

Tomasz RYMARCZYK
Grzegorz KŁOSOWSKI

APPLICATION OF NEURAL RECONSTRUCTION OF TOMOGRAPHIC IMAGES IN THE PROBLEM OF RELIABILITY OF FLOOD PROTECTION FACILITIES

ZASTOSOWANIE NEURONOWEJ REKONSTRUKCJI OBRAZÓW TOMOGRAFICZNYCH W PROBLEMATYCE NIEZAWODNOŚCI ZABEZPIECZEŃ PRZECIWPOWODZIOWYCH*

The article presents an innovative concept of enhancing the flood embankments and landfills monitoring. The key advantage of such a solution is to obtain a more detailed distribution of components within a flood barrier. It leads to more early and sufficient threat detection, considering the exploitation of the building, thus - a vast enhancement of an embankment's performance. The method is based on implementing a neural system, composed of a number of parallelly-working neural networks. Each of them generate a singular point of final output view. By implementing such monitoring measures it is possible to successfully reconstruct two-and-three dimensional models of flood barriers and dams - including possible breaches and damages within its inner structure. An important advantage of such a solution is the possibility of replacing the systems that monitor hydrotechnical facilities pixel-by-pixel by neural imaging. The performed research leads to solving the problem of low resolution of such images. As this problem was of crucial value to tomographic imaging method, it was a main obstacle to the development of neural reconstruction method. Moreover, as the results may be obtained in real-time and at various levels, these new functionalities stand out in comparison to currently used methods for monitoring protective banks.

Keywords: *electric tomography, flood embankments and landfills, hydrotechnical facilities exploitation, neural networks, numerical methods.*

W artykule zaprezentowano nowatorską koncepcję usprawnienia monitoringu wałów i zapór przeciwpowodziowych. Główną przewagą nowego rozwiązania nad znanymi metodami jest uzyskanie dokładniejszego rozkładu komponentów wnętrza zapory, co zasadniczo przyczynia się do wczesnego i niezawodnego wykrycia zagrożeń związanych z eksploatacją tego typu budowli. Dzięki temu, zastosowanie nowej metody spowoduje wzrost niezawodności zabezpieczeń przeciwpowodziowych. W opisywanej metodzie założono wytrenowanie systemu neuronowego złożonego z wielu działających równolegle sieci neuronowych, z których każda generuje pojedynczy punkt obrazu wyjściowego. Powyższy sposób, uwzględniający jednoczesne zastosowanie wielu sieci neuronowych, umożliwia skuteczną realizację trudnych zagadnień rekonstrukcji obrazów dwu i trój-wymiarowych, w tym obrazowanie uszkodzeń i przecieków wnętrza zapór przeciwpowodziowych. Ważną zaletą prezentowanej metody jest możliwość zastąpienia obrazowaniem neuronowym wielu innych, obecnie stosowanych systemów, które monitorują budowle hydrotechniczne w sposób punktowy. Przeprowadzone badania umożliwiają rozwiązanie problemu niskiej rozdzielczości obrazów tomograficznych, co stanowi główną barierę rozwoju tych metod w odniesieniu do dużych budowli ziemnych. Poprawa rozdzielczości rekonstruowanych obrazów, a także możliwość ich uzyskiwania w różnych przekrojach w czasie rzeczywistym, są nowymi funkcjonalnościami, które wyróżniają obrazowanie neuronowe na tle obecnie stosowanych metod monitoringu wałów i zapór przeciwpowodziowych.

Słowa kluczowe: *tomografia elektryczna, zapory i wały przeciwpowodziowe, eksploatacja budowli hydrotechnicznych, sieci neuronowe, metody numeryczne.*

1. Introduction

The exploitation of flood defences - such as dams and flood banks - is of key value that heavily impacts the security of people, animals and plants that lay within the area of the object. There are two main types of issues that may appear as a result of improper exploitation of such pieces of infrastructure. The first threat is a physical damage of the embankment, which may result in a breach. The other is the leakage of such a structure - in case of reservoirs that contain fluid chemical compound waste it might lead to a vast range of contamination. Both types of breaches may result in [25]:

- endangering both people and animals' lives and cause an evacuation;
- closing public responsibility facilities, such as administration, hospitals or schools;
- increasing the possibility of epidemic, epizootic or epifitotic outbreaks;
- increasing the possibility of a plague of insects or rodents;
- destruction of stock and harvest in agricultural holdings (weakening the economical state of food industry, an increase of food supplies prices, a need to compensate the entrepreneurs who process and sell food);

(*) Tekst artykułu w polskiej wersji językowej dostępny w elektronicznym wydaniu kwartalnika na stronie www.ein.org.pl

- destruction and damaging buildings (houses, utility buildings and public utility buildings);
- infrastructural damage (including roads, bridges, fly-overs, tunnels, dams, pumping stations, hydrotechnical devices, water mains and sewer networks-related devices);
- destruction in energy-production infrastructure - including generation, transmission and distribution of electricity and heating;
- disruptions in the functioning of communication and teleinformation systems;
- damage dealt to communication traction, accidents caused in industrial plants;
- malfunctioning of the fuel distribution system;
- possible increase in criminality as well as an increased number of common offenses (such as burglary, robberies, property destruction).

What is more, the penetration of chemical waste through embankments creates such hazards as the possibility of local environment contamination, as well as damage to installations and technical equipment. Also, it may cause a release of harmful substances and - consequently - a degradation of the natural environment.

Floods are considered to be natural disasters that cause particularly many tragedies [3, 7]. One of the means of ensuring the safety of flood-endangered areas near the flotation tailings landfills and rivers is to raise the flood embankments [18]. Considering the insufficient filtration capacity of the embankment, the high water level may cause leaks, which results in partial or complete destruction of the hydro-technical building [19].

As breakdowns lead to serious consequences, such technical facilities such as dams, embankments and other flood defences are equipped with various systems to increase their reliability. Embankment and dam exploitation systems include both adequate means of service as well as a code of operating activities designed as a set of strict procedures and instructions. This kind of guide set a universal standard which should be followed. These include, among others, tips regarding the frequency and method of inspections, tests, measurements and technical inspection of the facility, as well as a list of hydrotechnical building elements to be observed - along with a list of parameters that should be measured. The aforementioned registry constitute evidence of keeping constant observation, monitoring and measurements which are key elements of embankments and flood control dams. In most cases, flood protection security systems are extensive and vastly complex. They consist of many subsystems whose proper functioning affects the reliability of these objects. Typical subsystems included in embankments and flood control systems include hydrological protection systems, alarms, energy systems, mechanical water flow regulation systems and, as well as computer-aided decision support software.

In order to ensure effective monitoring of these systems, appropriate methods should be used. Computer-aided decision support systems play a special role in the integration of other pieces of software as well as decision-making automation. The latter consists of identifying and forecasting specific threats together with the probability of their occurrence. The final decision regarding the response to the results is always made by a human. Below, there are listed currently used monitoring methods - in the context of the Extraction Waste Treatment Facility Żelazny Most KGHM POLSKA MIEDŹ S.A. It is the largest hydrotechnical facility in Poland and one of the largest facilities of this type in the world. The monitoring methods used there can be divided into two groups: means related to the current behavior of the structure and its reliability, and those related to the impact of the structure on the surrounding natural environment. The first group includes the following monitoring methods: visual assessment of technical condition (direct observation carried out by employees),

geodetic monitoring (detection of structural deformation by manual measurements with benchmarks and automatic using micromirrors), geotechnical monitoring (detection of anomalies in the geological structure of the native substrate embankments and reservoirs through deep drilling and pressure probes), hydrogeological monitoring (detection of anomalies which result in embankment leakage by observing piezometric pressures in piezometers installed in the waste mass, embankments and near and far foreground), seismic monitoring (detection of structural stability disturbances by means of accelerometers that are triggered each time they identify vibrations at a certain level), information systems for the analysis of large data sets (Big Data). The prevention on surrounding natural environment include hydrological monitoring (detecting leaks) and chemical monitoring (detection of contamination that affects groundwater).

The global trend of IT and communication technology development is reflected in the increase in the importance of IT flood protection systems. The extensive measurement systems provide a great deal of data collected from different points of flood defence. One of the main tasks of IT systems installed in hydrotechnical facilities is to create mathematical models based on the information provided. Currently used IT systems implement a wide variety of methods. The deterministic methods include the Fellenius one, which makes it possible to assess the degree of embankment stability by dividing the potential landslide mass into vertical blocks (belts). This method is also known as the Petterson-Fellenius or the Swedish method [4]. An example of a statistical quantitative method is the HST model (Hydrostatic-Season-Time). The empirical HST model is widely used for the analysis of various types of measurement data on flood embankments and dams [6]. Another group of methods used to improve the risk of flood barriers breach are probabilistic ones. It may be exemplified by the first order reliability method (FORM), by means of which the mode of longitudinal damage of a long embankment consisting of homogeneous soils can be examined [9]. In order to increase the reliability of earth structures, together with the FORM method the Hasofer-Lind reliability index can be applied [13]. Harmonic analysis is also one of the methods used in exploitation processes [11].

A frequent problem with flood dams is insufficient water filtration causing the so-called sub-penetration. In the literature one can find propositions of methods to calculate the probability that such phenomena will occur [15].

Another group of intelligent stochastic methods used by IT systems in order to increase the reliability of exploitation processes, including embankments and flood barriers, are heuristic methods based on fuzzy logic [14, 22, 24]. Less frequently used methods to obtain the same purpose are: integer linear programming [10], Support Vector Machine [17], non-linear criterion of shear stability [23], and artificial neural networks (ANN) [1, 8]. Currently, the main application area of ANN are predictive issues which aim at enhance exploitation processes by identifying [16] or classifying faults [26].

