

dr hab. inż. Maria Mrówczyńska, prof. uczelni¹⁾
ORCID: 0000-0002-4762-3999

Zastosowanie sieci neuronowych i metody komponentów głównych PCA do kompresji wyników przemieszczeń obiektów budowlanych

Neural networks and PCA principal component methods application to compress the results of the construction object's displacement

DOI: 10.15199/33.2022.11.05

Streszczenie. W artykule zaproponowano wykorzystanie metody transformacji PCA (*Principal Component Analysis*), realizowanej z wykorzystaniem sieci neuronowej do kompresji wielowymiarowych danych, uzyskanych w wyniku prowadzonych pomiarów geodezyjnych. Jako przykład możliwości zastosowania prezentowanego podejścia wykorzystano wyniki pomiarów przemieszczeń pionowych obiektu budowlanego. Testy oceny skuteczności zaproponowanego podejścia wykonano z wykorzystaniem współczynnika korelacji oraz błędu średniokwadratowego, który nie przekroczył dwukrotności błędu średniego pomiaru. Wyniki analiz numerycznych porównano z wartościami przemieszczeń pionowych punktów sieci pomiarowo-kontrolnej, uzyskanymi z rzeczywistych pomiarów. Wyniki sugerują, że podejście może znaleźć zastosowanie do kompresji, a następnie rekonstrukcji danych z monitoringu geodezyjnego bez zmniejszenia dokładności identyfikacji przemieszczeń.

Słowa kluczowe: geodezyjny monitoring obiektów budowlanych; przemieszczenia pionowe; sieci neuronowe; analizy składników głównych PCA.

Abstract. The article proposes using the PCA (*Principal Component Analysis*) transformation method carried out using a neural network to compress multidimensional data obtained from geodetic measurements. As an example of the possibility of using the presented approach, the results of measurements of vertical displacements of a construction object were used. Tests to assess the effectiveness of the proposed method were performed using a correlation coefficient and a mean-square error that did not exceed twice the error of the average measurement. The results of numerical analyses were compared with the values of vertical displacements of the measuring and control network points obtained from actual measurements. The results suggest that the approach can be applied to the compression and subsequent reconstruction of geodetic monitoring data without compromising the accuracy of displacement identification.

Keywords: buildings geodetic monitoring; vertical displacements; neural networks; PCA principal component analysis.

Pomiar oraz poprawna interpretacja przemieszczeń pionowych obiektów budowlanych powiązana jest z monitoringiem geodezyjnym, prowadzonym w sposób okresowy lub ciągły. W ostatnich latach systemy monitorowania i diagnostyki kondycji obiektów budowlanych uwzględniają nie tylko przemieszczenia całego obiektu, ale również badają obciążenia poszczególnych elementów konstrukcyjnych i analizują wpływ czynników zewnętrznych [1, 2]. Jednocześnie wykorzystuje się skaniny laserowe, bezzałogowe statki powietrzne (UVA) oraz system GNSS realizowany w postaci systemu czujników RTK-GPS [3, 4]. Metody te są związa-

ne z pozyskiwaniem dużych zbiorów danych, których dalsza transmisja oraz opracowanie może być trudne do zrealizowania. W tym kontekście zastosowanie adekwatnych do zachodzących zjawisk deformacji algorytmów przetwarzania informacji jest podstawowym warunkiem prawidłowo prowadzonego monitoringu [5]. Wraz z rozwojem technologii informacyjnej, zaczęto dokonywać przetwarzania danych eksperymentalnych oraz stosować kompresję danych, pozwalającą na zmniejszenie objętości informacji [6]. Kompresja wyników przeprowadzonych eksperymentów oraz powstających w związku z tym dużych zbiorów danych jest zagadnieniem aktualnym ze względu na konieczność poprawy prędkości transmisji i ograniczenia miejsca do przechowywania danych. Jedną z podstawowych


metod analizy i kompresji wielowymiarowych danych jest prezentowana w artykule **metoda analizy składników głównych PCA**, która rozkłada wielowymiarowy zbiór danych na nieskorelowane wektory własne oraz powiązane z nimi składniki główne [7]. Wykorzystując kompresję strata, można uzyskać wiarygodne wartości przemieszczeń oraz zminimalizować zbiory danych powstające w wyniku prowadzonego długookresowego monitoringu geodezyjnego oraz pomiarów generujących wyniki w postaci dużych zbiorów danych.

