

# Możliwości zastosowania systemów klasyfikacyjnych do interpretacji wyników badań sondą CPT

Mgr inż. Anna Górska-Pawliczuk, dr hab. inż. Piotr E. Srokosz

Uniwersytet Warmińsko Mazurski w Olsztynie, Wydział Nauk Technicznych

Prawidłowe rozpoznanie geotechniczne terenu jest pierwszym z aspektów możliwości powstania na danym obszarze inwestycji budowlanych. Właściwości geotechniczno-inżynierskie zalegającego gruntu mają wpływ na projektowaną konstrukcję pod względem bezpieczeństwa i optymalizacji kosztów posadowienia obiektu budowlanego czy inżynierskiego. Na etapie projektowania niezbędne są szczegółowe informacje geotechniczne uzyskane za pomocą badań *in situ* oraz badań laboratoryjnych. Niezwykle istotny jest wybór metody oraz rodzaju badań. Dobieramy je, między innymi, w zależności od stopnia skomplikowania warunków geotechnicznych. Prawidłowe określenie parametrów geotechnicznych narzuca konieczność poszukiwania metod, za pomocą których uzyskane wyniki badań będą miały największą wiarygodność. Jednym z najbardziej uznanych i najczęściej stosowanych badań *in situ* do rozpoznania geotechnicznego gruntu oraz projektowania fundamentów pośrednich jest pomiar stożkową sondą statyczną CPT (*Cone Penetration Test*) lub CPTU (z pomiarem ciśnienia wody w porach). Potwierdzeniem tego faktu jest powstały algorytm obliczeniowy nośności na podstawie sondowań przedstawiony w normie europejskiej PN-EN 1997-2:2007 załącznik D.6 oraz D.7, w którym zakłada się dwojaką możliwość wyprowadzenia oporu ścinania z parametrów penetracyjnych. Coraz powszechniejsze zainteresowanie badaniami stało się powodem zorganizowania w 2014 roku kolejnej, piątej edycji szkoleń dotyczących badań penetracyjnych sondą pt. *5th International Workshop CPTU and DMT in soft clays and organic soils*. [6]. Międzynarodowa wymiana doświadczeń na tego rodzaju szkoleniach pozwala polskim badaczom na jeszcze prężniejszy rozwój oraz określa istotę zapotrzebowania tego rodzaju badań do korelacji regionalnych.

Bardzo efektywną procedurą identyfikacji stratygrafii podłoża opartą na uziarnieniu gruntu i genezie jest procedura Tumaya [10,18]. Podstawową trudnością w procesie interpretacji wyników badań CPT/CPTU jest konieczność posiadania regionalnych korelacji pomiędzy mierzalnymi cechami fizycznymi ( $q_p$ ,  $f_s$ ,  $u_c$ ) a właściwościami mechanicznymi badanych materiałów gruntowych. Należy podkreślić, że prawidłowo wyznaczone korelacje powinny przedstawiać wszystkie zależności występujące pomiędzy każdym z elementów układu: sonda-grunt. Analizie powinny podlegać nie tylko informacje związane z mierzalnymi oddziaływaniami gruntu na sondę (opór stożka, tarcie na tulei

ciernej, ciśnienie wody w porach gruntu), ale także reakcje sondy na te oddziaływania (np. wzajemny wpływ czujników na siebie, ich nieliniowości w dziedzinie temperatury, czasu i zakresu pomiaru, zmiany wartości odczytów w funkcji zużycia elementów pośredniczących w przekazywaniu oddziaływań itp.). Uwzględnienie wszystkich powyższych oddziaływań jest przedsięwzięciem niezwykle trudnym. Zastosowanie uczącego się systemu klasyfikacyjnego LCS (*Learning Classifier System*) nie wymaga wyznaczania postaci jawnej wymienionych niepewności pomiarowych, ponieważ w procesie uczenia LCS automatycznie uwzględnia się wszelkie niepewności związane z relacjami pomiędzy odczytywanymi wartościami parametrów sondy CPT a rodzajem gruntu określonym w wierceniach penetracyjnych. W praktyce inżynierskiej interpretacja wyników badań CPT jest procesem adaptacji istniejących i szeroko publikowanych w literaturze branżowej nomogramów korelacyjnych (zobacz [7, 8, 9, 17]). Należy zaznaczyć, że w niniejszej pracy przedstawiono wyniki prób zastosowania systemu LCS do zautomatyzowania procesu adaptacji przykładowego nomogramu korelacyjnego.

