

Methodology for assessing the moisture content of historic brick masonry using machine learning

Metoda oceny wilgotności zabytkowych murów ceglanych z wykorzystaniem uczenia maszynowego

DOI: 10.15199/33.2024.09.12

Abstract. The subject of the paper is an original two-stage methodology for assessing the moisture content of historic brick walls using machine learning. The first stage includes the creation of a dataset from the results of experimental and archival research carried out in selected historic buildings. Stage two considers the generation of a model based on the dataset and the indicated machine learning algorithms. The reliability and practical suitability of the methodology was verified by an example of its application.

Keywords: historic brick walls; moisture content assessment methodology; non-destructive methods; machine learning.

Streszczenie. Przedmiotem artykułu jest oryginalna dwuetapowa metoda oceny wilgotności zabytkowych murów ceglanych z wykorzystaniem uczenia maszynowego. Etap pierwszy obejmuje utworzenie zbioru danych z rezultatów badań doświadczalnych i archiwalnych przeprowadzonych w wytypowanych budynkach zabytkowych. Etap drugi uwzględnia wygenerowanie modelu na podstawie zbioru danych oraz wskazanych algorytmów uczenia maszynowego. Wiarygodność i przydatność praktyczną metody zweryfikowano przykładem jej zastosowania.

Słowa kluczowe: zabytkowe mury ceglane; metoda oceny wilgotności; metody nieniszczące; uczenie maszynowe.

The assessment of the moisture content of brick masonry in buildings under conservation protection is associated with many difficulties resulting from the inability to freely interfere with the historic tissue [1]. The inclusion of a building under legal protection excludes the free use in research of destructive methods based on taking samples of masonry for testing, such as the gravimetric method, which is considered to give the most reliable results [2, 3]. Non-destructive methods are therefore predominantly used to measure the moisture content of brick masonry in historic buildings [4 ÷ 6], and the common practice of testing using these methods generally involves the use of one selected method.

The unquestionable advantage of non-destructive methods is the lack of interference in the structure of the masonry, and therefore the possibility of carrying out tests at any number of test points. However, the limitations of such testing should be borne in mind, undoubtedly affecting the accuracy of the results obtained. Non-destructive moisture measurement is carried out indirectly, which means that the result of a direct measurement is a physical or chemical feature of the material other than moisture, the value of which is affected by the water content. In order to identify the moisture level, it is therefore necessary to know the correlation relationship between the dimensionless number X , which is the result of the measurement, and the actual mass moisture content U_m of the masonry to be tested [7]. This involves taking a certain number of material samples for gravimetric testing in the laboratory.

Ocena wilgotności murów ceglanych w budynkach będących pod ochroną konserwatorską wiąże się z wieloma trudnościami wynikającymi z braku możliwości swobodnej ingerencji w zabytkową tkankę [1]. Objęcie budynku ochroną prawną wyklucza swobodne stosowanie metod niszczących, bazujących na pobieraniu do badań próbek muru, np. metody grawimetrycznej, która uznawana jest za dającą najbardziej wiarygodne wyniki [2, 3]. Do pomiaru wilgotności murów ceglanych w obiektach zabytkowych stosowane są więc przede wszystkim metody nieniszczące [4 ÷ 6], a powszechna praktyka prowadzenia badań z ich użyciem zakłada z reguły zastosowanie jednej wybranej metody.

Niewątpliwą zaletą metod nieniszczących jest brak ingerencji w strukturę muru, a co za tym idzie możliwość wykonania badań w dowolnej liczbie punktów badawczych. Należy mieć jednak na uwadze ograniczenia tak prowadzonych badań, które niewątpliwie wpływają na dokładność uzyskiwanych rezultatów. Pomiar wilgotności metodami nieniszczącymi odbywa się w sposób pośredni, co znaczy, że wynikiem bezpośredniego pomiaru jest inna, niż wilgotność, fizyczna bądź chemiczna cecha materiału, na której wartość wpływa zawarta w nim woda. Do zidentyfikowania poziomu wilgotności konieczna jest zatem znajomość zależności korelacyjnej między liczbą bezwymiarową X , będącą rezultatem pomiaru, a rzeczywistą wilgotnością masową U_m badanego muru [7]. Wiąże się to z koniecznością pobrania określonej liczby próbek materiału do badań metodą grawimetryczną w laboratorium. Zasadniczo zależność $X-U_m$ należy opracować w przypadku każdego nowo badanego obiektu, ponieważ wskazania mierników uzależnione są nie tylko od zawartości

¹⁾ Wrocław University of Science and Technology, Faculty of Civil Engineering; anna.hola@pwr.edu.pl

In principle, the $X-U_m$ relationship must be developed for each new object to be tested, as the meter indications depend not only on the moisture content of the material being tested, but also on other characteristics of the material, such as the type and concentration of salts present, and these can be different for each object [8]. In order to develop a correlation relationship, it is necessary to take a minimum of 30 masonry samples for laboratory testing, but there is not always permission from the conservation service for such interference with historic masonry. Taking a smaller number of masonry samples also offers the possibility of identifying the moisture level, but only using a hypothetical relationships selected from those available in the literature [7]. However, it should be noted that the availability of hypothetical relationships in the literature is low and the results obtained from them are not very accurate, which does not allow this method of identifying moisture level to be considered fully reliable.

