



Przybliżenie przemieszczeń pionowych na obszarze LGOM z wykorzystaniem sztucznych sieci neuronowych

Prediction of vertical displacements in the area of LGOM by use of artificial neural networks

Dr hab. inż. Maria Mrówczyńska, prof. UZ*

Treść: W pracy podjęto próbę przybliżenia przemieszczeń pionowych punktów sieci pomiarowo-kontrolnej, zlokalizowanej na terenie będącym pod wpływem eksploatacji górniczej, z wykorzystaniem sztucznych sieci neuronowych. Teren badań położony jest na obszarze Legnicko-Głogowskiego Okręgu Miedziowego, na którym prowadzone są cykliczne obserwacje geodezyjne mające na celu monitoring deformacji terenu. W celu prognozy przemieszczeń punktów kontrolowanych położonych na omawianym obszarze, zastosowano sztuczne sieci neuronowe wielowarstwowe uczone z wykorzystaniem gradientowych metod optymalizacji. Wyniki podlegające opracowaniu, w postaci zmian różnic wysokości, uzyskano z pomiarów wykonywanych metodą niwelacji precyzyjnej w latach 1967÷2012.

Abstract: This paper attempts to predict the vertical displacements, by measuring network points control, located within, under the influence of mining activities, by use of artificial neural networks. The study area is located in the Legnica-Głogów Copper District, on which regular observations were made, aiming at monitoring ground deformation. In order to forecast movements in the controlled points located in the area in question, we used artificial neural networks using multilayer learned gradient optimization methods. Results are subject to development, such as changes in height differences, obtained from measurements made using precision leveling in the years 1967÷2012.

Słowa kluczowe:

sztuczna inteligencja, monitoring deformacji terenu, pomiary geodezyjne

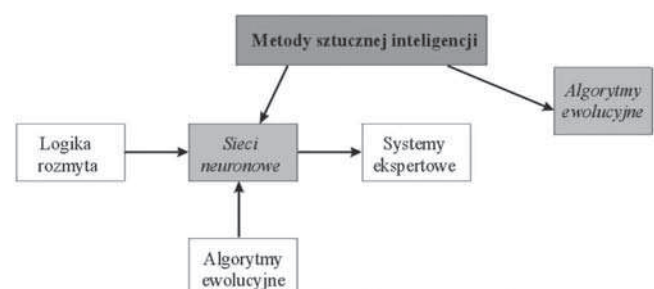
Key words:

artificial intelligence, ground deformation monitoring, geodetic surveys

1. Wprowadzenie

Wyniki pomiarów geodezyjnych mają szczególne znaczenie w rozpoznawaniu procesów oddziaływania prowadzonej eksploatacji górniczej na górotwór oraz powierzchnię terenu. Pomiary geodezyjne dostarczają dane opisowe dotyczące wpływu eksploatacji na górotwór i powierzchnię, co w znacznym stopniu ułatwia wyjaśnienie procesu deformacji obiektów oraz pozwala na przeprowadzenie prognozy procesu deformacji obejmującej wyznaczenie wartości przemieszczeń końcowych oraz określającej tempo przemieszczeń w czasie eksploatacji. W praktyce inżynierskiej pozyskiwanie danych pomiarowych często jest utożsamiane z monitoringiem geodezyjnym złożonym nie tylko z pomiarów, ale również z interpretacji uzyskanych wyników. Taki sposób postępowania umożliwia sprecyzowanie wniosków na temat deformacji powierzchni terenu [10]. Typowym objawem deformacji są przemieszczenia punktów sieci pomiarowo-kontrolnej zlokalizowanej na obszarze badań, które najczęściej są spowodowane zmianą warunków gruntowo-wodnych bądź wpływem eksploatacji górniczej. W procesie wyznaczania geometrycznego modelu przemieszczeń najważniejszym elementem jest identyfikacja zbioru wzajemnie stałych punktów, na których został zdefiniowany układ odniesienia [9].