## LCS - UCZĄCY SIĘ SYSTEM KLASYFIKACYJNY

Koncepcja LCS była opracowana przez J. Hollanda w 1976 roku. [3]. W 1978 roku Holland opracował pierwszą aplikację opartą na koncepcji LCS – był to *Cognitive System One* (CS-1) [4]. Archetyp CS-1 był wzorcem wszystkich późniejszych LCS, których architekturę określono mianem „Michigan” [15]. W 1980 roku S. Smith w swojej rozprawie doktorskiej zatytułowanej „A learning system based on genetic adaptive algorithms” [13] zaproponował koncepcję i aplikację *Learning System One* (LS-1), która dała początek nowej architekturze, znanej w literaturze przedmiotu pod nazwą „Pittsburgh”. Obie koncepcje są rozwijane do dnia dzisiejszego – w pracy [15] przedstawiono ponad 80 algorytmów LCS wraz z ich zastosowaniami.

W uproszczeniu, LCS jest zbiorem reguł o postaci *warunek: akcja* [1, 2], które są stosowane w następującej formie:

*jeżeli zdarzenie spełnia warunek, to następuje akcja,*

zatem, zbiór reguł LCS może opisywać zarówno pewną funkcję odwzorowującą daną dziedzinę argumentów na pewien zbiór

wartości, jak również dowolne zjawisko przyczynowo-skutkowe, którego przyczyny i skutki można przedstawić w formie dyskretnych wartości. Problem tworzenia LCS polega na takim doborze reguł, aby reakcje systemu na następujące po sobie zdarzenia były takie same jak reakcje obserwowanego zjawiska. Użyteczność każdej reguły w systemie jest opisana wartością jej siły  $s$  – zmiany tej wartości są podstawowym elementem procesu uczenia. Najprostsza postać algorytmu tworzenia i uczenia LCS ma następującą formę:

- krok 1: stworzenie listy przyczyn  $\mu_j$  (komunikatów) oraz odpowiadającej jej listy akcji  $\alpha_j$  (odpowiedzi), które stanowią dyskretną formę opisywanego zjawiska ( $j \in [1, \eta]$ ,  $\eta$  – przyjęta liczba zdarzeń przyczynowo-skutkowych);
- krok 2: losowa generacja reguł  $R_i$  (warunków  $c_i$  i powiązanych z nimi akcji  $a_i$ ), nadanie wszystkim regułom jednakowej, początkowej wartości siły  $s_i^0$  (np.  $s_i^0 = 1,0$ ;  $i \in [1, \lambda]$ ,  $\lambda$  – przyjęta liczba reguł);
- krok 3: sprawdzenie dla każdego zdarzenia  $j$ , czy  $\mu_j = c_i$ , wyznaczenie zbioru  $M$  zawierającego wszystkie  $c_i$  spełniające warunek równości;

- krok 4: wyznaczenie efektywnej siły  $\sigma_i$  każdej reguły ze zbioru  $M$ , według formuły:

$$\sigma_i = b_0 \cdot (b_1 + b_2 \cdot u_i) \cdot s_i + n_\sigma \quad (1)$$

gdzie:



$b_0 \div b_2$  – stałe parametry, ustalone arbitralnie (np.  $b_0 = 0,1$ ;  $b_1 = 0,5$ ;  $b_2 = 0,05$ );

$n_\sigma$  – szum losowy o rozkładzie normalnym, który zakłóca determinizm wyznaczania efektywnej siły analizowanej reguły;


$u_i$  – cecha  $c_i$ , którą opisuje się możliwości reguły związane z uogólnianiem modelowanych związków przyczynowo-skutkowych;