Metoda badań

Zaproponowany w artykule proces wykorzystujący algorytm PCA i sztuczne sieci neuronowe do kompresji danych w postaci wyników pomiarów przemieszczeń pionowych obiektu bu-

¹⁾ Uniwersytet Zielonogórski, Instytut Budownictwa; m.mrowczynska@ib.uz.zgora.pl

dowlanego został przedstawiony na rysunku 1. Metoda składników głównych PCA bazuje na korelacji pomiędzy wieloma zmiennymi i badaniu wewnętrznej struktury zmiennych opisywanej za pomocą kilku składników głównych. Metoda PCA pozwala na liniową redukcję wymiarów zbioru wejściowego z wykorzystaniem transformacji ortogonalnych [8].



Rys. 1. Schemat badań z wykorzystaniem metody PCA i sztucznej inteligencji

Fig. 1. Research diagram using the PCA method and artificial intelligence

Samoorganizujące sieci neuronowe stanowią komplementarną klasę sieci, które identyfikują istotne cechy sygnałów wejściowych w trakcie prowadzonego procesu uczenia. W efekcie budowana jest struktura sieci, która najlepiej odwzorowuje zależności przestrzenne zachodzące w danych [9]. W badaniach wykorzystano mechanizm samoorganizacji bazujący na regule asocjacji Hebba, pozwalającej na stworzenie mechanizmu wykorzystującego model liniowy neuronu, w przypadku którego sygnał wyjściowy z_i pojedynczego neuronu jest wyznaczany zgodnie z zależnością [10]:

$$z_i = \sum_{j=1}^n w_{ji} x_j \quad (1)$$

gdzie:

$x = [x_1, x_2, \dots, x_n]$ – wektor wejściowy;
 $w = [w_1, w_2, \dots, w_n]$ – wektor wag.

Natomiast postać funkcji energetycznej (funkcji celu) E zapiszemy jako [10]:

$$E = -1/2 \sum_{m=1}^K \sum_{j=1}^m w_{im} A_{mj} w_{ji} - 1/2 \sum_{m=1}^K \sum_{j=1}^m \eta_{im} w_{im} w_{ji} - \sum_{j=1}^K b_j w_{ji} \quad (2)$$

gdzie:

K – liczba wzorców uczących;
 m – liczba neuronów w warstwie ukrytej;
 A_{mj} – macierz kowariancji aktywności j -tego oraz m -tego neuronu.

Składnik $-1/2 \sum_{m=1}^K \sum_{j=1}^m w_{im} A_{mj} w_{ji}$ funkcji energetycznej (2) jest wariancją σ_i^2 aktywności i -tego neuronu, natomiast składnik $-1/2 \sum_{m=1}^K \sum_{j=1}^m \eta_{im} w_{im} w_{ji} - \sum_{j=1}^K b_j w_{ji}$ jest funkcją celu występującą w teorii optymalizacji. Analiza składników głównych za pomocą sieci PCA jest jedną z metod statystycznej analizy wielo-

wymiarowych danych. Sama sieć jest jednowarstwowa, o liniowych funkcjach aktywacji [6]. Przekształcenie liniowe $z = wx$, będące podstawą analizy składników głównych, odpowiada transformacji wektora wejściowego $x \in \mathbf{R}^n$ w wektor wyjściowy $z \in \mathbf{R}^m$ z wykorzystaniem macierzy wag $w \in \mathbf{R}^{n \times m}$. Natomiast rekonstrukcja (transformacja Karhuna – Loeve’a) wektora wejściowego

x na podstawie macierzy w i wektora składników głównych z przebiega zgodnie z zależnością:

$$\check{x} = w^T z \quad (3)$$

Takie podejście powoduje, że transformacja PCA (dla $m \ll n$) jest kompresją stratną, zmniejszającą objętość informacji zawartej w zbiorze wejściowym. Jednocześnie transformacja przekształca zbiór wejściowy w zbiór niezależnych składników głównych, uszeregowanych pod względem ich ważności w procesie odtworzenia informacji.