For the reasons described, attempts have been made in recent years to move away from the model of conducting moisture tests using a single non-destructive method. In the literature, it is increasingly common to find descriptions of tests carried out according to two or more complementary non-destructive methods, in order to obtain a more complete picture of the moisture content [e.g. 9 ÷ 11]. My research work to date on an alternative – non-invasive and allowing for reliable test results – means of quantifying the moisture content of salted brick masonry in historic buildings has shown that reliable assessment is possible using two complementary non-destructive methods and machine learning [i.a. 12 ÷ 13].

The purpose of the paper is to present an original, reliable method for assessing the moisture content of historic brick masonry, developed on the basis of own experience gained both during moisture tests in many buildings erected in different historical periods and analyses carried out using the results obtained from these tests and artificial intelligence. In addition, an example of the application of this methodology will be presented, verifying its reliability and practical suitability.

Description of the method

The method for assessing the moisture content of historic brick walls using machine learning consists of two stages.

The first stage involves carrying out experimental research in the selected historic buildings, at the research points indicated in them, using the following **methods: non-destructive dielectric, non-destructive microwave, destructive gravimetric and indicator papers**, as well as archival research, in order to create a data set. For each test point, this yields seven numerical values, hereafter referred to as parameters. These are: two dimensionless parameters X_D [-] and X_M [-] determined nondestructively and describing indirectly the moisture content of the masonry, the parameter U_m [%] determined destructively and describing in percentage the actual mass moisture content of the masonry, three parameters X_C [%], X_S [%], X_A [%] describing in percentage the molar concentration of the chloride, sulphate and nitrate salts contained in the masonry respectively, and the dimensionless parameter Y [-] describing the year of construction of the object.

wilgoci w badanym materiale, ale również od innych cech, np. rodzaju i stężenia występujących w nim soli, które mogą być inne w przypadku każdego obiektu [8]. Do opracowania zależności korelacyjnej konieczne jest pobranie do badań laboratoryjnych minimum 30 próbek muru, ale na taką ingerencję w zabytkowy mur nie zawsze jest zgoda służb konserwatorskich. Pobranie mniejszej liczby próbek muru również umożliwia identyfikację poziomu wilgotności, tyle że z wykorzystaniem zależności hipotetycznej dobranej spośród dostępnych w literaturze [7]. Należy jednak podkreślić, że dostępność zależności hipotetycznych w literaturze jest niewielka, a uzyskiwane na ich podstawie wyniki są mało dokładne, co nie pozwala uznać tego sposobu identyfikacji poziomu wilgotności za w pełni wiarygodny.

Z opisanych powodów, w ostatnich latach podejmowane są próby odejścia od modelu prowadzenia badań wilgotności z użyciem jednej metody nieniszczącej. W literaturze coraz częściej można spotkać opisy badań prowadzonych wg dwóch lub więcej uzupełniających się metod nieniszczących, w celu uzyskania pełnego obrazu zawilgocenia [np. 9 ÷ 11]. Dotychczasowe moje prace badawcze nad alternatywnym – nieinwazyjnym i pozwalającym na uzyskanie wiarygodnych wyników badań – sposobem ilościowej oceny wilgotności zasolonych murów ceglanych w budynkach zabytkowych wykazały, że możliwa jest wiarygodna ocena z wykorzystaniem dwóch komplementarnych metod nieniszczących i uczenia maszynowego [m.in. 12 ÷ 13].

Celem artykułu jest przedstawienie oryginalnej, wiarygodnej metody oceny wilgotności zabytkowych murów ceglanych, opracowanej na podstawie własnych doświadczeń nabytych zarówno podczas badań wilgotności w wielu budynkach wzniesionych w różnych okresach historycznych, jak i analiz prowadzonych z wykorzystaniem uzyskanych rezultatów tych badań i sztucznej inteligencji. Ponadto zaprezentowany zostanie przykład zastosowania tej metody weryfikujący jej wiarygodność i przydatność praktyczną.

Opis metody

Metoda oceny wilgotności zabytkowych murów ceglanych z wykorzystaniem uczenia maszynowego składa się z dwóch etapów.

Pierwszy etap obejmuje zrealizowanie badań doświadczalnych w wytypowanych budynkach zabytkowych, we wskazanych w nich punktach badawczych, **metodami: nieniszcząca dielektryczną, nieniszcząca mikrofalową, niszcząca gravimetryczną oraz papierków wskaźnikowych, a także badań archiwalnych**, w celu utworzenia zbioru danych. W przypadku każdego punktu badawczego uzyskuje się w ten sposób po 7 wartości liczbowych, nazywanych dalej parametrami. Są to: dwa parametry bezwymiarowe X_D [-] i X_M [-], określone nieniszcząco i opisujące pośrednio wilgotność muru; parametr U_m [%], określony niszcząco i opisujący w procentach rzeczywistą wilgotność masową muru; trzy parametry X_C [%], X_S [%], X_A [%], opisujące w procentach stężenie molowe zawartych w murze odpowiednio soli chlorkowych, siarczanowych i azotanowych oraz parametr bezwymiarowy Y [-], opisujący rok budowy obiektu.