W ostatnich latach, coraz większego znaczenia jako metody prognostyczne nabierają techniki bazujące na sztucznej inteligencji, głównie sieci neuronowe oraz algorytmy ewolucyjne, które mogą się wzajemnie uzupełniać tworząc zaawansowane narzędzie wykorzystywane w procesie przybliżenia (rys. 1). Sieci neuronowe pozwalają osiągnąć lepsze wyniki przybliżenia ze względu na posiadane zdolności kojarzenia zależności pomiędzy czynnikami wpływającymi na prognozę (dane wejściowe) oraz elementami prognozowanymi (dane wyjściowe). Cały proces przybliżenia z zastosowaniem sieci neuronowych odbywa się bez konieczności przedstawiania w jawnej postaci zależności pomiędzy danymi wejściowymi a wyjściowymi. Dodatkowo ze względu na swoje zdolności generalizacyjne sieci potrafią przeprowadzić prawidłowo



Rys. 1 Metody sztucznej inteligencji w prognozowaniu [2]
Fig. 1. Methods of artificial intelligence in predicting [2]


* Uniwersytet Zielonogórski, Wydział Budownictwa, Architektury i Inżynierii Środowiska

proces uczenia nawet wówczas, gdy zbiór wejściowy jest niepełny lub obciążony błędami [2].

Przedmiotem artykułu jest predykcja, z zastosowaniem sztucznych sieci neuronowych, przemieszczeń pionowych punktów sieci pomiarowo-kontrolnej, będąca rezultatem opracowania wyników pomiarów okresowych wykonanych metodą niwelacji precyzyjnej w latach 1967÷2012.

2. Architektura sieci perceptronowej oraz algorytmy uczące

Budowa sieci neuronowych mająca swoje podstawy w budowie komórki nerwowej człowieka powoduje, że sieci neuronowe są doskonałe w rozwiązywaniu zadań wymagających uczenia się, kojarzenia elementów, klasyfikacji danych, rozpoznawania wzorców i podejmowania szybkich decyzji [2]. W przypadku prognozowania zjawisk najczęściej w praktyce wykorzystywane są sieci neuronowe o budowie perceptronu wielowarstwowego, sieci Kohonena, sieci rekurencyjne oraz sieć typu Hechta-Nielsena (rys. 2).



Rys. 2. Sieci neuronowe wykorzystywane w predykcji [2]
Fig. 2. Neural networks used in prediction [2]

Jednym z najpopularniejszych rodzajów sieci neuronowych jest sieć neuronowa jednokierunkowa wielowarstwowa (perceptron wielowarstwow). W sieci perceptronowej neurony są ułożone w warstwach, a połączenia występują wyłącznie pomiędzy kolejnymi warstwami, pozwalając na przepływ sygnałów w jednym kierunku od warstwy wejściowej, przez warstwy ukryte, do warstwy wyjściowej (rys. 3). Liczba warstw ukrytych może być dowolna, jednak zostało udowodnione [7], że jedna warstwa (maksymalnie dwie) jest wystarczająca, aby sieć neuronowa stanowiła uniwersalny układ aproksymacyjny, który jest w stanie zrealizować funkcję nieliniową wielu zmiennych w postaci

$$\mathbf{y} = \mathbf{f}(\mathbf{x}), \quad (1)$$

gdzie:

- \mathbf{x} – oznacza wektor wejściowy,
- \mathbf{y} – realizowaną funkcję wektorową w całym zbiorze nieokreśloności.

Neurony w sieci realizują odwzorowanie nieliniowe, które w przypadku i -tego neuronu położonego w k -tej warstwie można opisać zależnością [8]

$$y_i^{(k)} = f(\text{net}_i^{(k)}) = f\left(\sum_j w_{ij} y_j^{(k-1)}\right) \quad (2)$$

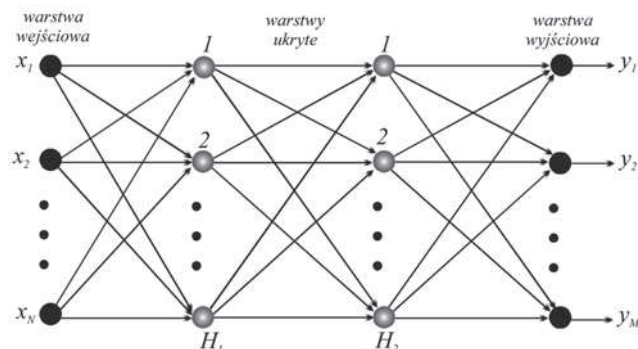
Wektor wag \mathbf{w} jest tworzony przez wagi sieci w_{ij} , natomiast funkcja aktywacji $f(\text{net})$ sieci perceptronowej może być między innymi funkcją sigmoidalną unipolarną

$$f(\text{net}) = 1/(1 + \exp(-\lambda \text{net})), \quad (3)$$

bądź bipolarną

$$f(\text{net}) = \tanh(\lambda \text{net}), \quad (4)$$

gdzie λ jest współczynnikiem nachylenia funkcji aktywacji, zwykle $\lambda = 1$.



