mech. and Geotech. Eng., ASCE GeoInstitute, Cambridge 2003.

20. Durgunoglu H. T., Kulac H. F., Oruc K., Yildiz R., Sickling J., Boys I. E., Altugu T., Emrem C.: A case history of ground treatment with jet grouting against liquefaction for a cigarette factory in Turkey. Grouting and Ground Treatment, ASCE, Reston, VA, 2003, 452-463.

21. Eramo N., Modoni G., Arroyo M.: Design control and monitoring of a jet grouted excavation bottom plug, In Viggiani G., ed., Proceedings of the 7th International Symposium on the Geotechnical Aspects of Underground Construction in Soft Ground: London: Taylor & Francis Group: pp. 611–618, 2012.

22. Flora A., Modoni G., Lirer S., Croce P.: The diameter of single-, double-, and triple-fluid jet grouting columns: Prediction method and field trial results. Géotechnique, vol. 63, 11, 2013, 934-945.

23. Haykin S.: Neural networks. A comprehensive foundation. Pearson Education, Delhi, India, 1999.

24. Ho C. E.: Fluid-soil interaction model for jet grouting. Grouting for ground improvement: Innovative concepts and applications, Geotechnical special publication 168, T. M. Hurley and L. F. Johnsen, eds., ASCE, Reston, VA, 2007, 1-10.

25. Hui C. L. P.: Artificial Neural Networks – Application. Ed. InTech. Vienna, Austria, 2011.

26. Ismael N. F., Jeragh A. M.: Static cone tests and settlement of calcareous desert sands, 9th Canadian Geotechnical Conference, 23 (3): 1986, 297-303.

27. Lignola G. P., Flora A., Manfredi G.: A simple method for the design of jet-grouted umbrellas in tunelling. ASCE Journal of Geotechnical and Geoenvironmental Engineering 134(12), 2008, 1778-1790.

28. Lunne T., Eide O., de Ruiter J.: Correlations between cone resistance and vane shear strength in some Scandinavian soft to medium stiff clays. Canadian Geotechnical Journal,, 13, 1976, 430- 441.

29. Maertens J., Maekelberg W.: Special applications of the jet grouting technique for underpinning works. Proceedings of the 15th ICSMFE, Istanbul, Turkey: 27–31 August, 2001, 1795-1798.

30. Masters T.: Sieci neuronowe w praktyce. Programowanie w języku C++. WNT, Warszawa, 1996.

31. Mauro M., Santillan F.: Large scale jet grouting and deep mixing test program at Tuttle Creek Dam. Proceedings of the 33rd Annual and 11th International Conference on Deep Foundations, Paper 1607, 2008.

32. McCulloch W., Pitts W.: A logical calculus of the ideas immanent in nervous activity. Bulletin of Mathematical Biophysics, 7, 1943, 115-133.

33. Miki G., Nakanishi W.: Technical progress of the jet grouting method and its newest type. Proceedings of the International Conference on In Situ Soil and Rock Reinforcement, Paris, France, October 9-11, 1984, 195-200.

34. Modoni G., Bzówka J.: Analysis of foundations reinforced with jet grouting. Journal of Geotechnical and GeoEnvironmental Engineering, ASCE, Vol. 138, No. 12, 2012, 1442-1454.

35. Modoni G., Croce P., Mongiovì L.: Theoretical modelling of jet grouting. Géotechnique 56(5), 2006, 335-347.

36. Nikbakhtan B., Osanloo M.: Effect of grout pressure and grout flow on soil physical and mechanical properties in jet grouting operations. International Journal of Rock Mechanics and Mining Sciences, Volume 46, Issue 3, April 2009, 498-505.

37. Pichler B., Lackner R., Mang H. A.: Back analysis of model parameters in geotechnical engineering by means of soft computing. International Journal for Numerical Methods in Engineering. Volume 57, Issue 14, 14 August 2003, 1943-1978.

38. Robertson P. K., Campanella R. G., Wightman A.: SPT-CPT correlations. Journal of the Geotechnical Engineering Division, ASCE, 109(11), 1983, 1449-1459.

39. Shen S., Wang Z., Yang J., Ho C.: Generalized Approach for Prediction of Jet Grout Column Diameter. Journal of Geotechnical and GeoEnvironmental Engineering, ASCE, GT.1943-5606.0000932 (Mar. 22, 2013).

40. Stark T., Axtell P., Lewis J., Dillon J., Empson W., Topi J., Walberg F.: Soil Inclusions in Jet Grout Columns. Deep Foundation Institute Journal 3, No. 1, 2009, 44-55.

41. Tornaghi R.: Trattamento colonnare dei terreni mediante gettiniezione (jet grouting). Proceedings of the 17th National Conference of Geotechnical Engineering, Taormina, Italy: 26-28 April, 1989, 193-203 [in Italian].

42. Tornaghi R., Pettinaroli A.: Design and Control Criteria of Jet Grouting Treatments. Proc. ASEP – GI, Int. Symp. sur l'Amélioration des Sols en Place, Paris 2004, 1-24.

43. Yahiro T., Yoshida H.: Induction grouting method utilizing high-speed water jet. Proceedings of the 8th ICSMFE, Moscor, Russia: June 1973: 402-404.