The experimental methods have been selected on the basis of my experience to date in conducting humidity surveys in various historical buildings and are dictated, among other things, by the availability and user-friendliness of the testing apparatus, the ease of conducting the surveys and the reliability of the results obtained. The procedure leading to the creation of the dataset is shown graphically in Figure 1 and described in detail in [14]. Table 1, on the other hand, gives, as an example, an excerpt from a dataset of 290 result sets, which I created from the results of surveys carried out in twelve historic buildings. The full dataset is available in the publications [12, 13]. In addition, a narrower dataset, covering U_m moisture from 8% upwards, with 97 result sets, is provided in [13].

Stage two of the method involves the construction of a machine learning model using the dataset created in stage I and selected machine learning algorithms. The parameters X_D , X_M , X_C , X_S , X_A and Y were used as input variables in the learning, validation and verification processes of the algorithms. The research methods used to acquire them do not interfere or interfere minimally with the fabric of the building and can therefore be approved by the conservation services. The parameter U_m was used as the reference in the learning process, while the output variable evaluated was the parameter U_{mc} describing the mass moisture value generated by the model.

As part of my research to date, conducted on the suitability of machine learning for assessing the mass moisture content of brick masonry in historic buildings. I have analysed 11

Metody badań doświadczalnych zostały dobrane na podstawie dotychczasowych moich doświadczeń, zdobytych podczas prowadzenia badań wilgotności w różnych obiektach zabytkowych i podyktowany jest m.in. dostępnością i prostotą obsługi aparatury badawczej, łatwością prowadzenia badań i wiarygodnością uzyskiwanych rezultatów. Sposób postępowania prowadzący do zbudowania zbioru danych przedstawiono graficznie na rysunku 1, a szczegółowo opisano w [14]. W tabeli 1 podano natomiast dla przykładu fragment zbioru liczącego 290 zestawów wyników, który utworzyłam z wyników badań przeprowadzonych w dwunastu budynkach zabytkowych. Pełny zbiór dostępny jest w publikacjach [12, 13]. Dodatkowo, w [13] zamieszczony został zawężony zbiór danych, obejmujący wilgotność U_m od 8% w górę, liczący 97 zestawów wyników.

Etap drugi metody obejmuje budowę modelu uczenia maszynowego z wykorzystaniem zbioru danych utworzonego w etapie I i wybranych algorytmów uczenia maszynowego. Jako zmienne wejściowe w procesach uczenia, walidacji i weryfikacji algorytmów przyjęto parametry X_D , X_M , X_C , X_S , X_A i Y . Metody badawcze stosowane w celu ich pozyskania nie ingerują lub ingerują w minimalnym stopniu w tkankę budynku, dlatego też mogą uzyskać akceptację służb konserwatorskich. Za wzorzec w procesie uczenia posłużył parametr U_m , natomiast ocenianą zmienną wyjściową był parametr U_{mc} opisujący wartość wilgotności masowej wygenerowaną przez model.

W ramach dotychczasowych badań, prowadzonych nad przydatnością uczenia maszynowego do oceny wilgotności masowej murów ceglanych w budynkach zabytkowych, przeanalizowałam 11 różnych algorytmów uczenia sztucznych sieci neuronowych, algorytm lasów losowych