Rys. 3. Architektura sieci perceptronowej [8]
Fig. 3. Perception network architecture [8]

Proces uczenia sieci perceptronowej jest uczeniem nadzorowanym (z nauczycielem) dla przeprowadzenia którego niezbędne jest wyodrębnienie zbiorów: uczącego, testowego oraz walidacyjnego. Utworzenie zbioru walidującego jest pożądane w każdym przypadku, jednak przy małej liczbie wzorców pewnym kompromisem i koniecznością jest rezygnacja z niego. Uczenie sieci odbywa się z wykorzystaniem jednej z metod gradientowych przez minimalizację funkcji celu $E(\mathbf{w})$ definiowanej z wykorzystaniem normy euklidesowej jako:

$$E(\mathbf{w}) = \sum_{j=1}^p (y(\mathbf{x}_j, \mathbf{w}) - \mathbf{d}_j)^2 \quad (5)$$

gdzie p jest liczbą par $(\mathbf{x}_j, \mathbf{d}_j)$ zbioru uczącego.

Proces uczenia polega na takim doborze współrzędnych wektora wag \mathbf{w} , aby uzyskać minimalną wartość funkcji błęd na zadanych zbiorach uczącym i testowym.

W każdej iteracji procesu uczenia wyznacza się, za pośrednictwem wektora gradientu, kierunek minimalizacji określony wektorem \mathbf{s} zależnym od wektora wag \mathbf{w} . Do najważniejszych gradientowych metod obliczania kierunku minimalizacji należą metoda największego spadku, zmiennej metryki, gradientów sprzężonych oraz Levenberga-Marquardta. Najprostszą z wymienionych metod jest metoda największego spadku, w której kierunek minimalizacji jest zgodny z kierunkiem ujemnego gradientu

$$\mathbf{s}(k) = -\nabla E(\mathbf{w}), \quad (6)$$

wówczas równanie adaptacji wag w iteracji $k+1$ można zapisać w postaci

$$\mathbf{w}(k+1) = \mathbf{w}(k) - \eta \nabla E(\mathbf{w}), \quad (7)$$

gdzie η jest współczynnikiem uczenia sieci przyjmowanym zazwyczaj z zakresu $(0, 1)$.

3. Obszar badań

Badaniami wpływu eksploatacji górniczej na powierzchnię terenu został objęty obszar Legnicko-Głogowskiego Okręgu Miedziowego (LGOM) leżący w południowej części monokliny przedsudeckiej. Na podstawie badań strukturalnych

w poziomie złoża miedzi i soli cechsztyńskich oraz obserwacji prowadzonych w wyrobiskach górniczych i szybach głębinowych kopalni KGHM Polska Miedź S.A. stwierdzono, że tutejsze masywy skalne dzielą się na trzy kompleksy zalegające na sobie dyskordantnie i są podzielone długimi łukami stratygraficznymi. Układ kompleksów zilustrowanych na rysunku 4, poczynając od najstarszego przedstawia się jak następuje [4]:

- kompleks skał krystalicznych wieku proterozoicznego oraz skał starszego paleozoiku, które stanowią podłoże monokliny,
- kompleks skał permo-mezozoicznych, z których została zbudowana monoklina,
- kompleks osadów kenozoicznych, które stanowią pokrywę monokliny.

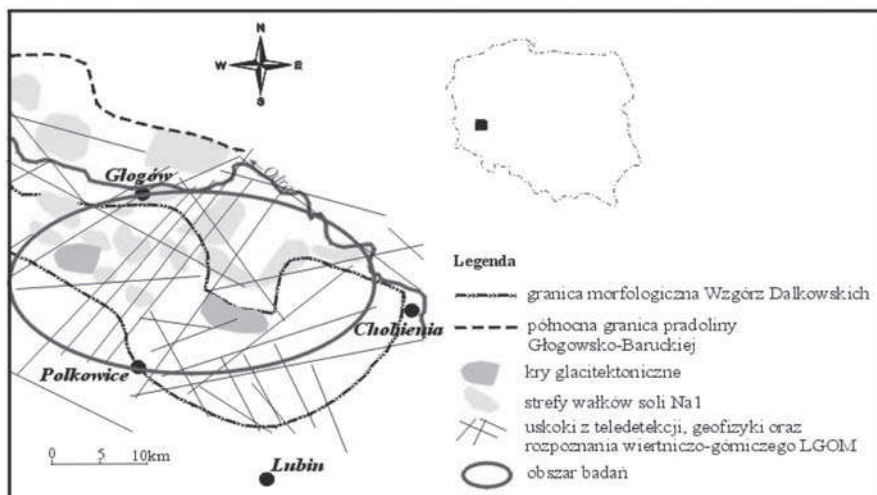
Obserwacje strukturalne w kopalni na obszarze LGOM wykazują kilka istotnych cech, które świadczą o tym, że południowa część monokliny przedsudeckiej leży w szerokiej strefie uskokuwej Odry. Wyodrębniono następujące cechy:

- lewoskrętną rotację układu spękań w poziomie złoża miedzi w miarę przesuwania się w kierunku północno – zachodnim,
- przesunięcia poziome na uskokach NW-SE,
- występowanie w spągowych partiach soli cechsztyńskich spękań ekstensywnych,
- charakter inicjalny uskokuw w spągu osadów cechsztynu.

Szczegółowe informacje na temat budowy geologicznej omawianego obszaru można znaleźć w pracach [4, 5].

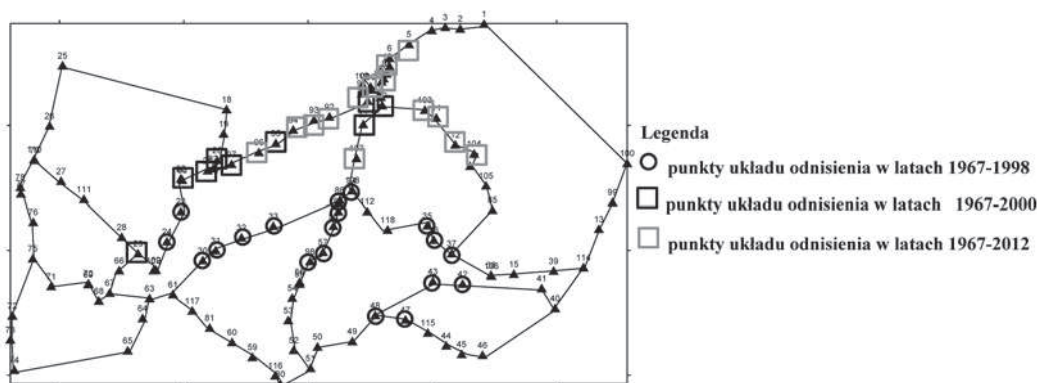
Przemieszczenia pionowe punktów kontrolowanych położonych na obszarze LGOM wyznaczono na podstawie pomiarów wykonanych metodą niwelacji precyzyjnej w latach 1967, 1998, 2000 oraz 2012. Pomiarami został objęty obszar o powierzchni około 80 000 ha, na którym zostało zlokalizowanych 118 punktów powiązanych obserwacjami w postaci różnic wysokości w liczbie 125 (rys. 5).

W pierwszym etapie obliczeń wyznaczone zostały zmiany różnic wysokości uzyskane w trzech czasookresach: 1967÷1998, 1967÷2000, 1967÷2012. Zmiany te poddano następnie wyrównaniu za pomocą procedury najmniejszych kwadratów przy minimalnych ograniczeniach stopni swobody dla przyjętego błędu średniego obserwacji wynoszącego $m_{\Delta h} = 0,3$ mm. Kolejnym krokiem, stanowiącym podstawowy problem dotyczący określenia modelu przemieszczeń, było zdefiniowanie układu odniesienia [3]. Układ zdefiniowano dla każdego okresu pomiarowego według zasady minimalnej sumy modułów [1], a następnie wyznaczono przemieszczenia pionowe z wyrównania z warunkami na układ odniesienia. Wyznaczone przemieszczenia pionowe oraz maksymalne obniżenie terenu, które w okresie 1968÷2012 zostało oszacowane na poziomie -3,792 m wraz z nieką osiadań charakteryzowaną przez linię największego spadku zgodną z kierunkiem postępu eksploatacji przedstawiono na rysunku 6.