As previously mentioned, flood protection facilities belong to the category of hydrotechnical constructions. The analysis of procedures and rules of exploiting this type of objects allows to notice one of the main processes that ensure a proper course of operations, being observation of current behavior and phenomena detection. Due to their specificity, they may indicate irregularities threatening the safety of the building. Current methods of monitoring technical facilities such as flood banks and dams have, however, numerous disadvantages. The first of them are apparently high usage costs. Most of the currently used methods require the involvement of specialists, which means that labor is an important element of such expenses. In addition, the measurement systems require investments for repairs, maintenance, spare parts and materials that wear out. Also, an important disadvantage is usually a late threat detection. In the case of systems that are not a component of integrated IT systems, information about the threat reaches the relevant services within a few hours' delay. The delay de-

depends on the frequency with which the readings of the measuring devices are included in the procedures. The effectiveness of monitoring methods that are by now implemented is also insufficient [4, 5]. Due to the point character of the measurements, there is a great uncertainty of the conclusions drawn on their basis. Probes and sensors placed in various places on the embankment do not give the possibility of obtaining full knowledge about its current state. There is a serious risk that defects appearing inside the flood dam (cracks, changes in the internal structure, changes in composition and density of the earth, etc.) will not be detected early enough to enable them to be corrected. In order to get the most complete knowledge about the technical condition of the facility, it is necessary to use many monitoring methods at the same time. In order to simplify the way of monitoring the facility and the application procedure, there is a clear need to develop one effective method, ensuring the speed and reliability of collecting, transferring and processing of information about existing threats. Most of the mentioned disadvantages would be eliminated if it was possible to develop a new method of technical condition assessment that would gather a current stream of data concerning differences in the internal structure of the flood defence. One of the potential methods to achieve this goal is electrical tomography [2, 12]. The tomography generates the image of the tested object interior. This method is mainly used in medicine and material engineering. The main obstacle of tomographic methods development in flood embankments and dams monitoring is the lack of appropriate technology that would provide a significant improvement in image resolution.

This article presents a new approach to the operational problem of object monitoring using neural imaging. Previous attempts to use artificial neural networks in electrical tomography have focused on the use of individual neural networks to process input signals into images. During the research, an improved method of neural tomographic reconstruction was developed. Its characteristic feature is the usage of a neural network system in which each network generates the color of a single pixel on the image grid. Thanks to the original architecture of the intelligent imaging system, a new functionality was obtained with reference to known tomographic methods, which consisted in increasing the resolution of cross-section images of scanned hydrotechnical objects.

2. Neural reconstruction of tomographic images

The neural reconstruction of tomographic images presented in this article is a new method aimed at increasing the resolution of images, and thus enhancing the flood protection monitoring effectiveness. The algorithm makes it possible to eliminate the main operational problems of hydrotechnical facilities connected with their monitoring. Tomography supported by a neural system gives new possibilities for surveillance. The presented concept create an accurate, three-dimensional image of the interior of a hydrotechnical building in real time. This is the key functionality that lessens the importance of maintaining the majority of existing subsystems of flood protection monitoring. Currently used monitoring systems (geodetic, geotechnical, hydrological, etc.) relate to obtaining point data regarding selected object parameters. Later on, obtained incomplete information is subject to analysis, both by IT systems and by specialists who perform the final assessment of the dam condition. Such an assessment process has major disadvantages resulting from measuring points, measurement errors, lack of real-time monitoring and subjectivism in evaluating the status of the subject technical object. The method depicted in this article is free from the above restrictions, as it results in obtaining sharp, colorful, three-dimensional images of the interior of the dams and flood dams bodies in high resolution and in real time. The obtained images are easy to analyze because they faithfully reproduce all changes taking place inside flood embankments and dams. Phenomena such as: cracks, changes in the structure of internal layers, moisture increase or

density changes are immediately visible. The comparison of images recorded at regular intervals make it possible to determine the pace of changes that are taking place within the structure. This is a very valuable functionality because it provides a solid basis for making accurate and reliable predictions about the sources, directions of development, type and area of damage developing inside the building.

3. Neural system to reconstruct tomographic images - modelling

The presented solution is an improvement of the already known electrical tomography. A number of electrodes are placed in the body of the flood embankment. Then, a source of electric current with certain parameters (voltage, current, frequency, amplitude) is connected to different electrodes. The voltage values between the respective electrodes are read and recorded. The aforementioned voltage values are the input vector, on the basis of which the neural system generates images of the interior of the dam. It is assumed that the values of electric parameters read out from electrodes are closely dependent on the material from which the flood defence is made. Any changes in the internal structure of the dam caused by moisture, leakage, structure breakage, landslides and any other anomalies, are reflected in the values of the current-voltage parameters read from the electrodes. To confirm the above assumptions, a mechanism for converting electrical signals into high-resolution color images has been developed.

3.1. The means of data gathering

The real-life object of the research was the barrage of the Źelazny Most Flotation Wastes Depository located in the south-western part of Poland between Lubin and Głogów. The reservoir is located in a natural valley between moraine hills in the upper part of the Rudna river catchment. The management of the disposal facility is KGHM "Polska Miedz" S.A. Branch Hydrotechnical Plant in Rudna [21]. The "Źelazny Most" facility is intended for storing flotation waste from the Red Ore Enrichment Plants: Polkowice, Lubin and Rudna. Currently, it is the only place for depositing flotation waste from all mines. Due to the area occupied, the "Źelazny Most" landfill is one of the largest facilities of its kind in the world [20]. The total length of dams surrounding the reservoir is over 14 km. The total area of the landfill is 1410 ha. The height of the dams at the highest point reaches 55 m. The topographic model of the Źelazny Most reservoir is shown in Fig.1.




Fig. 1. Topological model of the Źelazny Most Flotation Wastes Depository

The facility has been equipped with various diagnostic and control-measurement systems, whose task is to ensure a high degree of reliability of the Źelazny Most reservoir. These include: drainage, systems for rapid and emergency dewatering of the basin, embankments and relief wells whose task is to reduce the water pressure in the soil of the ground. Around the „Źelazny Most” facility, constant surveil-

lance is carried out on a regular basis. The monitoring concerns both surface and underground waters. The imperfection of currently used methods of monitoring is their punctuality. By using them, you cannot get cross-sectional images of the interior of the dam. Fig. 2 shows a photo of an earth embankment of the reservoir with visible elements of various measurement systems that provide point data enabling on-going monitoring of the building.



Fig. 2. Surface of the earth embankment around the Želazny Most reservoir

The key element of the neural system used to reconstruct tomographic images is a neural controller. Its task is to convert electrical signals into images. A proper set of training data was needed to implement the neural system. Due to the fact that it was not possible to download this type of data directly from the embankment of the Želazny Most reservoir, a physical model of the flood embankment part was created in the laboratory conditions. By doing so, the examined features of the real object such as: dam material, geometry of shape, proportions of dimensions, water level in tank were reproduced. Thus, research data from many measuring cases was obtained. The data included sets (vectors) of current-voltage drops values and images of cross-sections of the barrier corresponding to these sets. Fig. 3 shows the earth model of a part of an embankment with the Electrical Impedance Tomography (EIT) system, which includes: electrode system, electronic voltage distribution module for individual electrodes and a module for recording results. The glass panes of the terrarium made it possible to observe the changes taking place in the mass of the earth embankment caused by seepage. Thanks to the possibility of observing the interior of the earth dam, it was possible to gather a large set of data containing vectors of electrical parameters and images assigned to these vectors.




Fig. 3. The physical model of the Želazny Most reservoir dam

In the dam model, 16 electrodes were placed to cover the entire embankment width. As a result, by placing rows of electrodes spaced apart at equal distances, the entire length of the barrier can be covered with the EIT system. The arrangement of the rows of electrodes in the dam is presented in Fig. 4.




Fig. 4. Scheme of the flood embankment with the electrodes placed on it

3.2. The concept of the neural system

The neural system of tomographic image reconstruction is the original concept of a system that contains many neural networks. When run in parallel, they generate an image consisting of single points. Each of the output image points is the effect of an independent, separately trained neural network. By using this method, two-dimensional (2D) and three-dimensional (3D) images are generated. From the point of view of the mechanism of creating the output image, the difference between 2D and 3D images depends on the number of pixels that make up a single image. In the case of 3D images, these points are vastly more numerous than in the case of 2D images.

As mentioned before, the EIT system that was touched upon consisted of a set of 16 electrodes, which generated 208 voltage drops during each measurement. The measurements read thanks to the electrodes placed in the body of embankment, made it possible to determine the conductivity of the tested object, which is variable depending on such factors as e.g. moisture level, heterogeneity of the structure or the type of soil. The illustrated cross-section of the embankment has been divided into a grid of pixels generated as triangular elements by means of the finite element method. In the case of 2D imaging, the pixel grid of the initial image counted 2012 points, while in the case of a three-dimensional image a spatial grid of 17869 points was used. The first case is presented in Fig. 5. In the upper part of the drawing, the locations of the electrodes are marked. The 3D case is presented in Fig. 6. The density of the grid points around the electrodes serves to more accurately reflect the changes taking place inside the depicted flood bank.

Fig. 7 and 8 present the method of operation of a neural system that converts electrical signals from electrodes into 2D and 3D images. The input vector contains 208 measuring cases (1). Each single measurement case corresponds to a certain amount of voltage drop for a given pair of electrodes.

$$U = [\alpha_1, \alpha_2, \alpha_3, \dots, \alpha_{208}]^T \quad (1)$$

The U vector is the input vector for all artificial neural networks (ANN) included in the neural system.

The design of the neural model was based on the following assumptions:




Fig. 5. Grid of the output 2D image of the flood barrier section (counting 2012 points)




Fig. 6. Grid of the output 3D image of the flood barrier section (counting 17869 points)




Fig. 7. A mathematical neural model for converting electrical signals into 2D images




Fig. 8. A mathematical neural model for converting electrical signals into 3D images

1. Each point of the output image is generated by a separate artificial neural network with 208 voltage drop values. The output of each of the neural networks is a single real number corresponding to the conductivity value of a single element of the reconstructed image (in the visual form represented by the appropriate color of the assumed scale of conductivity).
2. A mutual relationship between individual points of the output image is assumed. Therefore, any neural network that generates the value of a single image element can be trained independently, with randomly generated initial weights and biases.
3. Neural networks assigned to elements of the output image can solve both classification and regression problems. In the case of a classification issue, the generated image may be

monochrome or have several colors / shades. Then the classifier assigns a given pixel to a specific color. If the network implements the regression problem, the output generates a real number, corresponding to the conductivity value of the given element. This type of imaging is the most desirable, but this network layout is the most difficult to train. Neural systems described in this paper deal with regression issues.

During the research, many trials were carried out, taking into account various configurations of the neural multi-layered perceptron. In particular, variants were analyzed taking into account changes in the following factors affecting the efficiency of the neural system: selection of network training algorithm, number of hidden layers and number of neurons in each layer of the network, parameters of the perceptron (learning factor, maximum number of incorrect validations, momentum and others). The possibility of using new solutions in the field of convolutional neural networks (CNN) was also analyzed. The research results showed that CNN networks are ineffective in this case due to insufficient data input - especially in comparison to the high resolution of the output image.