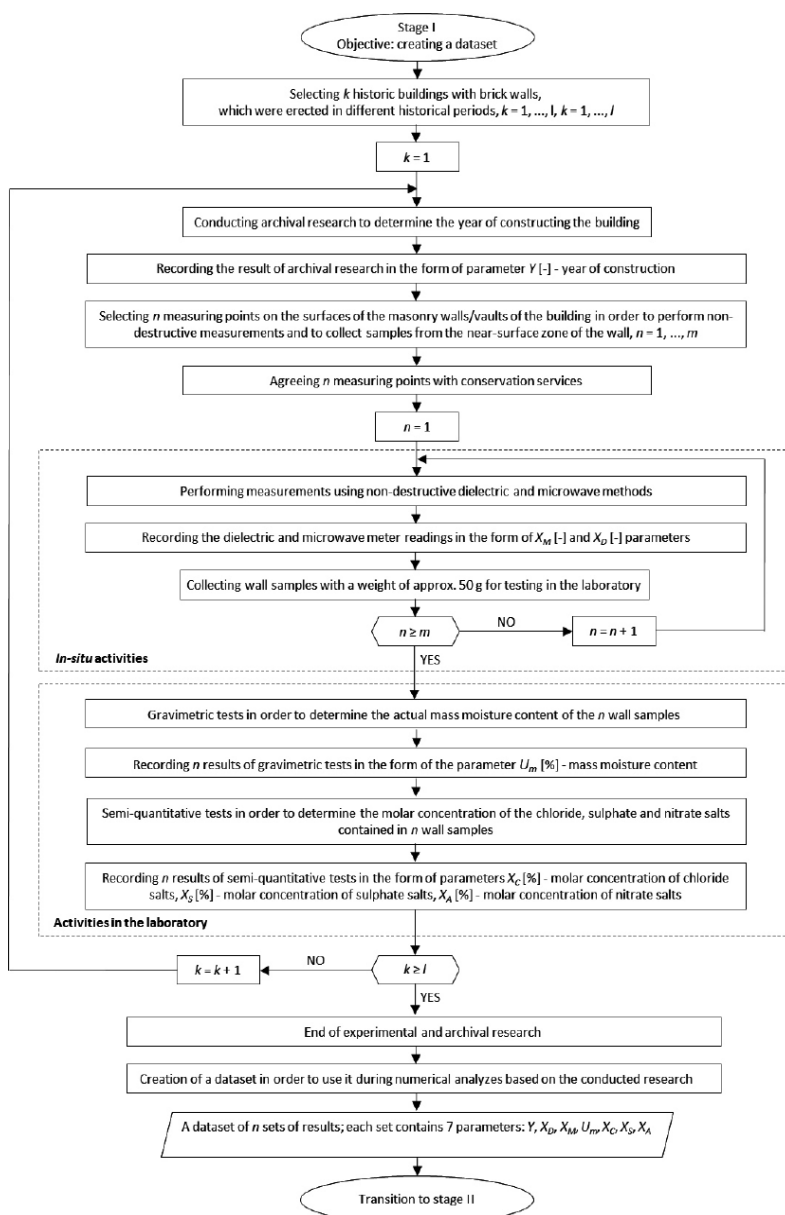


Fig. 1. Diagram showing stage I of the methodology for assessing moisture in saline brick walls in historic buildings using machine learning [14]

Rys. 1. Schemat obrazujący I etap metody oceny wilgotności zasolonych murów ceglanych w budynkach zabytkowych z wykorzystaniem uczenia maszynowego [14]

different artificial neural network learning algorithms, a random forest algorithm and a support vector method. These were selected based on a literature recognition of the application of machine learning in the field of construction [15]. The numerical analyses, published in papers [12, 13], were carried out in two variants: for a full dataset, including datasets with U_m mass moisture contents of 3% to 12% and above, and a narrowed dataset, including U_m moisture contents from 8% upwards. In doing so, I was looking to provide a more accurate neural assessment of the amount of moisture contained in walls that are heavily damp or wet, which is characteristic of some historic buildings.

Of the algorithms analysed, the following were recommended for model building in the developed methodology: **a random forest algorithm** for a given dataset, covering result sets with mass moisture content values from 3% to 12% and above, and an unidirectional multilayer artificial neural network with back-propagation error, Levenberg-Marquardt learning algorithm, with a 6-6-1 structure for a narrowed dataset, covering result sets with mass moisture content values from 8% upwards. Table 2 shows the very good values obtained for the recommended algorithms for the R, RMSE and a20-index parameters assessing the quality of the model fit to the learning data and the accuracy of the mapping. The procedure leading to the creation of the model is shown in Figure 2 and described in detail in [14].

Table 1. The dataset formed from the results of the experimental and archival studies described in the first stage of the methodology

Own study
Tabela 1. Zbiór danych utworzony z wyników badań doświadczalnych i archiwalnych opisanych w pierwszym etapie metody
Opracowanie własne

| Data set no./Nr zestawu danych | Y [-] | X_D [-] | X_M [-] | X_C [%] | X_S [%] | X_A [%] | U_m [%] |
|--------------------------------|-------|-----------|-----------|-----------|-----------|-----------|-----------|
| 1. | 1910 | 104,0 | 35,7 | 0,224 | 0,450 | 0,050 | 4,00 |
| 2. | 1910 | 73,3 | 33,8 | 0,162 | 0,300 | 0,025 | 3,76 |
| 3. | 1910 | 78,0 | 39,6 | 0,420 | 0,300 | 0,000 | 4,95 |
| ... | ... | ... | ... | ... | ... | ... | ... |
| 61. | 1850 | 168,7 | 63,6 | 0,163 | 0,400 | 0,025 | 8,37 |
| 62. | 1850 | 141,5 | 52,7 | 0,033 | 0,250 | 0,000 | 7,13 |
| ... | ... | ... | ... | ... | ... | ... | ... |
| 200. | 1400 | 125,20 | 46,20 | 0,053 | 0,700 | 0,250 | 2,83 |
| 201. | 1400 | 86,40 | 48,50 | 0,038 | 1,600 | 0,025 | 3,50 |
| ... | ... | ... | ... | ... | ... | ... | ... |
| 219. | 1280 | 129,00 | 75,30 | 0,013 | 0,200 | 0,000 | 22,61 |
| 220. | 1280 | 135,00 | 70,80 | 0,015 | 0,250 | 0,000 | 19,41 |
| 221. | 1280 | 134,00 | 57,70 | 0,014 | 0,250 | 0,000 | 15,26 |
| ... | ... | ... | ... | ... | ... | ... | ... |
| 290. | 1860 | 126,00 | 57,60 | 0,045 | 0,500 | 0,000 | 9,86 |

i metodę wektorów nośnych. Zostały one wybrane na podstawie rozpoznania literaturowego dotyczącego zastosowania uczenia maszynowego w dziedzinie budownictwa [15]. Analizy numeryczne, opublikowane w pracach [12, 13], przeprowadzone zostały w dwóch wariantach: w przypadku pełnego zbioru danych, obejmującego zestawy danych z wilgotnością masową U_m wynoszącą od 3% do 12% i więcej, oraz zawężonego zbioru danych, obejmującego wilgotność U_m od 8% w górę. Szukałam w ten sposób możliwości dokładniejszej neuronowej oceny ilości wilgoci zawartej w murach mocno zawilgoczonych lub mokrych, charakterystycznych dla części obiektów historycznych.