- krok 5: pomniejszenie sił wszystkich reguł znajdujących się w zbiorze  $M$  o wartość  $\sigma_i$ ;
- krok 6: deterministyczny wybór reguły  $R_k$  o największej sile  $\sigma_k$ ; odczytanie przyporządkowanej jej akcji  $a_k$ ;
- krok 7: sprawdzenie poprawności zgłoszonej przez regułę  $R_k$  akcji:  $a_k = \alpha_j$ ; w przypadku zgodności akcji  $a_k$  z oczekiwanym skutkiem  $\alpha_j$  siła reguły  $s_k$  jest zwiększana o założoną wartość  $r$  (np.  $r = 10,0$ ):

$$s_k = s_k + r$$



Rys. 1. Przykład nomogramu interpretacyjnego (na podstawie [7]; liczby  $I_{soil}$  oznaczają grunty: 1 – słabonośne drobnoziarniste, 2 – organiczne, 3 – iły, gliny, 4 – gliny pylaste, gliny, 5 – pyły, gliny pylaste, 6 – pyły piaszczyste, pyły, 7 – piaski pylaste, pyły piaszczyste, 8 – piaski, piaski pylaste, 9 – piaski, 10 – żwir, piaski, 11 – prekonsolidowany grunt spoisty, 12 – prekonsolidowane piaski, piaski gliniaste); a) nomogram oryginalny, b) nomogram z oznaczeniami barwnymi (odcienie szarości oznaczają różne wartości  $I_{soil}$  w kolejności: najciemniejszy odpowiada  $I_{soil} = 1$ , najjaśniejszy odpowiada  $I_{soil} = 12$ )



Rys. 2. Dyskretne formy nomogramu interpretacyjnego z rys. 1. Dyskretyzacja: a) 10-bitowa, b) 12-bitowa, c) 14-bitowa

- krok 8: pomniejszenie sił wszystkich reguł w systemie według formuły:

$$s_k = s_k \cdot (1 - \tau) \quad (3)$$

gdzie:

$\tau$  – ustalona wartość (tzw. *life tax*, np.  $\tau=0,001$ ), która zapobiega „pa-sożytnictwu” mało użytecznych reguł.

W celu dostosowania zbioru reguł wygenerowanego w sposób losowy do narzuconego modelu prosta eliminacja mało użytecznych reguł (poprzez zmniejszanie ich siły aż do zera) oraz ekspozycja wartościowych reguł jest tylko jedną z dwóch podstawowych operacji uczenia. Zastępowanie mało efektywnych reguł przez nowe, potencjalnie lepsze reguły, następuje w procesie cyklicznej optymalizacji, realizowanej za pomocą algorytmów genetycznych (*genetic algorithm, GA*). Szczegóły dotyczące budowy i zasad działania GA zawarto w [14], a ich aplikacje w LCS można znaleźć między innymi w [2].

## ZASTOSOWANIE LCS DO INTERPRETACJI WYNIKÓW BADAŃ CPT

Koncepcja zastosowania LCS do interpretacji wyników badań CPT polega na generacji i adaptacji zbioru reguł o postaci:  $[q_p, R_f]:[I_{soil}]$ , tzn. warunkami są pary wartości jednostkowego oporu  $q_i$  i współczynnika tarcia  $R_f$ , a akcjami  $I_{soil}$  – wartości z ustalonego zbioru, które są wskaźnikami, np. rodzaju gruntu. W celu łatwiejszego przetwarzania informacji niesionych przez reguły stosuje się kodowanie binarne warunków i akcji, uwzględniając w kodzie warunków poza wartościami standardowymi „0” i „1” dodatkowo znak „\*” oznaczający wartość dowolną, tzn. „0” lub „1” w zależności od bieżących potrzeb (im więcej znaków „\*” występuje w warunku, tym ogólniejsza jest dana reguła, prawdopodobieństwo wystąpienia „\*” w łańcuchu –  $p_u$ ). Zatem łańcuchy warunków są kodowane *tritami*, a łańcuchy akcji – bitami. Na rys. 1. przedstawiono przykład nomogramu interpretacyjnego, zaczerpniętego z [7], który wykorzystano w uczeniu uproszczonej formy LCS. Na rys. 2a ÷ c przedstawiono dyskretne postaci tego nomogramu opracowane dla różnych liczb bitów dyskretyzacyjnych. Ze względu na półlogarytmiczną formę nomogramu funkcje transformujące wartości rzeczywiste na ich odpowiedniki binarne przyjęły postać:

$$\text{bin}(q_i) = \text{int}(A \cdot \log_{10}(q_i) + B) \quad (4)$$

$$\text{bin}(R_f) = C \cdot R_f + D \quad (5)$$

$$\text{bin}(I_{soil}) = E \cdot I_{soil} + F \quad (6)$$

gdzie:

$A \div F$  – stałe transformacji wynikające z zakresu argumentów ( $q_i, R_f, I_{soil}$ ) oraz docelowej liczby bitów dyskretyzacyjnych);

$\text{int}(\cdot)$  – funkcja zaokrąglająca argument do liczby naturalnej;

$\text{bin}(\cdot)$  – funkcja konwertująca argument do postaci binarnej.