Due to the large amount of data and the need to train several thousand neural networks (for the 3D model), the implementation of the above concept required the use of fast algorithms including parallel computations and computers with high computing power.

3.3. Training process of the selected neural network

The analysis of the training process for the selected neural network included in the neural system for the reconstruction of the 2D image is presented below. In this case, the complete neural system counted 2012 separately trained ANNs. Due to the large number of networks, in this study it is impossible to present the learning process of all artificial neural networks.

Fig. 9 presents a diagram of the used model of the neural network. The network has 208 inputs, 10 neurons in the hidden layer and 1 neuron in the output layer. The hidden layer uses a logistic transfer function. In the output layer, the transfer function is linear.

Table 1 presents the results of training one neural network, selected randomly from the system integrating 2012 networks. Presented network generates on the output a single pixel of the output image. The total number of cases used in the network training process was 10442. All cases were randomly divided into 3 sets: training, validation and




Fig. 9. A neural network model that generates a single point of the output image

Table 1. The division of data into sets and results of the training process

Division of the data set	The number of cases in a given set	Mean Squared Error (MSE)	Regression (R)
Learning set (70%)	7310	$1.35760 \cdot 10^{-3}$	0.997303
Validation set (15%)	1566	$5.84343 \cdot 10^{-3}$	0.988642
Test set (15%)	1566	$6.88341 \cdot 10^{-3}$	0.987701

test in the following proportions: 70%, 15%, 15%. The validation set was used to determine the moment of stopping the training process. It is used to verify the quality of the obtained network. The training process ends when the gradient change dynamics approaches zero.

The Mean Squared Error (MSE) reflects the mean square difference between the outputs and the reference values. The lower the MSE values, the better. Zero MSE means no error. The training set was burdened with the lowest learning error, which is the most common and correct situation. The low MSE error of the training set results from the fact that the weight of the network is best adapted to the training cases. The highest medium-squared error (MSE) of $6.88341 \cdot 10^{-3}$ occurred with reference to the test set. A slightly smaller MSE error of $5.84343 \cdot 10^{-3}$ was recorded for the validation set. The smallest error was noted in relation to the training set.

Another analyzed network quality indicator was the regression of R. R = 1 means full compliance of the outputs with the patterns, while R = 0 means the lack of connections between them. The regression coefficient merit for all three sets was very high, close to 1. This proves the high ability of the network to knowledge generalization (that is, the correct conversion of input data to output information not only for the training set).

The results obtained as a result of checking the network on the test set are the most reliable indicator of the effectiveness of a given network, because cases from this set do not participate in the learn-

ing process. Good MSE and R indices for the test and validation test indicate lack of over-training.

Fig. 10 presents correlation diagrams of the considered network. As you can see the difference beyond the reference lines is noticeable, however the number of cases away from the reference line is not large. This is evidenced by the overlapping correlation lines for all considered sets: the training, validation and test sets, and collectively (for all three sets).

Fig. 11 presents the mean square error (MSE) diagrams recorded during the network training process. MSE values are low. The relatively regular shape of the lines (no large fluctuations) indicates the




Fig. 11. MSE error charts for the training, validation and test sets

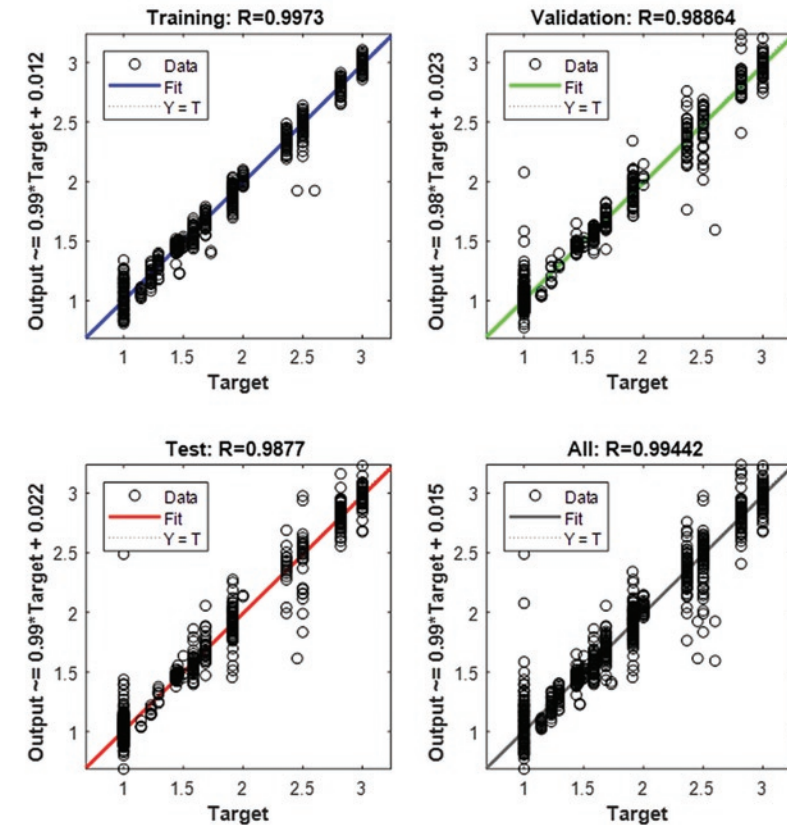


Fig. 10. Correlation diagrams of a neural network

lack of overfitting and thus the high efficiency of the developed system of tomographic reconstruction of the image. The hyperbolic shape of the curves indicates a sufficient number of training cases. The chart marks the thirtieth epoch (iteration) on which the learning of the network was completed. This is the iteration in which the MSE error of the validation set has reached its minimum.

Fig. 12 presents a histogram of errors (differences) between the values generated by the network and the patterns. Each vertical bar indicates the number of deviations from the reference value. As you can see, the largest number of deviations are very small errors, with values close to zero. The shape of the histogram is similar to the normal distribution curve. This fact also confirms the high quality of the received solution.

4. Results of research on the neural system of reconstructing tomographic images

As part of the research work, two neural models of tomographic image reconstruction systems have been developed. The first model realized the issues of flat (2D) imaging, while the second model generated spatial (3D) images. This chapter presents the effects of both neural network systems.

In Table 2a in two columns, the patterns and reconstructed images generated by the 2D controller are summarized. Table 2b presents a graphical representation of differences in the values of individual pixels between the reference images and reconstructed images presented in




Fig. 12. Histogram of network error learning process

When analyzing table 2a, it can be seen that the resulting images accurately represent the shapes and colors of the reference images. In the case of the 2D model, the numerical values of the pixels of the reference image were real numbers belonging to the range from 1 to 3. From Table 2b, the values of errors of images reconstructed with respect to their patterns can be read. You can see that most pixels on the grid do not contain errors (no color). In the case of deviations greater than zero, most errors do not exceed 0.2.

Table 3a presents a comparative analysis of reconstructed 3D images. High accuracy of mappings for all five presented cases is also visible here. The spatial grid of the 3D model has as many as 17869 points. The numerical values of the pixels of the reference image were real numbers that belong to the range from 1 to 2. Table 3b shows the values of errors of images reconstructed with respect to their patterns. Most pixels on the grid do not contain errors (no color). As in the 2D model, non-zero deviations in most cases do not exceed 0.2.

5. Conclusion

The article presents the original concept of a neural system for the reconstruction of tomographic images. The effectiveness of the method has been verified based on the conditions of the “Żelazny Most” Flotation Wastes Depository. Taking into account the key structural features of the Żelazny Most technical facility, a physical model of the flood embankment part was developed. The above model was equipped with an electrode system and the necessary tomography devices (EIT), which enabled the execution of many measurements of electrical quantities and the allocation of cross-sections of the investigated embankment model to those sizes. The data obtained in this way was used to train the neural network system. An innovative feature of the solution is the separate training of a large number of neural networks in the amount corresponding to the resolution of the reconstructed image mesh.

During the laboratory experiments two models of reconstruction of tomographic images were developed - flat (2D) and spatial (3D). The obtained results indicate that the presented method of neural imaging can be effective both in the case of two- and three-dimensional reconstruction. The application of a system of many separate neural networks operating simultaneously to depict the cross-section of the embankment damage enabled the generation of exact mappings of the given patterns. The quality of these mappings is sufficient to correctly identify the nature of threats, as well as to assess the rate of changes taking place inside the flood embankment.

Taking into account the possibility of taking measurements at regular intervals, the rate of leakage spreading can be easily determined. The above information enables not only an accurate diagnosis useful for determining the embankment’s reliability level, but also an effective forecast of the moment of the coming disaster. Thanks to information obtained by the use of neural imaging system, it is possible to appropriately plan actions to prevent damage to flood protection facilities.

Acknowledgment

The authors would like to thank the authorities and employees of the Institute of Mathematics, Maria Curie-Skłodowska University, Lublin, Poland for sharing supercomputing resources.

Table 2a. Results of 2D imaging

ID	The cross-sectional patterns of the flood embankment	The images reconstructed by using a neural generator
1		
2		
3		
4		
5		

Table 2b. Differences in 2D imaging results

ID	Differences between the pattern image and the reconstructed image
1	
2	
3	
4	
5	

Table 2a. The color scale in the illustrations in Table 2b reflects differences in the conductivity between the elements of the reference images and the elements of the reconstructed images.

In Table 3a, the patterns and reconstructed images generated by the 3D controller are compared in a similar way. Table 3b presents a graphical representation of differences in the values of individual pixels between spatial model images and reconstructed images presented in Table 3a.

As in Table 2b, the color scale in the illustrations in Table 3b reflects differences in conductivity between the elements of the reference images and the elements of the reconstructed images.