Spośród przeanalizowanych algorytmów, do budowy modeli w opracowanej metodzie zarekomendowane zostały: **algorytm lasów losowych** w przypadku danego zbioru danych, obejmującego zestawy wyników wilgotności masowej od 3% do 12% i więcej, oraz sztuczna sieć neuronowa jednokierunkowa wielowarstwowa ze wsteczną propagacją błędów, algorytmem uczenia Levenberg-Marquardt, o strukturze 6-6-1 dla zawężonego zbioru danych, obejmującego zestawy wyników z wartością wilgotności masowej od 8% w górę. W tabeli 2 przedstawiono uzyskane bardzo dobre wartości parametrów R, RMSE i a20-index, w przypadku rekomendowanych algorytmów oceniających jakość dopasowania modelu do danych uczących i trafność odwzorowania. Sposób postępowania prowadzący do zbudowania modelu przedstawiono na rysunku 2, a szczegółowo opisano w [14].

Table 2. Summary of R, RMSE and a20-index parameter values assessing the quality of the model fit to the learning data and the accuracy of its representation

Own study
Tabela 2. Wartości parametrów R, RMSE i a20-index oceniających jakość dopasowania modelu do danych uczących i trafność ich odwzorowania
Opracowanie własne

| Characteristics of the data and the machine learning model used /Charakterystyka danych i zastosowanego modelu uczenia maszynowego | Average value for training, testing and verification processes/Wartość uśredniona dla procesów uczenia, testowania i weryfikacji | | |
|--|--|-----------|------------|
| | R [-]* | RMSE [%]* | a20-index* |
| Large dataset including result sets with U_m values ranging from 3% to 12% and above; random forest algorithm/Duży zbiór danych obejmujący zestawy wyników z wartościami U_m w przedziale od 3% do 12% i więcej; algorytm lasów losowych | 0,984 | 1,08 | 0,77 |
| Narrowed dataset including result sets with U_m values from 8% upwards; artificial neural network/Zawężony zbiór danych obejmujący zestawy wyników z wartościami U_m od 8% w górę; sztuczna sieć neuronowa | 0,946 | 1,57 | 0,75 |

perfect R and a20-index = 1, perfect RMSE = 0/ idealne R i a20-index = 1, idealny RMSE = 0

An example of applying the method in practice

The building to which the developed method was applied is the Golden Gate in Gdansk. It was erected at the beginning of the 17th century and is now regarded as one of the most splendid monuments of the Gdansk Old Town (it was entered in the register of monuments by a decision of the Provincial Conservator of Monuments in Gdańsk in 1967). The building has two overground storeys. As the name suggests, the ground floor functions as a gate and has three passages: the main one – on the axis, and two side ones (photo). There is an unused basement under the building.

Tests to assess the moisture content of the

brick masonry of the Złota Brama building were carried out at 95 test points, where non-destructive measurements were made using dielectric and microwave methods and samples of several grams were taken from the near-surface zone of the masonry to determine the molar concentration of chloride, sulphate and nitrate salts. In addition, masonry samples weighing approximately 50 g were taken at 18 of the 95 test points for moisture testing using the gravimetric method, for which permission was obtained from the Provincial Conservator of Monuments. These samples were taken to verify the accuracy of the masonry U_{mc} mass moisture representation by the machine learning model, which was done by comparing the eighteen values generated

by the model with the eighteen actual U_m values obtained experimentally using the gravimetric method. In addition, the results obtained using both machine learning models were compared. The verification results are shown in Figure 3 and Table 3.

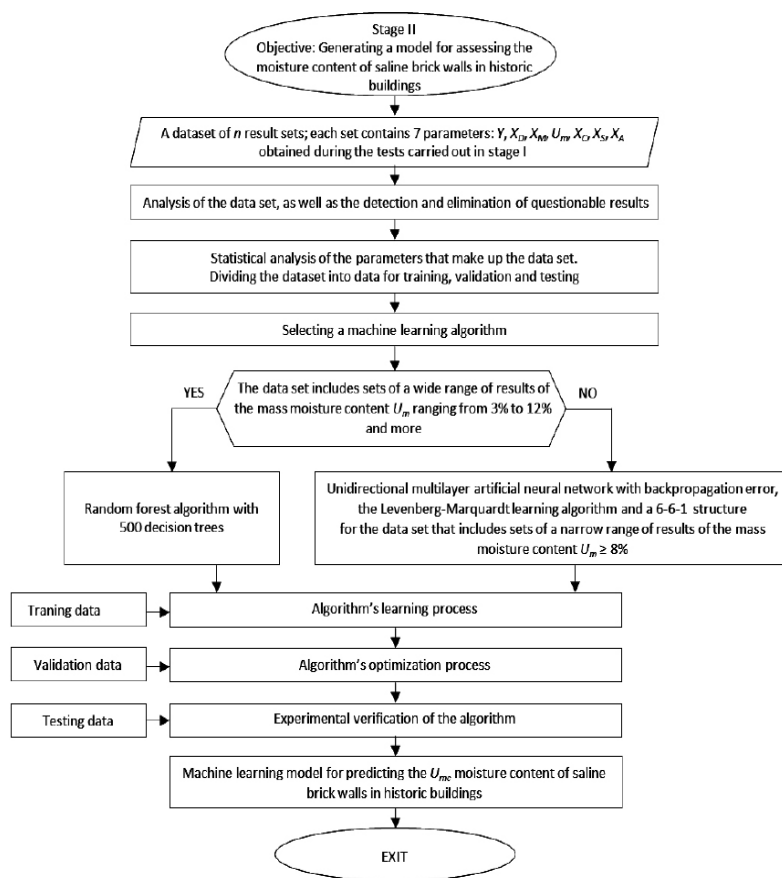


Fig. 2. Diagram showing stage II of the methodology for assessing moisture in saline brick walls in historic buildings using machine learning [14]