Zarówno komunikaty, jak i warunki są tworzone za pomocą konkatencji (z łac. *concatenatio*) (operator „|” w formule 7) łańcuchów binarnych powstałych z transformacji wartości  $q_i$  i  $R_f$

$$\mu_j, c_i = \text{bin}(q_i) | \text{bin}(R_f) \quad (7)$$

natomiast odpowiedzi i akcje, z racji jednej wielkości  $I_{soil}$  są łańcuchami tworzonymi bezpośrednio według formuły (6):

$$\alpha_j, a_i = \text{bin}(I_{soil}) \quad (8)$$

Należy zaznaczyć, że w zagadnieniach opisanych ciąglą dziedziną argumentów preferuje się stosowanie kodowania za pomocą liczb rzeczywistych oraz algorytmy ewolucyjne, zamiast genetycznych. W niniejszej pracy przedstawiono również wyniki uzyskane z LCS opartego na kodowaniu liczb rzeczywistych według standardu IEEE-754, przyjmując następujące formuły konwersji wielkości fizycznych na łańcuchy  $\mu_j, c_i, \alpha_j, a_i$ :

$$\mu_j, c_i = f_p^{(16)}(5 \cdot \log_{10}(q_i) + 6) \left| f_p^{(16)}\left(\frac{15}{8} \cdot R_f + 1\right)\right. \quad (9)$$

$$\alpha_j, a_i = f_p^{(16)}(I_{soil}) \quad (10)$$

gdzie:

$f_p^{(16)}$  – funkcja konwertująca liczbę rzeczywistą bądź całkowitą na zmiennoprzecinkowy, wykładniczy format 16-bitowy (w zakresie od 1,00 do 16,00; 14 bitów mantysy + 2 bity wykładnika cechy). Zastosowanie przedstawionej konwersji pozwoliło zachować kanoniczną postać operacji LCS, a jednocześnie zastosować algorytm ewolucyjny, wykorzystujący w przetwarzaniu informacji arytmetykę liczb rzeczywistych, zmienoprzecinkowych.

## ANALIZA WYNIKÓW

Analizę możliwości uczenia się binarnej formy LCS przeprowadzono na podstawie wyników 27 prób w wariantach:  $\lambda = 10^4$ ,  $10^5$  i  $10^6$  (co odpowiada  $\eta = 1024$ , 4096 i 16384); dyskretyzacji 10-, 12- i 14-bitowej przy prawdopodobieństwie  $p_u = 0,0; 0,2$  i 0,4. Na rys. 3 i 4 przedstawiono przykładowe wyniki.