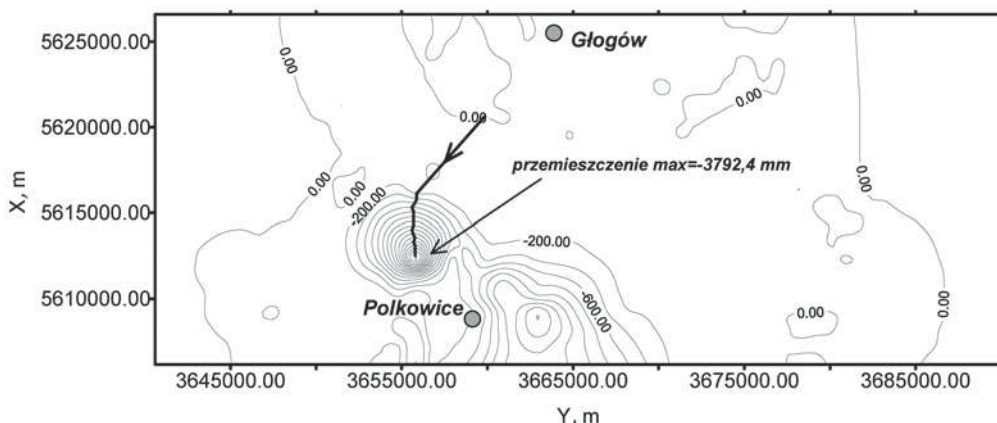
Rys. 4. Szkic budowy strukturalnej podłoża na badanym obszarze deformacji LGOM [opracowanie własne]

Fig. 4. Sketch of the structural form of the subsoil of the area under research of the LGCA




Rys. 5. Schemat sieci pomiarowej kontrolnej [opracowanie własne]

Fig. 5. Diagram of the measurement – control network



Rys. 6. Geometryczny model przemieszczeń uzyskany w okresie 1967÷2012 [opracowanie własne]
Fig. 6. Geometrical model of displacement obtained in the period of 1967÷2012

Predykcję przemieszczeń pionowych na obszarze Legnicko-Głogowskiego Okręgu Miedziowego wykonano z zastosowaniem sieci perceptronowej uczonej w sposób nadzorowany przy wykorzystaniu gradientowych metod optymalizacji. Danymi tworzącymi zbiór uczący były przemieszczenia pionowe uzyskane na punktach sieci pomiarowo-kontrolnej w latach 1967÷1998 oraz 1967÷2000, natomiast zbiór testowy stanowiły przemieszczenia pionowe wyznaczone dla okresu 1967÷2012. Współrzędnymi wektora wejściowego były współrzędne (x, y) punktów sieci pomiarowo-kontrolnej oraz określenie czasu, wektor wyjściowy stanowiły przemieszczenia pionowe. W procesie uczenia przeanalizowano różne warianty architektury sieci neuronowej, najkorzystniejsza okazała się składająca się z dwóch warstw ukrytych o 15 neuronach w warstwie pierwszej oraz 10 w warstwie drugiej. Dla tak przyjętej architektury sieć została nauczona z wykorzystaniem gradientowych metod optymalizacji: największego spadku, gradientów sprzężonych, zmiennej metryki oraz Levenberga-Marquardta.



Rys. 7. Przemieszczenia uzyskane z zastosowaniem sieci neuronowych [opracowanie własne]
Fig. 7. Displacements obtained by the use of neural networks

Najkorzystniejszy wynik predykcji przemieszczeń pionowych (rys. 7) na obszarze LGOM uzyskano z zastosowaniem metody gradientów sprzężonych, dla której błąd uczenia był równy 14,33 cm, natomiast błąd testowania 18,62 cm. Najmniej korzystne wyniki uzyskano dla sieci uczonej metodą największego spadku. Punkty sieci pomiarowo-kontrolnej, dla których osiągnięto najmniejsze wartości błędów predykcji są


zlokalizowane w północnej części obszaru, czyli tam gdzie deformacje terenu są najmniejsze, natomiast największe błędy predykcji pojawiają się na punktach położonych na obszarze charakteryzującym się największymi deformacjami (rys. 8). W tablicy 1 zostały zestawione wartości błędów uczenia i testowania sieci, dla wszystkich zastosowanych metod uczenia, w postaci błędu średniego RMSE danego wzorem [6]

$$RMSE = \frac{1}{\sqrt{p}} \sqrt{\sum_{i=1}^p (y_i - d_i)^2} \quad (8)$$

Tablica 1. Błędy uczenia i testowania sieci perceptronowej o architekturze 3_15_10_1