Przemieszczenia pionowe (D_M) uzyskane w wyniku prowadzonych pomiarów geodezyjnych oraz ich rekonstrukcja (D_R) za pomocą algorytmu PCA [mm]

Vertical displacements (D_M) obtained as a result of geodetic measurements and their reconstruction (D_R) using the PCA algorithm [mm]

Nr punktu	Epoka 1		Epoka 2		Epoka 3		Epoka 4	
	D_M	D_R	D_M	D_R	D_M	D_R	D_M	D_R
1	0,15	0,08	-0,58	-0,86	0,43	0,27	0,55	0,38
2	0,08	0,04	-0,43	-0,63	0,40	0,20	0,53	0,42
3	-0,05	0,01	-1,83	-1,63	0,45	0,36	-0,18	-0,03
4	-0,09	-0,04	-1,76	-1,61	0,23	0,51	-0,42	-0,22
5	-0,13	-0,03	-1,89	-1,59	0,82	0,71	0,36	0,12
6	-0,22	-0,16	-1,89	-1,62	0,32	0,48	-0,26	-0,38
7	-0,01	-0,16	-0,90	-1,05	1,46	1,24	0,65	0,62
8	0,17	0,09	-0,55	-0,66	1,25	1,23	0,07	0,06
9	-0,07	0,05	-0,85	-1,08	2,41	2,24	1,77	1,49
10	0,06	0,01	-0,66	-0,49	2,36	2,58	1,79	1,50
11	0,03	-0,05	-0,66	-0,50	0,30	0,22	-0,40	-0,29
12	-0,18	0,40	-0,94	-0,76	0,46	0,67	-0,17	-0,29
Współczynnik korelacji R	0,6887		0,9436		0,9737		0,9864	
Błąd RMSE [mm]	0,10		0,21		0,17		0,17	

Wyniki i ich dyskusja

Kompresja geodezyjnych danych pomiarowych metodą analizy składników głównych PCA została wykonana z wykorzystaniem sieci neuronowej, na przykładzie przemieszczeń pionowych obiektu budowlanego reprezentowanego przez 12 punktów sieci pomiarowo-kontrolnej, zaobserwowanych w czterech cyklach pomiarowych. Dane występowały w postaci dwunastu wektorów wejściowych (pomiarowych) x o czterech składowych (elementach) w postaci przemieszczeń pionowych (tabela), które były podawane sekwencyjnie. Przeprowadzono również analizę regresji liniowej między wartościami przemieszczeń pionowych, uzyskanymi z pomiarów terenowych a wartościami przemieszczeń odtworzonymi z wykorzystaniem sieci neuronowej PCA. Na podstawie równania (4) obliczono współczynniki korelacji R w przypadku poszczególnych okresów pomiarowych, a wg równania (5) wartości błędów średniokwadratowych RMSE odtworzenia wektora wejściowego (tabela):

$$R = \frac{\sum_{i=1}^n (D_{Mi} - \bar{D}_M)(D_{Ri} - \bar{D}_R)}{\sqrt{(\sum_{i=1}^n (D_{Mi} - \bar{D}_M)^2) \sqrt{(\sum_{i=1}^n (D_{Ri} - \bar{D}_R)^2)}} \quad (4)$$

$$RMSE = \sqrt{\sum_{i=1}^n (D_{Mi} - D_{Ri})^2} \quad (5)$$

gdzie:

D_{Mi} i D_{Ri} – i -te przemieszczenie pomierzone i przemieszczenie odtworzone;
 \bar{D}_M i \bar{D}_R – średnie przemieszczenie pomierzone i przemieszczenie odtworzone.