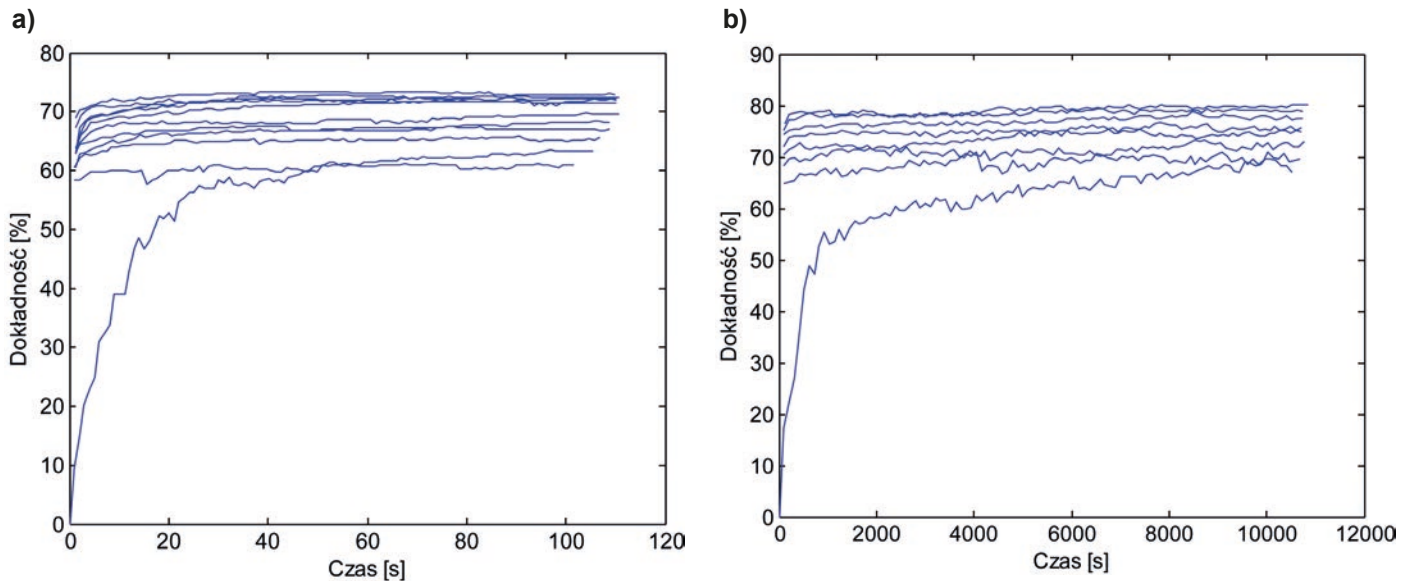
Jak można zauważyć, dokładność odzwierciedlenia danych stanowiących podstawę uczenia LCS zależy przede wszystkim od dwóch parametrów: liczby reguł oraz prawdopodobieństwa uogólniania. Parametry te zależą z kolei od liczby punktów w zbiorze danych (rys. 5a ÷ c). Ich wartości należy oznaczać metodą prób i błędów. Z kolei wyniki uzyskane z LCS pracującego w przestrzeni liczb rzeczywistych wskazują jednoznacznie (rys. 5d), że nawet największa, przyjęta w analizie liczba reguł ( $\lambda = 10^6$ ) nie zapewnia możliwości ukształtowania zbioru reguł zapewniającego dokładne odwzorowanie struktury danych (możliwe wartości liczb w zastosowanej odmianie standardu IEEE-754 reprezentują ponad  $2,8 \cdot 10^{14}$  punktów w przestrzeni liczb rzeczywistych). Jednym z rozwiązań problemu niskiej efektywności uczenia LCS jest zastosowanie operatora „uzupełniania/pokrywania” (ang. *cover*, zob. [16]), polegającego na uzupełnianiu zestawu reguł o nowe reguły według następujących zasad: jeżeli żaden warunek  $c_x$  nie pasuje do otrzymanego komunikatu  $\mu_x$ , to jest tworzony zbiór reguł z warunkiem pasującym do komunikatu  $c_x = \mu_x$  i losowo wygenerowanymi akcjami  $a_i$ ; jeżeli żaden warunek  $c_x$  pasujący do komunikatu  $\mu_x$  nie ma przyporządkowanej akcji  $a_x$  pasującej do wymaganej odpowiedzi  $\alpha_x$ , to danemu warunkowi przyporządkowuje się akcję pasującą do tej odpowiedzi  $c_x: a_x = \alpha_x$ . Na rys. 5d przedstawiono wyniki obliczeń w następujących wariantach: bez uzupełniania reguł, z uzupełnianiem warunków oraz z uzupełnianiem warunków i akcji.

Biorąc pod uwagę fakt, że w zadaniu z  $\eta = 1024$  wyjściową liczbę reguł  $\lambda = 100$  zwiększono w procesie uzupełniania warunków i akcji do wartości tylko około  $\lambda = 1,4 \cdot 10^4$ , oferując jednocześnie dokładne odwzorowanie zbioru danych, operacja


uzupełniania jest najsukuteczniejszym elementem konstruowania systemu LCS pracującego na zbiorze liczb rzeczywistych. Zastosowanie tej operacji w wariacie binarnego LCS jest również wskazane w celu wydawnego skrócenia czasu uczenia systemu.