Table 3a. 3D imaging results

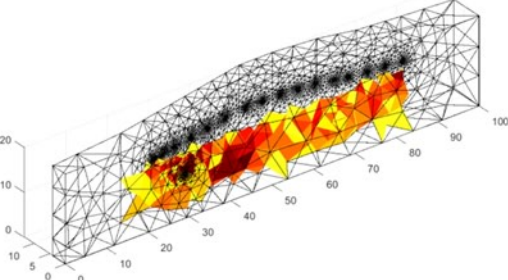
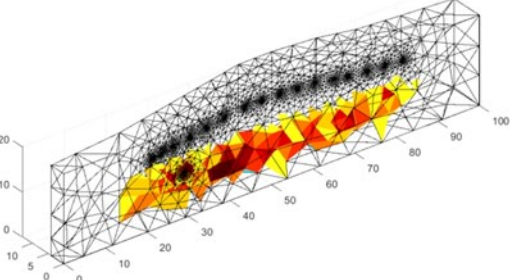
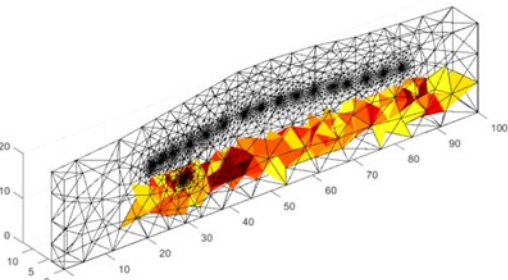
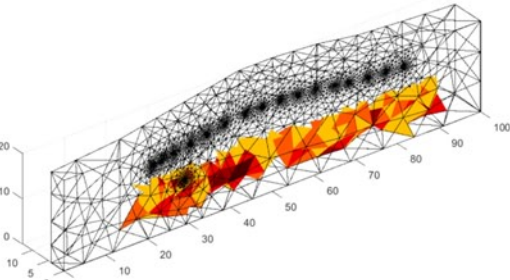
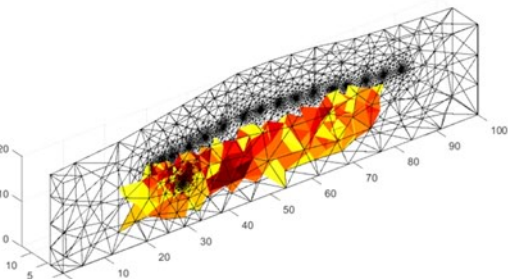
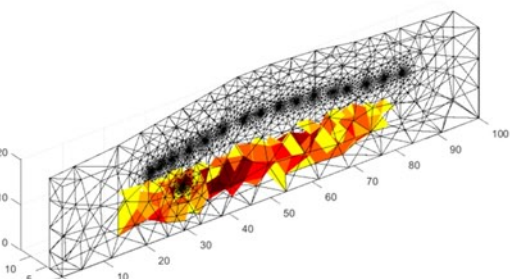
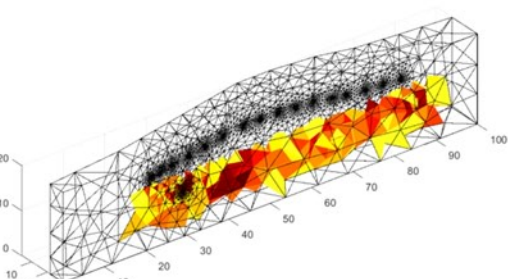
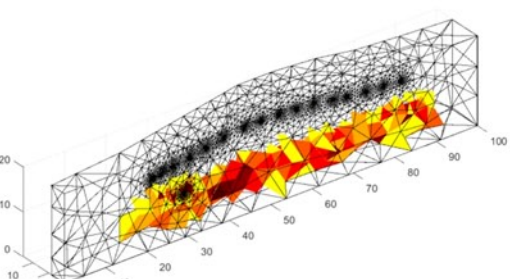
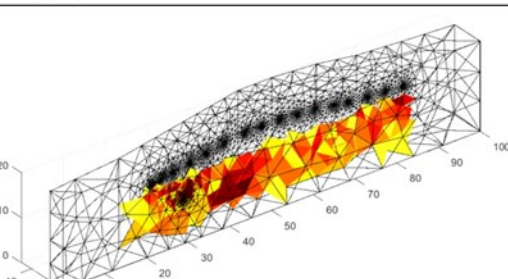
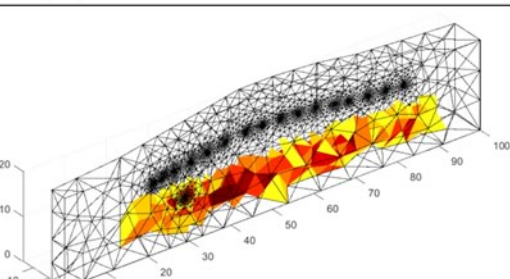
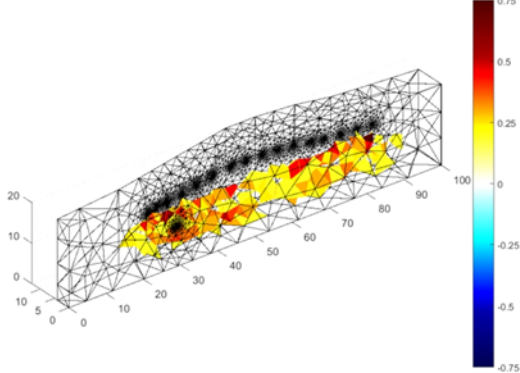
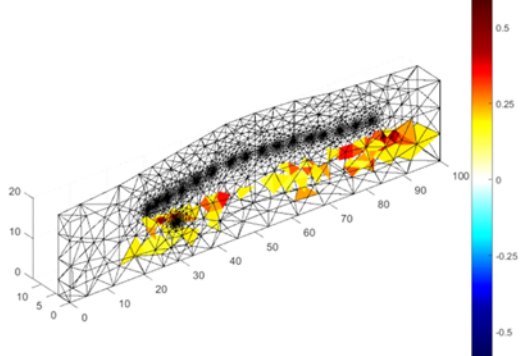
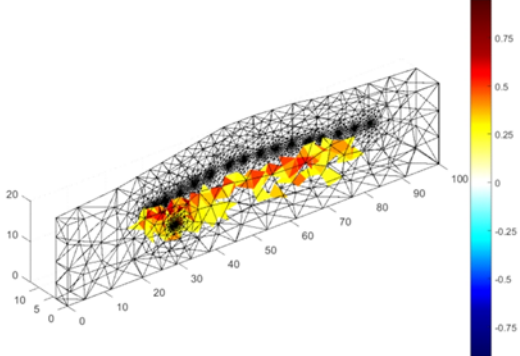
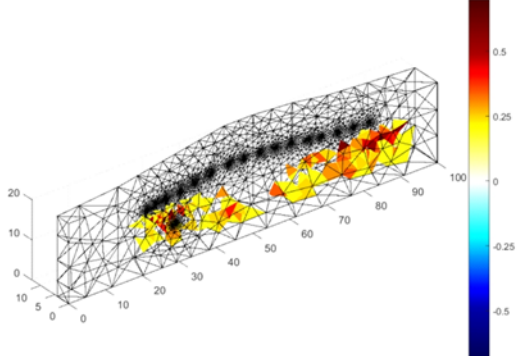
ID	The cross-sectional patterns of the flood embankment	The images reconstructed by using a neural generator
1		
2		
3		
4		
5		

Table 3b. Differences in 3D imaging results

ID	Differences between the pattern image and the reconstructed image
1	
2	
3	
4	

References

1. Adedigba S A, Khan F, Yang M. Dynamic failure analysis of process systems using neural networks. *Process Safety and Environmental Protection* 2017; 111: 529-543, <https://doi.org/10.1016/j.psep.2017.08.005>.
2. Banasiak R, Wajman R, Sankowski D, Soleimani M. Three-Dimensional Nonlinear Inversion of Electrical Capacitance Tomography Data Using a Complete Sensor Model. *Progress In Electromagnetics Research (PIER)* 2010; 100: 219-234, <https://doi.org/10.2528/PIER09111201>.
3. Beckers B, Schütt B. The elaborate floodwater harvesting system of ancient Resafa in Syria—Construction and reliability. *Journal of arid environments* 2013; 96: 31-47, <https://doi.org/10.1016/j.jaridenv.2013.04.004>.
4. Bouzelha K, Hammoum H, Amirouche C, Chaouadi T. Reliability analysis of stability to sliding of earthen embankment under seismic effect. *Procedia Structural Integrity* 2017; 5: 77-84, <https://doi.org/10.1016/j.prostr.2017.07.070>.
5. Curt C, Talon A. Assessment and control of the quality of data used during dam reviews by using expert knowledge and the ELECTRE TRI method. *Journal of Computing in Civil Engineering* 2011; 27.1: 10-17, [https://doi.org/10.1061/\(ASCE\)CP.1943-5487.0000187](https://doi.org/10.1061/(ASCE)CP.1943-5487.0000187).
6. Gamse S, Zhou W H, Tan F, Yuen K V, Oberguggenberger M. Hydrostatic-season-time model updating using Bayesian model class selection. *Reliability Engineering & System Safety* 2018; 169: 40-50, <https://doi.org/10.1016/j.res.2017.07.018>.
7. Gottardi G, Gragnano C G, Rocchi I, Bittelli M. Assessing River Embankment Stability Under Transient Seepage Conditions. *Procedia Engineering* 2016; 158: 350-355; <https://doi.org/10.1016/j.proeng.2016.08.454>.
8. Hawryluk M, Mrzygłód B. A durability analysis of forging tools for different operating conditions with application of a decision support system based on artificial neural networks (ANN). *Eksploatacja i Niezawodność – Maintenance and Reliability* 2017; 19 (3): 338–348, <https://doi.org/10.17531/ein.2017.3.4>.
9. Ji J, Chan C L. Long embankment failure accounting for longitudinal spatial variation—A probabilistic study. *Computers and Geotechnics* 2014; 61: 50-56, <https://doi.org/10.1016/j.compgeo.2014.05.001>.
10. Kłosowski G, Kozłowski E, Gola A. Integer linear programming in optimization of waste after cutting in the furniture manufacturing. *Advances in Intelligent Systems and Computing* 2018; 637: 260-270, https://doi.org/10.1007/978-3-319-64465-3_26.
11. Kozłowski E, Kowalska B, Kowalski D, Mazurkiewicz D. Water demand forecasting by trend and harmonic analysis. *Archives of Civil and Mechanical Engineering* 2018; 18(1): 140-148, <https://doi.org/10.1016/j.acme.2017.05.006>.
12. Kryszyn J, Smolik W, Radzik B, Olszewski T, Szabatin R. Switchless Charge-Discharge Circuit for Electrical Capacitance Tomography. *Measurement Science and Technology* 2014; 25(11): 115009, <https://doi.org/10.1088/0957-0233/25/11/115009>.
13. Low B K. FORM, SORM, and spatial modeling in geotechnical engineering. *Structural Safety* 2014; 49: 56-64, <https://doi.org/10.1016/j.strusafe.2013.08.008>.
14. Mazurkiewicz D. Maintenance of belt conveyors using an expert system based on fuzzy logic. *Archives of Civil and Mechanical Engineering*, 2015; 15.2: 412-418, <https://doi.org/10.1016/j.acme.2014.12.009>.
15. Nishimura S, Shimizu H. Reliability-based design of ground improvement for liquefaction mitigation. *Structural Safety* 2008; 30.3: 200-216, <https://doi.org/10.1016/j.strusafe.2006.11.002>.
16. Prajapati A, Ganesan S. Application of Statistical Techniques and Neural Networks in Condition-Based Maintenance. *Quality and Reliability Engineering International* 2013; 29(3): 439-461, <https://doi.org/10.1002/qre.1392>.
17. Rusek J. Application of Support Vector Machine in the analysis of the technical state of development in the LGOM mining area. *Eksploatacja i Niezawodność – Maintenance and Reliability* 2017; 19 (1): 54–61, <https://doi.org/10.17531/ein.2017.1.8>.
18. Rymarczyk T, Tchórzewski P, Adamkiewicz P, Duda K, Szumowski J, Sikora J. Practical Implementation of Electrical Tomography in a Distributed System to Examine the Condition of Objects. *IEEE Sensors Journal* 2017; 17(24): 8166-8186, <https://doi.org/10.1109/JSEN.2017.2746748>.
19. Rymarczyk T. New Methods to Determine Moisture Areas by Electrical Impedance Tomography. *International Journal of Applied Electromagnetics and Mechanics* 2016; 52:79-87, <https://doi.org/10.3233/JAE-162071>.
20. Stefanek P, Romaniuk D. Zastosowanie monitoringu geotechnicznego i środowiskowego na obiekcie unieszkodliwiania odpadów wydobywczych Żelazny Most. *Inżynieria Morska i Geotechnika*; 2015, 3: 376--381.
21. Stefanek P, Serwicki A. Ograniczenie oddziaływania OUOW Żelazny Most na środowisko poprzez zmianę technologii składowania odpadów. *Bezpieczeństwo Pracy i Ochrona Środowiska w Górnictwie*; 2014, 6: 36--42.
22. Ung S T, Williams V, Bonsall S, Wang J. Test case based risk predictions using artificial neural network. *Journal of Safety Research* 2006; 37.3: 245-260, <https://doi.org/10.1016/j.jsr.2006.02.002>.
23. Wu Z Y, Li Y L, Chen J K, Zhang H, Pei L. A reliability-based approach to evaluating the stability of high rockfill dams using a nonlinear shear strength criterion. *Computers and Geotechnics* 2013; 51: 42-49, <https://doi.org/10.1016/j.compgeo.2013.01.005>.
24. Yajun W, Wohua Z, Weiliang J, Changyu W, Dachun R. Fuzzy stochastic generalized reliability studies on embankment systems based on first-order approximation theorem. *Water Science and Engineering* 2008; 1.4: 36-47.
25. Zagrożenia okresowe występujące w Polsce, Wydział Analiz Rządowego Centrum Bezpieczeństwa, styczeń 2013.
26. Zuber N, Bajrić R. Application of artificial neural networks and principal component analysis on vibration signals for automated fault classification of roller element bearings. *Eksploatacja i Niezawodność – Maintenance and Reliability* 2016; 18 (2): 299–306, <https://doi.org/10.17531/ein.2016.2.19>.