Rys. 2. Schemat obrazujący II etap metody oceny wilgotności zasolonych murów ceglanych w budynkach zabytkowych z wykorzystaniem uczenia maszynowego [14]



*General view of the Golden Gate in Gdansk
Photo: author's archive
Widok Złotej Bramy w Gdańsku
Fot.: archiwum autorki*

przez model z osiemnastoma rzeczywistymi wartościami U_m , uzyskanymi doświadczalnie metodą grawimetryczną. Porównano ponadto rezultaty uzyskane z zastosowań obu modeli uczenia maszynowego. Rezultaty weryfikacji przedstawiono na rysunku 3 i w tabeli 3.

Przykład zastosowania metody w praktyce

Budynkiem, w którym zastosowano opracowaną metodę, jest Złota Brama w Gdańsku (fotografia). Została ona wzniesiona na początku XVII w. i uznawana jest obecnie za jeden z najświetniejszych zabytków gdańskiej starówki (do rejestru zabytków wpisano ją decyzją Wojewódzkiego Konserwatora Zabytków w Gdańsku w 1967 r.). Budynek ma dwie kondygnacje nadziemne. Jak nazwa wskazuje, przyziemie pełni funkcję bramy i ma trzy przejścia: główne – usytuowane na osi oraz dwa boczne. Pod budynkiem znajduje się nieużytkowane podpiwniczenie.

Badania mające na

celu ocenę wilgotności ceglanych murów budynku Złotej Bramy przeprowadzono w 95 punktach badawczych, w których wykonano pomiary nieniszczące metodami dielektryczną i mikrofalową oraz pobrano kilkugramowe próbki ze strefy przypowierzchniowej muru do oznaczenia stężenia molowego soli chlorkowych, siarczanowych i azotanowych. Ponadto, w 18 spośród 95 punktów badawczych, pobrano próbki muru o wadze ok. 50 g do badania wilgotności metodą grawimetryczną, na co uzyskano zgodę Wojewódzkiego Konserwatora Zabytków. Próbkę te pobrano w celu zweryfikowania trafności odwzorowania wilgotności masowej U_{mc} muru przez model uczenia maszynowego, czego dokonano przez porównanie osiemnastu wartości wygenerowanych

The results obtained indicate that both the artificial neural network and the random forest algorithm correctly mapped the verification data. This is evidenced by the position of points along the regression lines corresponding to the ideal mapping and the obtained satisfactory values of the linear correlation coefficient R , which amounted to 0.844 for the artificial neural network and 0.801 for the random forests. The correct representation is further evidenced by the obtained small mean values of the absolute error $|\Delta U_m|$ of 1.91% and 2.15% for the model based on the artificial neural network and the model based on the random forest algorithm, respectively, as well as the not too large, for in situ studies, mean values of the relative error $|RE|$ of 14.26% and 16.18%, respectively. It should be noted that the average U_{mc} moisture values identified by both models are the same or close to the average U_m moisture value obtained by the gravimetric method.

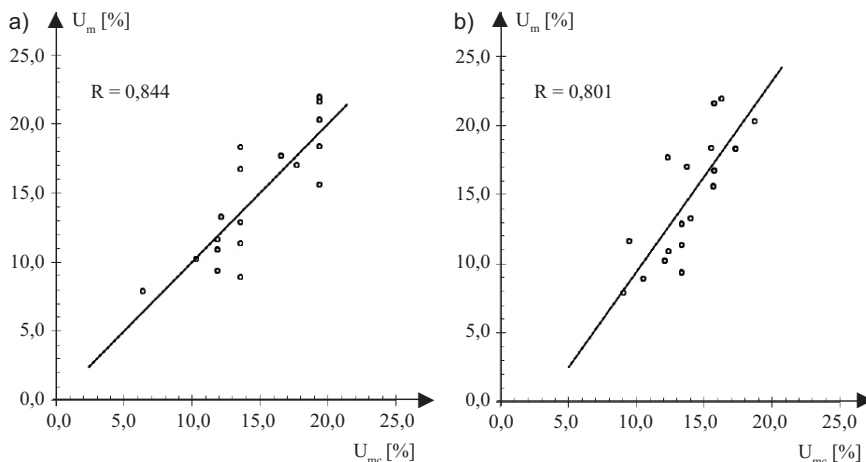


Fig. 3. Relationship between the actual U_m mass moisture content obtained by the gravimetric method and the U_{mc} moisture content identified by: a) the artificial neural network; b) the random forest algorithm [14, 16]

Rys. 3. Zależność między rzeczywistą wilgotnością masową U_m uzyskaną metodą gravimetryczną a wilgotnością U_{mc} zidentyfikowaną przez: a) sztuczną sieć neuronową; b) algorytm lasów losowych [14, 16]

Table 3. Summary of U_m and U_{mc} mass moisture values determined by the gravimetric method and using an artificial neural network and random forests, respectively *Own study*
Tabela 3. Zestawienie wartości wilgotności masowej U_m i U_{mc} określonych odpowiednio metodą gravimetryczną oraz za pomocą sztucznej sieci neuronowej i lasów losowych