Najważniejszym elementem programu analiz było potwierdzenie tezy, że dzięki zastosowaniu LCS jest możliwa automatyczna adaptacja nomogramów interpretacyjnych do warunków

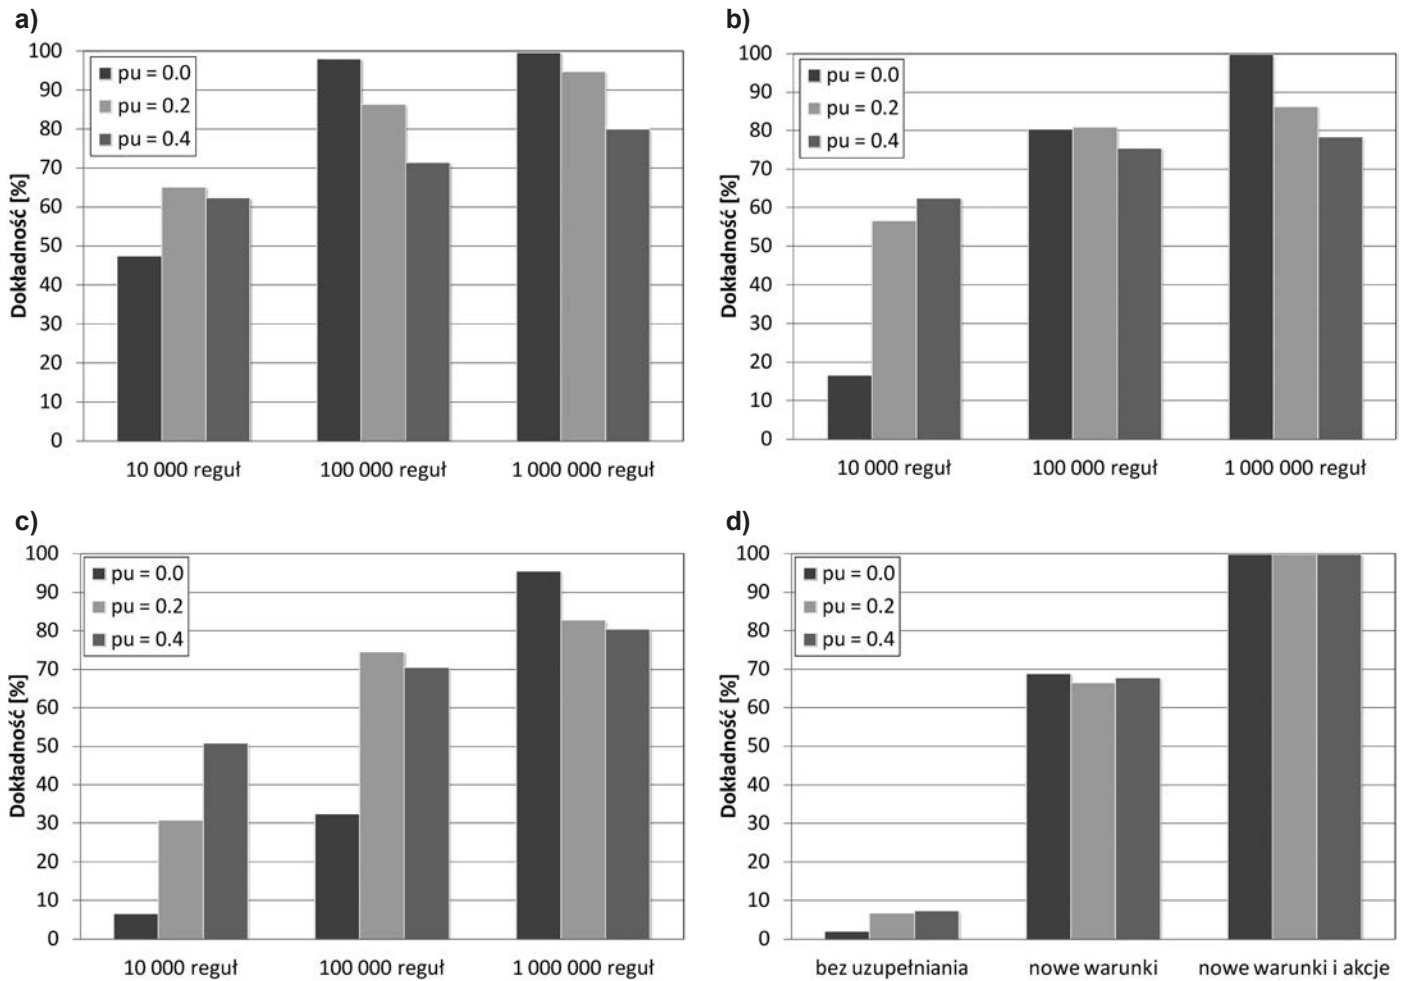
regionalnych. Na rys. 6 przedstawiono skorelowane wyniki badań uzyskane z sondowania CPTU i z wiercenia penetracyjnego przeprowadzonych w 2014 roku na terenie kampusu uniwersyteckiego Olsztyn-Kortowo. Rodzaje gruntów w profilu geotechnicznym określono na podstawie badań makroskopowych. Należy zaznaczyć, że przedstawione profile posłużyły jedynie jako wskazówki do określenia grupy gruntów – bez odpyły