Tomasz RYMARCZYK

University of Economics and Innovation
 ul. Projektowa 4, 20-209 Lublin, Poland
 Research and Development Center, Netrix S.A.
 ul. Związkowa 26, 20-148 Lublin, Poland
 E-mail: tomasz@rymarczyk.com

Grzegorz KŁOSOWSKI

Lublin University of Technology
 Department of Organization of Enterprise
 ul. Nadbystrzycka 38, 20-618 Lublin, Poland
 E-mail: g.klosowski@pollub.pl

dr inż. Tomasz Rymarczyk

Centrum Badawczo-Rozwojowe Nowoczesnych Technologii, Netrix S.A.
ul. Związkowa 26, 20-148 Lublin
Wyższa Szkoła Ekonomii i Innowacji w Lublinie
ul. Projektowa 4, 20-209 Lublin
E-mail: tomasz@rymarczyk.com

dr inż. Grzegorz Kłosowski

Politechnika Lubelska
Katedra Organizacji Przedsiębiorstwa na Wydziale Zarządzania
ul. Nadbystrzycka 38, 20-618 Lublin, Poland
E-mail: g.klosowski@pollub.pl

**Zastosowanie neuronowej rekonstrukcji obrazów tomograficznych
w problematyce niezawodności zabezpieczeń przeciwpowodziowych**

***Słowa kluczowe:** tomografia elektryczna, zapory i wały przeciwpowodziowe, eksploatacja budowli hydrotechnicznych, sieci neuronowe, metody numeryczne*

Streszczenie: W artykule zaprezentowano nowatorską koncepcję usprawnienia monitoringu wałów i zapór przeciwpowodziowych. Główną przewagą nowego rozwiązania nad znanymi metodami jest uzyskanie dokładniejszego rozkładu komponentów wnętrza zapory, co zasadniczo przyczynia się do wczesnego i niezawodnego wykrycia zagrożeń związanych z eksploatacją tego typu budowli. Dzięki temu, zastosowanie nowej metody spowoduje wzrost niezawodności zabezpieczeń przeciwpowodziowych. W opisywanej metodzie założono wytrenowanie systemu neuronowego, złożonego z wielu działających równolegle sieci neuronowych, z których każda generuje pojedynczy punkt obrazu wyjściowego. Powyższy sposób, uwzględniający jednoczesne zastosowanie wielu sieci neuronowych, umożliwia skuteczną realizację trudnych zagadnień rekonstrukcji obrazów dwu i trój-wymiarowych, w tym obrazowanie uszkodzeń i przecieków wnętrza zapór przeciwpowodziowych. Ważną zaletą prezentowanej metody jest możliwość zastąpienia obrazowaniem neuronowym wielu innych, obecnie stosowanych systemów, które monitorują budowle hydrotechniczne w sposób punktowy. Przeprowadzone badania umożliwiają rozwiązanie problemu niskiej rozdzielczości obrazów tomograficznych, co stanowi główną barierę rozwoju tych metod w odniesieniu do dużych budowli ziemnych. Poprawa rozdzielczości rekonstruowanych obrazów, a także możliwość ich uzyskiwania w różnych przekrojach w czasie rzeczywistym, są nowymi funkcjonalnościami, które wyróżniają obrazowanie neuronowe na tle obecnie stosowanych metod monitoringu wałów i zapór przeciwpowodziowych.

1. Wprowadzenie

Eksploatacja zabezpieczeń przeciwpowodziowych, takich jak wały przeciwpowodziowe i zapory wodne jest bardzo istotnym zagadnieniem wpływającym na

bezpieczeństwo ludzi, zwierząt i roślin znajdujących się w rejonie danego obiektu. Istnieją dwa podstawowe rodzaje problemów, jakie mogą wystąpić na skutek nieprawidłowej eksploatacji tam i zapór wodnych. Pierwszym, podstawowym zagrożeniem jest fizyczne uszkodzenie zapory, mogące doprowadzić do jej przerwania. Drugim rodzajem zagrożenia jest przesiąkanie zapory, co w przypadku zbiorników zawierających płynne odpady chemiczne może doprowadzić do różnego rodzaju skażeń. Przerwanie zapory może powodować następujące konsekwencje [25]:

- sprowadzenie zagrożenia dla życia ludzi i zwierząt oraz konieczność ewakuacji;
- zamknięcie urzędów administracji publicznej, szkół, szpitali;
- prawdopodobieństwo wystąpienia epidemii, epizootii lub epifitoz;
- możliwość wystąpienia plagi owadów i gryzoni;
- zniszczenie hodowli i zbiorów w gospodarstwach rolnych (osłabienie ekonomiczne przemysłu spożywczego, wzrost cen produktów żywnościowych, wypłata odszkodowań dla przedsiębiorców zajmujących się przetwarzaniem i sprzedażą żywności);
- zniszczenie i uszkodzenie budynków (mieszkalnych, gospodarczych, użyteczności publicznej);
- zniszczenia w infrastrukturze (m.in. drogi, mosty, wiadukty, tunele, wały przeciwpowodziowe, przepompownie, urządzenia hydrotechniczne, urządzenia i sieci kanalizacyjno-wodociągowe);
- zniszczenia w infrastrukturze wytwarzania, przesyłu lub dystrybucji energii elektrycznej i ciepłowniczej;
- zakłócenia funkcjonowania systemów łączności i systemów teleinformatycznych;
- zniszczenia lub uszkodzenia trakcji komunikacyjnych, awarie w zakładach przemysłowych;
- zakłócenia w funkcjonowaniu systemu dystrybucyjnego paliw;
- możliwy wzrost przestępczości o charakterze kryminalnym oraz zwiększona liczba przestępstw i wykroczeń pospolitych (kradzieże z włamaniem, rozboje, niszczenie mienia).

Przesiákanie odpadów chemicznych przez zapory stwarza z kolei takie zagrożenia, jak możliwość miejscowego skażenia środowiska naturalnego, a także uszkodzenia instalacji i urządzeń technicznych.

Powodzie zaliczane są do grupy katastrof naturalnych, które powodują wiele tragedii [3, 7]. Jednym ze sposobów zapewnienia bezpieczeństwa obszarów zalewowych w pobliżu składowisk odpadów flotacyjnych i rzek jest podnoszenie wysokości wałów przeciwpowodziowych [18]. Biorąc pod uwagę niewystarczającą zdolność filtracyjną nasypu, wysoki stan wody może powodować powstawanie przecieków, co skutkuje częściowym lub całkowitym zniszczeniem budowli hydrotechnicznej [19].

Z uwagi na poważne następstwa awarii, obiekty techniczne takie jak tamy, zapory wodne i inne zabezpieczenia przeciwpowodziowe wyposaża się w różnego rodzaju systemy, mające na celu zwiększenie stopnia ich niezawodności. Systemy eksploatacji tam i zapór obejmują zarówno odpowiednie środki obsługi jak również system działań eksploatacyjnych ujętych w formę ścisłych procedur i instrukcji. Instrukcje użytkowania budowli o przeznaczeniu hydrotechnicznym zawierają pewne treści, które można uznać za standardowe. Należą do nich między innymi zalecenia odnośnie częstości i sposobu dokonywania przeglądów, badań, pomiarów i kontroli stanu technicznego obiektu oraz wykaz elementów budowli hydrotechnicznej podlegających obserwacji wraz z listą parametrów, które powinny być

mierzone. Powyższe zapisy są dowodem na to, że stała obserwacja, monitoring i pomiary są kluczowymi elementami procesów eksploatacji tam i zapór przeciwpowodziowych.