Dokładność rekonstrukcji w całym okresie pomiarowym, scharakteryzowana średnim błędem kwadratowym RMSE, wynosi 0,17 mm. Największy błąd rekonstrukcji RMSE uzyskano w przypadku pomiarów wykonanych w epoce 2 i wyniósł on 0,21 mm, a najmniejszy równy 0,10 mm dotyczył pomiarów w epoce 1. Wartości błędu RMSE we wszystkich epokach pomiarowych nie przekraczają dwukrotności średniego błędu pomiaru. W przypadku pierwszej epoki pomiarowej uzyskano jednocześnie najmniejszą wartość współczynnika korelacji $R = 0,6887$, co może wskazywać, że na dokładność rekonstrukcji ma wpływ kierunek przemieszczeń, który w pierwszej epoce pomiarowej jest zmienny w poszczególnych punktach kontrolowanych, zlokalizowanych na obiekcie. Na rysunku 2 przedstawiono badany obiekt oraz geometryczny model przemieszczeń pionowych uzyska-

kompresję i dekompresję danych pomiarowych, analizy korelacji między przemieszczeniami uzyskanymi z pomiaru a przemieszczeniami odtworzonymi oraz wykonano analizę dokładności dekompresji wektora przemieszczeń. Na podstawie przeprowadzonych badań stwierdzono, że:

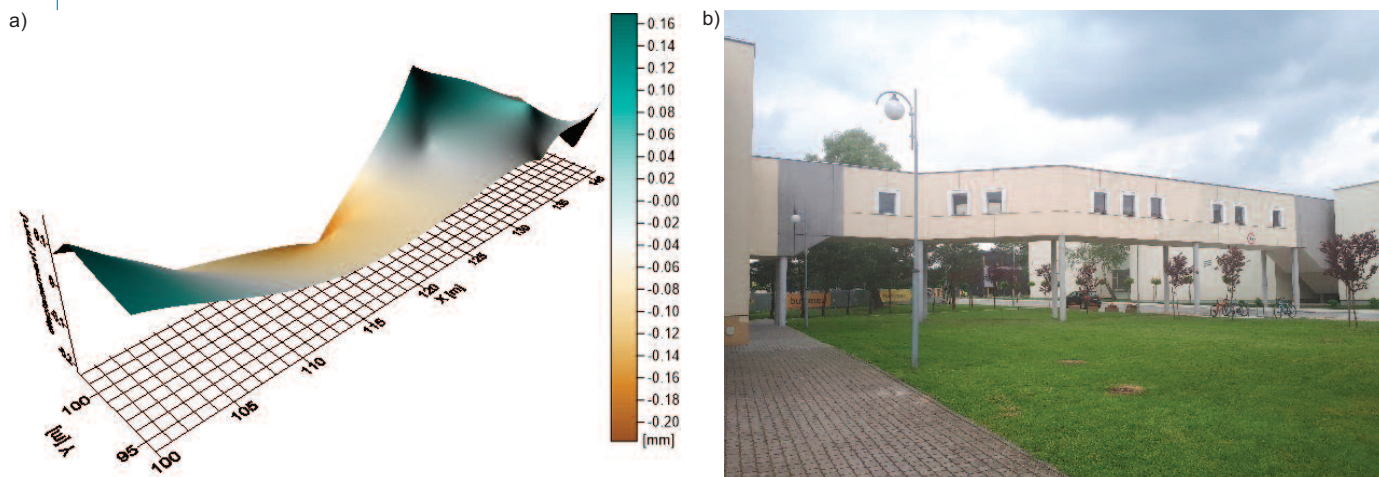
1) transformacja PCA może znaleźć zastosowanie do redukcji wymiaru przestrzeni danych pozyskiwanych podczas monitoringu geodezyjnego obiektów budowlanych, ponieważ kompresja wynika z potrzeby przechowywania danych pomiarowych oraz z potrzeby ich transmisji na odległość;