Rys. 3. Typowe relacje pomiędzy czasem uczenia a dokładnością odwzorowania nomogramu przez LCS (AG uruchamiany po każdym 100 cyklach uczenia)  
 a)  $\lambda = 10^5, p_u = 0,4; \eta = 1024$ , b)  $\lambda = 10^6, p_u = 0,4; \eta = 16384$




Rys. 4. Przykłady nomogramów wyuczonych przez LCS ( $\eta = 16384$ )  
 a)  $\lambda = 10^5, p_u = 0,0$ ; b)  $\lambda = 10^5, p_u = 0,2$ ; c)  $\lambda = 10^5, p_u = 0,4$ ; d)  $\lambda = 10^6, p_u = 0,4$ ; e)  $\lambda = 10^6, p_u = 0,2$ ; f)  $\lambda = 10^6, p_u = 0,0$



Rys. 5. Uzyskane dokładności LCS; a)  $\eta = 1024$ , b)  $\eta = 4096$ , c)  $\eta = 16384$ , d)  $\eta = 1024$ , kodowanie rzeczywiste



Rys.6. Wyniki sondowania CPT użyte do adaptacji nomogramu interpretacyjnego



Rys. 7. Wyniki adaptacji LCS: a) nomogram „wyuczony” przez LCS; b) nomogram po adaptacji

(*undrained*), – z odpływem (*drained*) oraz przejściowych (*intermediate*) [12, 18]. W aktualnie stosowanych w praktyce procedurach interpretacyjnych stosuje się wstępne przetwarzanie danych pomiarowych metodami Hordera-Bloha, Hegazy-Mayne czy Młynarka (zobacz [5]). Ze względu na specyfikę kodowania informacji w LCS polegającą na niejawnym konstruowaniu stanów przyczynowo-skutkowych wartości  $q_c$  i  $R_f$  z badań nie były poddawane procesom wstępnej obróbki. Opierając się na uzyskanych danych pomiarowych opracowano dane uczące LCS, które miały na celu adaptację systemu reguł odwzorowującego w 99,98% nomogram interpretacyjny w 12-bitowej dyskretyzacji – wyniki przedstawiono na rys. 7. Po kilkudziesięciu cyklach uczenia systemu na nomogramie pojawiły się punkty (zaznaczone białym okręgiem na rys. 7), które oznaczają wprowadzone nowe informacje związane z lokalnymi relacjami pomiędzy uzyskanymi wartościami  $q_i$  i  $R_f$  a określonym na podstawie badań makroskopowych rodzajem gruntu.

## PODSUMOWANIE

Analiza wyników obliczeń pozwoliła sformułować następujące wnioski:

- systemy LCS pracujące zarówno w grubej (binarnej), jak i drobnej (rzeczywistej) dyskretyzacji przestrzeni cech mierzalnych otrzymywanych z badań CPT mogą być wykorzystywane z powodzeniem do automatycznej interpretacji wyników tych badań;
- system LCS z wyuczonym, bazowym nomogramem interpretacyjnym CPT można adaptować w prosty sposób do regionalnych warunków przeprowadzania badań geotechnicznych;
- gdy liczba reguł w LCS jest większa od liczby wszystkich możliwych wartości ciągów kodujących informacje

stanowiących dane źródłowe, operacja uogólniania nie jest potrzebna ( $p_u = 0$ ), a wymuszanie jej oddziaływania w procesie uczenia obniża dokładność odwzorowania przez LCS danych źródłowych;

- w przypadku, gdy liczba reguł jest mniejsza od liczby wszystkich możliwych wartości ciągów kodujących dane źródłowe, uogólnianie jest procesem niezbędnym ( $p_u > 0$ ) do uzyskania wysokiej dokładności LCS;
- ze względu na konieczność dokładnego (blisko 100%) odwzorowania nomogramów interpretacyjnych CPT, binarne systemy LCS muszą składać się ze znacznej liczby reguł;
- zastosowanie operacji uzupełniania umożliwia wydajne uczenie systemu LCS przetwarzającego liczby rzeczywiste, w pełni ukształtowany LCS zawiera znacznie mniej reguł niż jego binarny odpowiednik uczony bez operacji uzupełniania reguł.