W większości przypadków zabezpieczenia przeciwpowodziowe są rozległymi i złożonymi systemami. Składają się z wielu podsystemów, których prawidłowe funkcjonowanie wpływa na niezawodność tych obiektów. Do typowych podsystemów wchodzących w skład tam i zapór przeciwpowodziowych zaliczyć można systemy osłony hydrologicznej, systemy alarmowe, systemy energetyczne, mechaniczne systemy regulacji i przepływów wody oraz informatyczne systemy wspomaganie decyzji.

W celu zapewnienia skutecznego monitoringu wymienionych systemów należy użyć odpowiednich metod. Informatyczne systemy wspomaganie decyzji pełnią szczególną rolę, polegającą na integracji pozostałych systemów i automatyzacji procesu decyzyjnego. Automatyzacja polega na identyfikacji i prognozowaniu określonych zagrożeń wraz z podaniem prawdopodobieństwa ich wystąpienia. Ostateczne decyzje odnośnie reagowania na rezultaty monitoringu zawsze podejmuje człowiek. Poniżej wymieniono aktualnie stosowane metody monitoringu w odniesieniu do Obiektu Unieszkodliwiania Odpadów Wydobywczych (OUOW) Żelazny Most KGHM POLSKA MIEDŹ S.A., będącego największym obiektem hydrotechnicznym w kraju i jednym z największych tego typu obiektów na świecie. Stosowane tam metody monitoringu można podzielić na dwie grupy: metody związane z aktualnym zachowaniem się konstrukcji i jej niezawodnością oraz metody związane z oddziaływaniem obiektu na otaczające go środowisko naturalne.

Do pierwszej grupy zaliczyć można następujące metody monitoringu: wizualna ocena stanu technicznego (obserwacja bezpośrednia prowadzona przez pracowników), monitoring geodezyjny (wykrywanie deformacji konstrukcji poprzez pomiary ręczne za pomocą reperów i automatyczne za pomocą mikroluster), monitoring geotechniczny (wykrywanie anomalii w budowie geologicznej podłoża rodzimego zapory i zbiornika poprzez głębokie wiercenia i sondy wciskane), monitoring hydrogeologiczny (wykrywanie anomalii spowodowanych nasiąkaniem zapory poprzez obserwację ciśnień piezometrycznych w piezometrach zainstalowanych w masywie odpadów, na zaporach oraz bliskim i dalekim przedpołu), monitoring sejsmiczny (wykrywanie zaburzeń stateczności budowli za pomocą czujników akcelerometrycznych, które są wzbudzane każdorazowo, gdy zidentyfikują drgania o określonym poziomie), systemy informatyczne do analizy dużych zbiorów danych (Big Data).

Do grupy metod związanych z zapobieganiem niekorzystnemu wpływowi obiektu na otaczające go środowisko naturalne zaliczyć można monitoring hydrologiczny (wykrywanie przecieków) oraz monitoring chemiczny (wykrywanie skażenia okolicznych wód gruntowych).

Ogólnoświatowy trend jakim jest rozwój technik informacyjnych i komunikacyjnych znajduje odzwierciedlenie we wzroście znaczenia systemów informatycznych w obrębie systemów eksploatacyjnych zabezpieczeń przeciwpowodziowych. Rozbudowane układy pomiarowe dostarczają wielu danych pobranych z różnych punktów zapory. Jednym z głównych zadań systemów informatycznych instalowanych w obiektach hydrotechnicznych jest tworzenie modeli matematycznych w oparciu o dostarczane informacje. W obecnie stosowanych systemach informatycznych wykorzystuje się algorytmy realizujące różnorodne metody. Do metod deterministycznych zaliczyć można metodę Felleniusa, która umożliwia ocenę stopnia stabilności zapory, wykorzystując podział potencjalnej bryły osuwiskowej na bloki (pasy) pionowe. Metoda ta znana jest również pod nazwą metody Pettersona-Felleniusa lub metody szwedzkiej [4]. Przykładem metody ilościowej o charakterze statystycznym jest model HST (Hydrostatic-Season-Time – Hydrostatyczny-Sezonowy-Czasowy). Empiryczny model HST jest szeroko stosowany do analizy różnych typów danych pomiarowych na temat wałów przeciwpowodziowych, tam i zapór [6]. Kolejną grupą metod wykorzystywanych w celu poprawy niezawodności procesów eksploatacyjnych zapór przeciwpowodziowych są metody probabilistyczne. Przykładem jest metoda niezawodności pierwszego rzędu (FORM), za

pomocą której można zbadać tryb uszkodzenia wzdłużnego długiego nasypu składającego się z gleb homogenicznych [9]. W celu zwiększenia niezawodności budowli ziemnych można zastosować indeks niezawodności Hasofera-Linda, który może być wykorzystany także w połączeniu z metodą FORM [13]. Do metod stosowanych w procesach eksploatacyjnych należy również analiza harmoniczna [11].

Częstym problemem w przypadku zapór wodnych jest niedostateczna filtracja wody powodująca tzw. podciekanie. W literaturze można odnaleźć propozycje metod kalkulacji prawdopodobieństwa wystąpienia tego rodzaju zjawisk [15].

Kolejną grupą inteligentnych metod stochastycznych, wykorzystywanych przez systemy informatyczne w celu podniesienia poziomu niezawodności procesów eksploatacyjnych, w tym także w odniesieniu do tam i zapór wodnych, są metody heurystyczne oparte na logice rozmytej [14, 22, 24]. Do rzadziej stosowanych metod zwiększających poziom niezawodności i usprawniających procesy eksploatacyjne zapór wodnych należą: programowanie liniowe całkowitoliczbowe [10], Support Vector Machine [17], nieliniowe kryterium wytrzymałości na ścinanie [23], a także sztuczne sieci neuronowe [1, 8]. Obecnie głównym obszarem zastosowań ANN (sztuczne sieci neuronowe = Artificial Neural Networks) są zagadnienia predykcyjne, usprawniające procesy eksploatacyjne poprzez identyfikację [16] lub klasyfikację usterek [26].

Jak wcześniej wspomniano, zabezpieczenia przeciwpowodziowe należą do kategorii budowli hydrotechnicznych. Analiza procedur i zasad eksploatacji w odniesieniu do tego rodzaju obiektów pozwala zauważyć, że jednym z głównych procesów zapewniających prawidłową eksploatację jest obserwacja bieżącego zachowania i detekcja zjawisk, które z uwagi na swoją specyfikę, mogą wskazywać na nieprawidłowości zagrażające bezpieczeństwu budowli. Obecne metody monitoringu obiektów technicznych typu wały przeciwpowodziowe i zapory wodne mają jednak liczne wady. Pierwszą z nich są dość wysokie koszty użytkowania. Większość obecnie stosowanych metod wymaga bowiem zaangażowania specjalistów, przez co istotnym elementem kosztów jest robocizna. Prócz tego, wykorzystywane systemy pomiarowe wymagają nakładów na remonty, konserwacje, części zamienne i materiały, które się zużywają. Istotną wadą jest też zwykle zbyt późna informacja o zagrożeniu. W przypadku systemów, które nie są częścią zintegrowanych systemów informatycznych, informacja o zagrożeniu dociera do odpowiednich służb z kilkugodzinnym opóźnieniem. Opóźnienie jest zależne od częstotliwości, z jaką odbywają się ujęte w procedurach odczyty urządzeń pomiarowych. Niewystarczający jest też poziom skuteczności znanych metod monitoringu [4, 5]. Z powodu punktowego charakteru pomiarów istnieje duża niepewność formułowanych na ich podstawie wniosków. Sondy i czujniki umieszczane w różnych miejscach bryły zapory nie dają możliwości uzyskania pełnej wiedzy odnośnie aktualnego jej stanu. Istnieje poważne ryzyko, że pojawiające się wewnątrz zapory usterki (pęknięcia, zmiany struktury wewnętrznej, zmiany składu i gęstości ziemi itp.) nie zostaną wykryte na tyle wcześnie, by umożliwić ich skorygowanie. W celu uzyskania jak najpełniejszej wiedzy na temat stanu technicznego obiektu zachodzi konieczność jednoczesnego stosowania wielu metod monitoringu. W celu uproszczenia sposobu monitorowania obiektu oraz procedury wnioskowania istnieje wyraźna potrzeba opracowania jednej skutecznej metody, zapewniającej szybkość i niezawodność rejestracji, przesyłania i przetwarzania informacji o występujących zagrożeniach. Większość wymienionych wad zostałaby wyeliminowana, gdyby możliwe było opracowanie nowej metody umożliwiającej ocenę stanu technicznego budowli hydrotechnicznej, w sposób umożliwiający bieżącą detekcję różnic w strukturze wewnętrznej obiektu. Jedną z potencjalnych metod umożliwiających osiągnięcie tego celu jest tomografia elektryczna [2, 12]. Tomografia umożliwia wgląd we wnętrze badanego obiektu poprzez wygenerowanie jego obrazu. Metoda ta znajduje zastosowanie głównie w medycynie i inżynierii materiałowej. Podstawową barierą na drodze rozwoju metod tomograficznych w monitoringu wałów i zapór

przeciwpowodziowych jest brak odpowiedniej technologii, która zapewniłaby istotną poprawę rozdzielczości obrazu.

Niniejszy artykuł prezentuje nowe podejście do problemu eksploatacyjnego, związanego z monitorowaniem obiektów przy użyciu obrazowania neuronowego. Dotychczasowe próby użycia sztucznych sieci neuronowych w tomografii elektrycznej koncentrowały się na wykorzystaniu pojedynczych sieci neuronowych do przetwarzania sygnałów wejściowych na obrazy. W trakcie badań opracowano udoskonaloną metodę neuronowej rekonstrukcji tomograficznej, której cechą charakterystyczną jest zastosowanie systemu sieci neuronowych, w którym każda z sieci generuje kolor pojedynczego piksela na siatce obrazu. Dzięki oryginalnej architekturze inteligentnego systemu obrazowania uzyskano nową funkcjonalność w odniesieniu do znanych metod tomograficznych, polegającą na zwiększeniu rozdzielczości obrazów przekrojów skanowanych obiektów hydrotechnicznych.