2) redukcja wymiaru przestrzeni danych prowadzi do kompresji, która w przypadku prezentowanego w artykule przykładu umożliwiła zmniejszenie liczby przechowywanych informacji o ok. 90%;

3) istnieje silna zależność liniowa pomiędzy przemieszczeniami uzyska-

Literatura

[1] Yanga DH et al. Monitoring and analysis of thermal effect on tower displacement in cable-stayed bridge. Measurement. 2018; <https://doi.org/10.1016/j.measurement.2017.10.036>.
 [2] Nowogońska B. Konsekwencje błędnych decyzji remontowych w XVII-wiecznym budynku szkieletowym. Materiały Budowlane. 2021; <https://doi.org/10.15199/33.2021.10.07>.
 [3] Błaszczak-Bąk W et al. Optimization of point clouds for 3D bas-relief modeling. Automation in Construction 2022; <https://doi.org/10.1016/j.autcon.2022.104352>.
 [4] Skrzypczak I et al. Scan-to-BIM method in construction: assessment of the 3D buildings model accuracy in terms inventory measurements. Building Research and Information 2022; <https://doi.org/10.1080/09613218.2021.2011703>.
 [5] Piniotis G et al. Deck and Cble Dynamic Testing of a Single-span Bridge Using Radar Interferometry and Videometry Measurements, Journal of Applied Geodesy 2016; <https://doi.org/10.1515/jag-2015-0030>.
 [6] Mrówczyńska et al. compression of results of geodetic displacement measurements using the PCA method and neural networks. Measurement 2020; <https://doi.org/10.1016/j.measurement.2020.107693>.



Rys. 2. Geometryczny model przemieszczeń pionowych – epoka 1 (a); badany obiekt (b)
 Fig 2. Geometric model of vertical displacements – epoch 1 (a); research object (b)

nych w wyniku ich odtworzenia dla epoki 1 (najmniejszy błąd rekonstrukcji). Uzyskane modele potwierdzają, że jesteśmy w stanie odtworzyć wektor przemieszczeń z błędem nieprzekraczającym dokładności wykonanego pomiaru.

Wnioski

Na podstawie danych pochodzących z monitoringu geodezyjnego prowadzonego na obiekcie budowlanym przedstawiono metodę transformacji (kompresji stratnej) PCA do redukcji wymiaru przestrzeni danych. Przeprowadzono

analizy w wyniku pomiaru a odtworzonymi algorytmem PCA, co potwierdza korzystny efekt działania algorytmu. Dodatkowo analiza stopnia dokładności odtworzenia wektora przemieszczeń, w postaci błędu RMSE, potwierdziła wysoką skuteczność zaproponowanej metody;

4) przedstawione analizy jakościowe i ilościowe geodezyjnych danych pomiarowych potwierdzają, że zastosowane metody pozyskania informacji oraz procedura obliczeniowa, mająca na celu kompresję danych, były odpowiednie.

[7] Lia Y et al. Accuracy enhancement of high-rate GNSS positions using a complete ensemble empirical mode decomposition-based multiscale multiway PCA. Journal of Asian Earth Sciences 2019; <https://doi.org/10.1016/j.jseas.2018.07.025>.
 [8] Wen L et al. Compression of smart meter big data: A survey. Renewable and Sustainable Energy Reviews 2018; <https://doi.org/10.1016/j.rser.2018.03.088>.
 [9] Mrówczyńska M. Analysis of principal components used for modelling changes in glaciectonically disturbed areas. Journal of Water and Land Development. 2018; <https://doi.org/10.2478/jwld-2018-0066>.
 [10] Wang H, Hong M. Supervised Hebb rule based feature selection for text classification. Information Processing & Management. 2018; <https://doi.org/10.1016/j.ipm.2018.09.004>.

Przyjęto do druku: 03.10.2022 r.