Przedstawiony przykład automatycznej adaptacji nomogramu interpretacyjnego jest tylko potwierdzeniem założonej tezy, że systemy LCS mogą być użyteczne w tworzeniu regionalnych baz danych związanych np. z sondowaniami CPT/CPTU. Nie ulega wątpliwości, że tworzenie takich baz danych wymaga znacznej liczby badań charakteryzujących się uzyskiwaniem wysokiej dokładności wyników, które powinny być dodatkowo skorelowane z wynikami badań laboratoryjnych. Należy podkreślić, że w przyjętym do analizy przykładowym zestawie danych nie uwzględniono wielu parametrów mających wpływ na lokalizację punktów na nomogramie interpretacyjnym, np. wartości składowej pionowej naprężenia geostatycznego. Jeśli uwzględni się fakt, że systemy LCS mogą przetwarzać zbiory danych zdefiniowane w wielowymiarowych przestrzeniach parametrów, wprowadzenie dodatkowych zmiennych do łańcuchów reguł (np. głębokości, ciśnienia w porach gruntu itp.) nie stanowi żadnej trudności.

## LITERATURA

1. Bull L., Learning Classifier Systems: A brief introduction. Applications of Learning Classifier Systems, Springer, 2004, 3-13.
2. Goldberg D., Algorytmy genetyczne i ich zastosowanie. Wydawnictwa Naukowo-Techniczne, 2003.
3. Holland J., Adaptation. Progress in theoretical biology, pod redakcją: Rosen R. i Snell F.M., 1976.
4. Holland J., Reitman J., Cognitive systems based on adaptive agents. Pattern-directed inference systems, pod redakcją: Waterman D.A. i Inand F., Hayes-Roth, 1978.
5. Młynarek Z., Site investigation and mapping in urban area. Proceedings of the 14<sup>th</sup> European Conference on Soil Mechanics and Geotechnical Engineering. Madrid 2007.
6. Młynarek Z., Wierzbicki J., CPTU and DMT in soft clays and organic soils. 5<sup>th</sup> International Workshop, Poznań, Poland. Wydawnictwo Exemplum, 2014.
7. Lunne T., Robertson P.K., Powell J.J.M., Cone Penetration Testing in geotechnical practice. Blackie Academic & Professional, 1997.
8. Pisarczyk S., Mechanika gruntów. Wydawnictwo OWPW, 2010.
9. PN-B-04452:2002 Geotechnika – Badania polowe.
10. PN-EN ISO 14688-1:2006 Badania geotechniczne – Oznaczenie I klasyfikowanie gruntów – Część 1: Oznaczenie i opis.
11. PN-EN ISO 14688-1:2006 Badania geotechniczne – Oznaczenie I klasyfikowanie gruntów – Część 2: zasady klasyfikowania.
12. PN-EN 1997-1:2008 Eurokod 7. Projektowanie geotechniczne. Część 1: Zasady ogólne.
13. Smith S., A learning system based on genetic adaptive algorithms, PhD thesis, University of Pittsburgh, 1980.
14. Srokosz P. E., Wybrane zastosowania algorytmów genetycznych w geotechnice. Wydawnictwo UWM w Olsztynie, 2012.
15. Urbanowicz R.J., Moore J.H., Learning Classifier Systems: A complete introduction, review and roadmap. Journal of Artificial Evolution and Applications, Vol. 2009, ID 736398, 25 str.
16. Wilson S.W., Get real! XCS with continuous-valued inputs. Festschrift in Honor of John H. Holland, pod red. Booker L., Forrest S., Mitchell M., Riolo R., University of Michigan, 1999.
17. Wiłun Z., Zarys geotechniki. Wydawnictwo Komunikacji i Łączności, 2004.
18. Zhang Z., Tumay M.T., Statistical to Fuzzy Approach toward CPT Soil Classification, ASCE Journal of Geotechnical and Geoenvironmental Engineering, Vol. 125, No. 3 (1999), 179-186.