2. Neuronowa rekonstrukcja obrazów tomograficznych

Prezentowana w niniejszym artykule neuronowa rekonstrukcja obrazów tomograficznych jest nową metodą mającą na celu zwiększenie rozdzielczości obrazów, a przez to podniesienie skuteczności monitoringu zabezpieczeń przeciwpowodziowych. Algorytm umożliwia wyeliminowanie głównych problemów eksploatacyjnych budowli hydrotechnicznych związanych z ich monitorowaniem. Tomografia wsparta systemem neuronowym daje nowe możliwości prowadzenia obserwacji. Zaprezentowana koncepcja, umożliwia uzyskanie dokładnego, trójwymiarowego obrazu wnętrza budowli hydrotechnicznej w czasie rzeczywistym. Jest to kluczowa funkcjonalność, dzięki której nie ma potrzeby utrzymywania większości dotychczasowych podsystemów monitoringu zabezpieczeń przeciwpowodziowych. Obecnie wykorzystywane systemy monitorujące (geodezyjny, geotechniczny, hydrologiczny itd.) umożliwiają zaledwie otrzymywanie danych punktowych dotyczących wybranych parametrów obiektu. Uzyskane w ten sposób niepełne informacje podlegają analizie, zarówno przez systemy informatyczne jak i przez specjalistów, którzy dokonują ostatecznej oceny stanu zapory. Taki proces oceny ma zasadnicze wady wynikające z punktowości pomiarów, błędów pomiarowych, braku monitoringu w czasie rzeczywistym oraz subiektywizmu w ocenach stanu przedmiotowego obiektu technicznego. Prezentowana w niniejszym artykule metoda jest wolna od powyższych ograniczeń, ponieważ umożliwia uzyskiwanie ostrych, kolorowych, trójwymiarowych obrazów wnętrza bryły zapory w wysokiej rozdzielczości w czasie rzeczywistym. Otrzymane obrazy są łatwe do analizy, ponieważ wiernie odwzorowują wszelkie zmiany zachodzące wewnątrz wałów przeciwpowodziowych i zapór wodnych. Zjawiska takie jak: pęknięcia, zmiany struktury warstw wewnętrznych, zawilgocenia, zmiany gęstości są natychmiast widoczne. Porównanie obrazów zarejestrowanych w równych odstępach czasu umożliwia dodatkowo skuteczne określenie tempa zachodzących zmian. Jest to bardzo cenna funkcjonalność, ponieważ daje solidne podstawy dokonywania dokładnych i wiarygodnych prognoz odnośnie źródeł, kierunków rozwoju, rodzaju i obszaru uszkodzeń rozwijających się wewnątrz budowli.


3. Modelowanie neuronowego systemu rekonstrukcji obrazów tomograficznych

Prezentowane rozwiązanie stanowi udoskonalenie znanej metody tomografii elektrycznej. W bryle wału przeciwpowodziowego umieszcza się pewną liczbę elektrod.

Następnie, do różnych elektrod podłączane jest źródło prądu elektrycznego o określonych parametrach (napięcie, natężenie, częstotliwość, amplituda). Wartości napięć pomiędzy odpowiednimi elektrodami są odczytywane i rejestrowane. Powyższe wartości napięć stanowią wektor wejściowy, na podstawie którego system neuronowy generuje obrazy wnętrza zapory wodnej. Zakłada się, że wartości odczytanych z elektrod parametrów elektrycznych są ściśle uzależnione od materiału, z którego składa się analizowane zabezpieczenie przeciwpowodziowe. Wszelkie zmiany struktury wewnętrznej zapory spowodowane zawilgoceniem, przeciekami, pęknięciem struktury, obsunięciem ziemi i wszelkimi innymi anomaliami, znajdują swoje odzwierciedlenie w wartościach parametrów prądowo-napięciowych odczytywanych z elektrod. Aby potwierdzić powyższe przypuszczenia opracowano mechanizm konwersji sygnałów elektrycznych na kolorowe obrazy o dużej rozdzielczości.

3.1. Sposób pozyskania danych

Rzeczywistym obiektem badań była zaporą Zbiornika Unieszkodliwiania Odpadów Wydobywczych Żelazny Most położonego w południowo-zachodniej części Polski pomiędzy Lubinem, a Głogowem. Zbiornik jest zlokalizowany w naturalnej dolinie między wzgórzami morenowymi w górnej partii zlewni rzeki Rudna. Zarządzającym obiektem unieszkodliwiania jest KGHM „Polska Miedź” S.A. Oddział Zakład Hydrotechniczny w Rudnej [21]. Obiekt Żelazny Most jest przeznaczony do składowania odpadów flotacyjnych z Zakładów Wzbogacania Rudy rejonu: Polkowice, Lubin i Rudna. Obecnie jest to jedyne miejsce deponowania odpadów z flotacji ze wszystkich kopalń. Ze względu na zajmowany teren, składowisko Żelazny Most jest jednym z największych tego typu obiektów na świecie [20]. Łączna długość zapór otaczających zbiornik wynosi ponad 14 km. Powierzchnia całkowita składowiska to 1410 ha. Wysokość zapór ograniczających w najwyższym miejscu sięga 55 m. Model topograficzny zbiornika Żelazny Most przedstawia rys.1.



Rys. 1. Model topologiczny Obiektu Unieszkodliwiania Odpadów Wydobywczych Żelazny Most


Obiekt wyposażono w różnorodne systemy diagnostyczne i kontrolno-pomiarowe, których zadaniem jest zapewnienie wysokiego stopnia niezawodności zbiornika Żelazny Most. Należą do nich: drenaże, układy do szybkiego i awaryjnego odwadniania akwenu, nasypy i studnie odciążające, których zadaniem jest obniżenie ciśnienia wody w gruntach podłoża. Wokół obiektu Żelazny Most na bieżąco prowadzone są obserwacje i badania monitorujące w odniesieniu do wód powierzchniowych i podziemnych. Niedoskonałością obecnie stosowanych metod monitoringu jest ich punktowość. Przy ich pomocy nie można uzyskać przekrojowych obrazów wnętrza zapory. Rys. 2 przedstawia zdjęcie ziemnego wału ochronnego zbiornika z

widocznymi elementami różnorodnych systemów pomiarowych, które dostarczają danych punktowych umożliwiającymi bieżący monitoring budowli.




Rys. 2. Powierzchnia wału ziemnego wokół zbiornika Żelazny Most

Kluczowym elementem neuronowego systemu rekonstrukcji obrazów tomograficznych jest sterownik neuronowy, którego zadaniem jest konwersja sygnałów elektrycznych na obrazy. Do wytrenowania systemu neuronowego potrzebny był odpowiedni zbiór danych uczących. Ze względu na to, że pobranie tego rodzaju danych bezpośrednio z zapory zbiornika Żelazny Most nie było możliwe, w warunkach laboratoryjnych opracowano model fizyczny fragmentu zapory, który odtwarzał badane cechy obiektu rzeczywistego, takie jak: materiał zapory, geometria kształtu, proporcje wymiarów, poziom wody w zbiorniku. W ten sposób pozyskano dane badawcze pochodzące z wielu przypadków pomiarowych. Dane obejmowały zbiory (wektory) wartości prądowo-napięciowych oraz odpowiadające tym zbiorom obrazy poprzecznych przekrojów zapory. Na rys. 3 przedstawiono model ziemny fragmentu wału ochronnego wraz z systemem EIT (Electrical Impedance Tomography), w skład którego wchodzi: układ elektrod, elektroniczny moduł rozdziału napięć na poszczególne elektrody oraz moduł rejestracji wyników. Szklane szyby terrarium umożliwiły obserwację zmian zachodzących w bryle wału ziemnego spowodowanych przesiąkaniem. Dzięki możliwości obserwacji wnętrza zapory ziemnej możliwe było zgromadzenie dużego zbioru danych, zawierających wektory parametrów elektrycznych oraz przyporządkowane tym wektorom obrazy.



Rys. 3. Model fizyczny zapory zbiornika Żelazny Most

W modelu zapory w linii prostej umieszczono 16 elektrod w taki sposób, aby swoim zasięgiem obejmowały całą szerokość obwałowania. Dzięki temu, umieszczając rzędy elektrod oddalonych od siebie w równych odległościach, można objąć systemem EIT całą długość zapory. Sposób rozmieszczenia rzędów elektrod w zaporze został zaprezentowany na rys. 4.




Rys. 4. Schemat wału przeciwpowodziowego z umieszczonymi w nim elektrodami

3.2. Koncepcja systemu neuronowego


Neuronowy system rekonstrukcji obrazów tomograficznych jest oryginalną koncepcją układu wielu sieci neuronowych, które uruchomione równoległe, generują obraz składający się z pojedynczych punktów. Każdy z punktów obrazu wyjściowego jest efektem działania niezależnej, osobno wytrenowanej sieci neuronowej. Za pomocą tej metody można generować zarówno obrazy dwuwymiarowe (2D) jak i trójwymiarowe (3D). Z punktu widzenia mechanizmu tworzenia obrazu wyjściowego, różnica pomiędzy obrazami 2D i 3D polega na ilości punktów składających się na pojedynczy obraz. W przypadku obrazów 3D punktów tych jest wielokrotnie więcej niż w przypadku obrazów 2D.

Jak już wcześniej wspomniano, rozpatrywany system EIT składał się z układu 16 elektrod, które w trakcie każdego pomiaru generowały wektor 208 spadków napięć. Pomiar

odczytywane dzięki umieszczonym w bryle zapory wodnej elektrodom, umożliwiły określenie konduktywności badanego obiektu, która jest zmienna w zależności od takich czynników jak np. zawilgocenie, niejednorodności struktury czy rodzaj gruntu. Obrazowany przekrój obwałowania został podzielony na siatkę pikseli, wygenerowaną jako elementy trójkątne za pomocą metody elementów skończonych. W przypadku obrazowania 2D siatka pikseli obrazu wyjściowego liczyła 2012 punktów, natomiast w przypadku obrazu trójwymiarowego zastosowano siatkę przestrzenną liczącą 17869 punktów. Pierwszy przypadek został zaprezentowany na rys. 5. W górnej części rysunku zaznaczono miejsca umieszczenia elektrod. Przypadek 3D został przedstawiony na rys. 6. Zagęszczenie punktów siatki wokół elektrod służy dokładniejszemu odwzorowaniu zmian zachodzących we wnętrzu obrazowanej zapory.