Opracowanie własne

| Data set no./Nr zestawu danych | The real humidity content U_m [%]/Rzeczywista U_m [%] | The accuracy of the representation of mass moisture by the ANN model/Trafność odwzorowania wilgotności masowej przez model SSN | | | The accuracy of the representation of mass moisture by the RF model/Trafność odwzorowania wilgotności masowej przez model RF | | |
|--------------------------------------|---|--|---|--|--|---|--|
| | | U_{mc} [%] | Absolute error $ \Delta U_m $ [%]/błąd bezwzględny $ \Delta U_m $ [%] | Relative error $ RE $ [%]/błąd względny $ RE $ [%] | U_{mc} [%] | Absolute error $ \Delta U_m $ [%]/błąd bezwzględny $ \Delta U_m $ [%] | Relative error $ RE $ [%]/błąd względny $ RE $ [%] |
| 1. | 7,88 | 6,40 | 1,48 | 18,78 | 9,03 | 1,15 | 0,15 |
| 2. | 8,88 | 13,59 | 4,71 | 53,04 | 10,52 | 1,64 | 0,18 |
| 3. | 9,35 | 11,89 | 2,54 | 27,16 | 13,38 | 4,03 | 0,43 |
| 4. | 10,19 | 10,33 | 0,14 | 1,37 | 12,13 | 1,94 | 0,19 |
| 5. | 10,89 | 11,89 | 1,00 | 9,18 | 12,37 | 1,48 | 0,14 |
| 6. | 11,34 | 13,59 | 2,25 | 19,84 | 13,38 | 2,04 | 0,18 |
| 7. | 11,60 | 11,89 | 0,29 | 2,5 | 9,50 | 2,10 | 0,18 |
| 8. | 12,87 | 13,59 | 0,72 | 5,59 | 13,38 | 0,51 | 0,04 |
| 9. | 13,26 | 12,14 | 1,12 | 8,45 | 14,01 | 0,75 | 0,06 |
| 10. | 15,60 | 19,37 | 3,77 | 24,17 | 15,68 | 0,08 | 0,01 |
| 11. | 16,73 | 13,59 | 3,14 | 18,77 | 15,74 | 0,99 | 0,06 |
| 12. | 16,98 | 17,68 | 0,70 | 7,12 | 13,75 | 3,23 | 0,19 |
| 13. | 17,70 | 16,58 | 1,12 | 6,33 | 12,32 | 5,38 | 0,30 |
| 14. | 18,29 | 13,59 | 4,70 | 25,70 | 17,35 | 0,94 | 0,05 |
| 15. | 18,36 | 19,39 | 1,03 | 5,61 | 15,53 | 2,83 | 0,15 |
| 16. | 20,28 | 19,39 | 0,89 | 4,39 | 18,75 | 1,53 | 0,08 |
| 17. | 21,59 | 19,39 | 2,20 | 10,19 | 15,74 | 5,85 | 0,27 |
| 18. | 21,92 | 19,39 | 2,53 | 11,54 | 16,28 | 5,64 | 0,26 |
| Average value/Wartość średnia | 14,65 | 14,65 | 1,91 | 14,26 | 13,82 | 2,15 | 16,18 |

Uzyskane wyniki wskazują na to, że zarówno sztuczna sieć neuronowa, jak i algorytm lasów losowych poprawnie odwzorowały dane weryfikacyjne. Świadczy o tym położenie punktów wzdłuż linii regresji, odpowiadających idealnemu odwzorowaniu i uzyskane satysfakcjonujące wartości współczynników korelacji liniowej R , które w przypadku sztucznej sieci neuronowej wyniosły 0,844, a w przypadku lasów losowych 0,801. O poprawnym odwzorowaniu świadczą ponadto uzyskane małe wartości średnie błędów bezwzględnego $|\Delta U_m|$ wynoszące 1,91% i 2,15% odpowiednio w modelu na bazie sztucznej sieci neuronowej i modelu na algorytmie lasów losowych oraz niezbyt duże, jak na badania in situ, średnie wartości błędów względnego $|RE|$ wynoszące odpowiednio 14,26% i 16,18%. Należy podkreślić, że średnie wartości wilgotności U_{mc} zidentyfikowane przez oba modele są takie same lub bliskie średniej wartości wilgotności U_m , uzyskanej na drodze badawczej za pomocą metody gravimetrycznej.

Summary

The paper presents an original two-step method for assessing the moisture content of salted brick walls in historic buildings using machine learning. It was developed on the basis of my experience gained both from moisture tests carried out in a number of buildings erected in different historical periods and from analyses carried out using artificial intelligence.

The article is supplemented with an example of the application of the method to assess the moisture content of brick masonry in the Golden Gate building in Gdansk. The obtained U_{mc} moisture values, mapped by two machine learning models developed using the algorithms recommended in the method, are close to the real U_m values obtained experimentally using the gravimetric method. These results demonstrate the reliability of the method and give hope that it can be used in practice to assess the moisture content of salted brick masonry in buildings of high historical value.

Received: 29.04.2024
Revised: 27.06.2024
Published: 23.09.2024

Podsumowanie

W artykule zaprezentowano oryginalną dwuetapową metodę oceny wilgotności zasolonych murów ceglanych w budynkach zabytkowych z wykorzystaniem uczenia maszynowego. Została ona opracowana na podstawie moich doświadczeń nabytych zarówno podczas badań wilgotności, zrealizowanych w wielu budynkach wzniesionych w różnych okresach historycznych, jak i w wyniku analiz przeprowadzonych z wykorzystaniem sztucznej inteligencji.