Table 1. Training and testing errors perceptron network architecture 3_15_10_1

Błąd	Gradientowa metoda optymalizacji			
	gradientów sprzężonych	Levenberga-Marquardta	zmiennej metryki	największego spadku
uczenia, cm	14,33	15,14	14,89	35,68
testowania, cm	18,62	22,46	25,21	48,23



Rys. 8. Rozkład błędów dla zbioru testowego (metoda gradientów sprzężonych) [opracowanie własne]
Fig. 8. Distribution of errors for the set test (conjugate gradient method)

4. Wnioski

W artykule podjęto próbę wykorzystania sieci perceptronowej do prognozowania przemieszczeń pionowych na obszarze będącym pod wpływem eksploatacji górniczej. Predykcję przeprowadzono dla jednego okresu pomiarowego, na podstawie pomiarów i obliczeń wykonanych dla dwóch

okresów pomiarowych. Najkorzystniejsze wyniki uczenia i testowania sieci osiągnięto z zastosowaniem metody gradientów sprzężonych, nieco gorsze rezultaty uzyskano dla metody Levenberga-Marquardta i zmiennej metryki, a najmniej korzystne dla metody największego spadku.

Na podstawie uzyskanych wyników można stwierdzić, że sieci neuronowe (perceptron wielowarstwowy) mogą zostać wykorzystane do prognozy pionowych zmian powierzchni terenu. Należy jednak zauważyć, że wartości błędów predykcji zwiększają się na punktach, na których zaobserwowano duże wartości przemieszczeń pionowych, dlatego też możliwym rozwiązaniem mogłoby być rozszerzenie wektora wejściowego o dodatkowe informacje, takie jak budowa geologiczna czy też głębokość prowadzonej eksploatacji. Prowadzenie badań z zastosowaniem sztucznej inteligencji w powiązaniu z teorią mechaniki górotworu stwarza możliwości prognozowania deformacji terenu, a tym samym przewidywania uszkodzeń obiektów usytuowanych w sąsiedztwie prowadzonej eksploatacji.

Literatura

1. *Gil J.*: Badanie nieliniowego geodezyjnego modelu kinematycznego przemieszczeń. seria: monografie nr 76, Wydawnictwo WSI w Zielonej Górze. 1995.
2. *Helt P., Parol M., Piotrowski P.*: Metody sztucznej inteligencji. Przykłady zastosowań w elektroenergetyce. Oficyna Wydawnicza Politechniki Warszawskiej. Warszawa, 2012.
3. *Kadaj R.*: Modele, metody i algorytmy obliczeniowe sieci kinematycznych w geodezyjnych pomiarach przemieszczeń i odkształceń obiektów. Kraków. Wydawnictwo AR.1998.
4. *Markiewicz A., Krański A.*: Neotektoniczna reaktywacja struktur halotektonicznych a zaburzenia glacitektoniczne w strefach marginalnych europejskich zlodowaceń plejstoceńskich na przykładzie Wzgórz Dalkowskich (SW Polska). Zielona Góra. Redakcja Wydawnictw Naukowo – Technicznych. 2002.
5. *Markiewicz A.*: Halotektoniczne uwarunkowania sedymentacji i deformacji osadów kenozoicznych w południowej części Monokliny Przedśudeckiej (SW Polska). Zielona Góra. Oficyna Wydawnicza Uniwersytetu Zielonogórskiego. 2003.
6. *Mrówczyńska M.*: Studium nad doбором metod inteligencji numerycznej do rozwiązywania problemów z geodezji inżynierskiej. Oficyna Wydawnicza Uniwersytetu Zielonogórskiego. Zielona Góra, 2015.
7. *Osowski S.*: Sieci neuronowe do przetwarzania informacji. Warszawa. Oficyna Wydawnicza Politechniki Warszawskiej. 2006.
8. Praca zbiorowa pod red. Borzykowskiego J.: Współczesna metrologia. Zagadnienia wybrane. Wydawnictwo Naukowo-Techniczne, Warszawa, 2007.
9. *Prószyński W., Kwaśniak B.*: Podstawy geodezyjnego wyznaczania przemieszczeń. Warszawa Oficyna Wydawnicza Politechniki Warszawskiej. 2006
10. *Wolski B.*: Monitoring metrologiczny obiektów geotechnicznych. Kraków. Wydawnictwo Politechniki Krakowskiej. 2006.