Artykuł wzbogacono o przykład zastosowania metody do oceny wilgotności murów ceglanych w budynku Żłotej Bramy w Gdańsku. Uzyskane wartości wilgotności U_{mc} odwzorowane przez dwa modele uczenia maszynowego, opracowane z wykorzystaniem rekomendowanych w metodzie algorytmów, są bliskie wartościom rzeczywistym U_m , uzyskanym doświadczalnie metodą grawimetryczną. Rezultaty te świadczą o wiarygodności metody i dają nadzieję na możliwość jej wykorzystania w praktyce do oceny wilgotności zasolonych murów ceglanych w budynkach o dużej wartości historycznej.

Wpłynął do redakcji: 29.04.2024 r.
Otrzymano poprawiony po recenzjach: 27.06.2024 r.
Opublikowano: 23.09.2024 r.

Literature

- [1] Ksit B. Diagnostyka wilgotności obiektów budowlanych. In: Drobiec Ł, editor. Naprawy i wzmocnienia konstrukcji, Budownictwo ogólne, Tom I, Wykłady. XXXVIII Ogólnopolskie Warsztaty Pracy Projektanta Konstrukcji, Wisła, 9–12.04.2024 r. Polski Związek Inżynierów i Techników Budownictwa: 2024. pp. 215–243.
- [2] Trochonowicz M, Szostak B, Lisiecki D. Analiza porównawcza badań wilgotnościowych metodą chemiczną w stosunku do badań grawimetrycznych wybranych materiałów budowlanych. *Budownictwo i Architektura*. 2016; 15: 163–171.
- [3] Hussain A, Akhtar S. Review of Non-Destructive Tests for Evaluation of Historic Masonry and Concrete Structures. *Arabian Journal for Science and Engineering*. 2017; <https://doi.org/10.1007/s13369-017-2437-y>.
- [4] Sandrolini F, Franzoni E. An operative protocol for reliable measurements of moisture in porous materials of ancient buildings. *Building and Environment*. 2006; <https://doi.org/10.1016/j.buildenv.2005.05.023>.
- [5] Matkowski Z. Badania wilgotności i zasolenia murów oraz sklepień ceramicznych w historycznym obiekcie podziemnym. *Materiały Budowlane*. 2022; <https://doi.org/10.15199/33.2022.11.48>.
- [6] Martínez-Garrido MI, Fort R, Gómez-Heras M, Valles-Iriso J, Varas-Muriel MJ. A comprehensive study for moisture control in cultural heritage using non-destructive techniques. *Journal of Applied Geophysics*. 2018; <https://doi.org/10.1016/j.jappgeo.2018.03.008>.
- [7] Hoła A. Methodology for the in situ testing of the moisture content of brick walls: an example of application. *Archives of Civil and Mechanical Engineering*. 2020; <https://doi.org/10.1007/s43452-020-00120-3>.
- [8] Pala A, Hoła J. Influence of burnt clay brick salinity on moisture content evaluated by non-destructive electric methods. *Archives of Civil and Mechanical Engineering*. 2016; <https://doi.org/10.1016/j.acme.2015.08.001>.
- [9] Valero LR, Sasso VF, Vicioso EP. In situ assessment of superficial moisture condition in façades of historic building using non-destructive techniques. *Case Studies in Construction Materials*. 2019; <https://doi.org/10.1016/j.cscm.2019.e00228>.
- [10] Balík L, Kudrnáčová L, Pavlík Z, Černý R. Application of infrared thermography in complex moisture inspection of the Schebek Palace. *AIP Conference Proceedings* 1866. 2017; <https://doi.org/10.1063/1.4994482>.
- [11] Muradov M, Kot P, Markiewicz J, Łapiński S, Tobiasz A, Onisk K, Shaw A, Hashim K, Zawieska D, Mohi-Ud-Din G. Non-destructive system for in-wall moisture assessment of cultural heritage buildings. *Measurement*. 2022; <https://doi.org/10.1016/j.measurement.2022.111930>.
- [12] Hoła A, Czarnecki S. Brick wall moisture evaluation in historic buildings using neural networks. *Automation in Construction*. 2022; <https://doi.org/10.1016/j.autcon.2022.104429>.
- [13] Hoła A, Czarnecki S. Random forest algorithm and support vector machine for nondestructive assessment of mass moisture content of brick walls in historic buildings. *Automation in Construction*. 2023; <https://doi.org/10.1016/j.autcon.2023.104793>.
- [14] Hoła A. Methodology of the quantitative assessment of the moisture content of saline brick walls in historic buildings using machine learning. *Archives of Civil and Mechanical Engineering*. 2023; <https://doi.org/10.1007/s43452-023-00679-7>.
- [15] Sun H, Burton HV, Huang H. Machine learning applications for building structural design and performance assessment: State-of-the-art review. *Journal of Building Engineering*. 2021; <https://doi.org/10.1016/j.jobe.2020.101816>.
- [16] Hoła A. Verification of Non-Destructive Assessment of Moisture Content of Historical Brick Walls Using Random Forest Algorithm. *Applied Sciences*. 2023; <https://doi.org/10.3390/app13106006>.