Rys. 5. Siatka obrazu wyjściowego 2D przekroju zapory licząca 2012 punktów




Rys. 6. Siatka obrazu wyjściowego 3D przekroju zapory licząca 17869 punktów


Na rys. 7 i 8 zaprezentowano sposób działania systemu neuronowego zamieniającego sygnały elektryczne pochodzące z elektrod, na obrazy 2D i 3D. Wektor wejściowy zawiera 208 przypadków pomiarowych (1). Każdy pojedynczy przypadek pomiarowy odpowiada pewnej wielkości spadku napięcia dla danej pary elektrod.

$$U = [\alpha_1, \alpha_2, \alpha_3, \dots, \alpha_{208}]^T \quad (1)$$

Wektor U jest wektorem wejściowym dla wszystkich sztucznych sieci neuronowych (ANN) wchodzących w skład systemu neuronowego.



Rys. 7. Matematyczny model neuronowy do konwersji sygnałów elektrycznych na obrazy 2D



Rys. 8. Matematyczny model neuronowy do konwersji sygnałów elektrycznych na obrazy 3D

Podczas projektowania modelu neuronowego oparto się na następujących założeniach:

1. Każdy punkt obrazu wyjściowego jest generowany przez odrębną sztuczną sieć neuronową, mającą na wejściu 208 wartości spadków napięć. Wyjście każdej z sieci neuronowych jest pojedynczą liczbą rzeczywistą odpowiadającą wartości konduktywności pojedynczego elementu rekonstruowanego obrazu (w postaci wizualnej przedstawianą poprzez odpowiedni kolor zakładanej skali konduktywności).
2. Zakłada się, że istnieje wzajemna zależność pomiędzy poszczególnymi punktami obrazu wyjściowego. W związku z tym, każda sieć neuronowa generująca wartość pojedynczego elementu obrazu, może być trenowana niezależnie, z losowo wygenerowanymi wagami początkowymi i biasem.
3. Sieci neuronowe przypisane do elementów obrazu wyjściowego mogą rozwiązywać zarówno zagadnienie klasyfikacyjne jak i regresyjne. W przypadku zagadnienia klasyfikacyjnego generowany obraz może być monochromatyczny lub posiadać kilka barw/odcieni. Wtedy klasyfikator przypisuje dany punkt do określonej barwy. Jeżeli sieć realizuje zagadnienie regresyjne, na wyjściu generowana jest liczba rzeczywista, odpowiadająca wartości konduktywności danego elementu. Taki rodzaj obrazowania jest najbardziej pożądanym, jednak ten układ sieci jest najtrudniej wytrenować. Systemy neuronowe opisywane w niniejszym opracowaniu realizują zagadnienia regresyjne.


W trakcie badań przeprowadzono wiele prób, uwzględniających różnorodne konfiguracje neuronowego perceptronu wielowarstwowego. W szczególności analizowano warianty, uwzględniające zmiany następujących czynników, mających wpływ na skuteczność działania systemu neuronowego: dobór algorytmu uczenia sieci, liczba warstw ukrytych i liczba neuronów w każdej z warstw sieci, parametry perceptronu (współczynnik uczenia, maksymalna liczba błędnych walidacji, momentum i inne). Analizowano także możliwość zastosowania nowych rozwiązań w zakresie konwolucyjnych sieci neuronowych (CNN – Convolutional Neural Networks). Rezultaty badań wykazały, że sieci CNN są w tym przypadku nieskuteczne z uwagi na zbyt małą liczbę danych wejściowych w porównaniu z dużą rozdzielczością obrazu wyjściowego.

Z uwagi na dużą liczbę danych oraz konieczność wytrenowania kilkunastu tysięcy sieci neuronowych (dla modelu 3D), realizacja ww. koncepcji wymagała zastosowania szybkich algorytmów uwzględniających obliczenia równoległe oraz komputerów o dużych mocach obliczeniowych.

3.3. Przebieg procesu trenowania wybranej sieci neuronowej

Poniżej zaprezentowano analizę procesu uczenia wybranej sieci neuronowej wchodzącej w skład systemu neuronowego do rekonstrukcji obrazu 2D. W tym przypadku, kompletny system neuronowy liczył 2012 osobno wytrenowanych sieci neuronowych. Z uwagi na dużą liczbę sieci, w niniejszym opracowaniu nie sposób zaprezentować przebiegu procesu uczenia wszystkich ANN.

Na rys. 9 zaprezentowano schemat zastosowanego modelu sieci neuronowej. Sieć ma 208 wejść, 10 neuronów w warstwie ukrytej i 1 neuron w warstwie wyjściowej. Warstwa ukryta wykorzystuje logistyczną funkcję transferową. W warstwie wyjściowej funkcja transferowa ma charakter liniowy.



Rys. 9. Model sieci neuronowej generującej pojedynczy punkt obrazu wyjściowego

W tabeli 1 zaprezentowano rezultaty uczenia jednej sieci neuronowej, wybranej losowo spośród systemu integrującego 2012 sieci. Prezentowana sieć generuje na wyjściu pojedynczy punkt obrazu wyjściowego. Łączna ilość przypadków wykorzystanych w procesie uczenia sieci wynosiła 10442. Wszystkie przypadki zostały losowo podzielone na 3 zbiory: uczący, walidacyjny i testowy w proporcjach: 70%, 15%, 15%. Zbiór walidacyjny jest wykorzystywany do ustalenia momentu zatrzymania procesu uczenia. Zakończenie procesu uczenia następuje w sytuacji, gdy dynamika zmiany gradientu zbliża się do zera. Zbiór testowy znajduje zastosowanie po zakończeniu uczenia. Służy on do weryfikacji jakości uzyskanej sieci.

Błąd MSE (Mean Squared Error) odzwierciedla średniokwadratową różnicę między wyjściami, a wielkościami wzorcowymi. Im niższe wartości MSE tym lepiej. Zerowy MSE oznacza brak błędu. Zbiór uczący obciążony został najniższym błędem uczenia, co jest sytuacją najczęściej spotykaną i prawidłową. Niski błąd MSE zbioru uczącego wynika z faktu najlepszego dostosowania wag sieci do przypadków uczących. Najwyższy błąd średniokwadratowy (MSE) o wartości $6.88341 \cdot 10^{-3}$ wystąpił w odniesieniu do zbioru testowego. Nieco mniejszy błąd MSE wynoszący $5.84343 \cdot 10^{-3}$ odnotowano dla zbioru walidacyjnego. Najmniejszy błąd odnotowano w odniesieniu do zbioru uczącego.


Innym badanym wskaźnikiem jakości sieci była regresja R. R=1 oznacza pełną zgodność wyjść z wzorcami, natomiast R=0 oznacza brak powiązań między nimi. Współczynnik regresji dla wszystkich trzech zbiorów był bardzo wysoki, bliski 1. Świadczy to o wysokiej zdolności sieci do generalizacji wiedzy (czyli prawidłowego przekształcania danych wejściowych na informacje wyjściowe nie tylko dla zbioru uczącego).

Tabela 1. Podział danych na zbiory i rezultaty procesu uczenia

Podział zbioru danych	Liczba przypadków w danym zbiorze	Błąd średniokwadratowy (MSE)	Regresja (R)
Zbiór uczący (70%)	7310	$1.35760 \cdot 10^{-3}$	0.997303
Zbiór walidacyjny (15%)	1566	$5.84343 \cdot 10^{-3}$	0.988642
Zbiór testowy (15%)	1566	$6.88341 \cdot 10^{-3}$	0.987701


Rezultaty otrzymane w wyniku sprawdzenia sieci na zbiorze testowym są najbardziej miarodajnym wskaźnikiem świadczącym o efektywności danej sieci, ponieważ przypadki z tego zbioru nie uczestniczą w procesie uczenia. Dobre wskaźniki MSE i R dla zbioru testowego i walidacyjnego świadczą o braku przeuczenia.

Na rys. 10 zaprezentowano diagramy korelacyjne rozpatrywanej sieci. Jak widać rozrzut wyników wykraczających poza linie wzorcowe jest zauważalny, jednak ilość przypadków oddalonych od linii wzorcowej nie jest duża. Świadczą o tym nakładające się linie korelacji dla wszystkich badanych zbiorów: zbioru uczącego, walidacyjnego i testowego oraz łącznie (dla wszystkich trzech zbiorów).




Rys. 10. Diagramy korelacyjne sieci neuronowej

Na rys. 11 zaprezentowano wykresy wartości błędu średniokwadratowego (MSE) zarejestrowane w trakcie procesu uczenia sieci. Wartości MSE są niskie. Stosunkowo regularne przebiegi linii wykresów (brak dużych fluktuacji) wskazują na brak przeuczenia, a tym samym na wysoką skuteczność opracowanego systemu tomograficznej rekonstrukcji obrazu. Hiperboliczny kształt krzywych wskazuje na wystarczającą liczbę przypadków uczących. Na wykresie zaznaczono trzydziestą epokę (iterację), na której zakończono uczenie sieci. Jest to epoka, w której błąd MSE zbioru walidacyjnego osiągnął swoje minimum.



Rys. 11. Wykresy błędów MSE dla zbiorów: uczącego, walidacyjnego i testowego

Na rys. 12 zaprezentowano histogram błędów (różnic) pomiędzy wartościami generowanymi przez sieć, a wzorcami. Każdy pionowy słupek wskazuje ilość odchyleń od wartości wzorcowej. Jak widać, największą liczbę odchyleń stanowią błędy bardzo małe, o wartościach zbliżonych do zera. Kształt histogramu przypomina krzywą rozkładu normalnego. Fakt ten również potwierdza wysoką jakość otrzymanego rozwiązania.



Rys. 12. Histogram błędów uczenia sieci

4. Rezultaty badań neuronowego systemu rekonstrukcji obrazów tomograficznych

W ramach prowadzonych prac badawczych opracowano dwa neuronowe modele systemów rekonstrukcji obrazów tomograficznych. Model pierwszy realizował zagadnienia obrazowania płaskiego (2D), natomiast model drugi generował obrazy 3D. W niniejszym rozdziale zaprezentowano efekty działania obu systemów neuronowych.

W tabeli 2a w dwóch kolumnach zestawiono wzorce i zrekonstruowane obrazy wygenerowane przez sterownik 2D. W tabeli 2b zaprezentowano graficzną reprezentację różnic wartości poszczególnych pikseli pomiędzy obrazami wzorcowymi i obrazami zrekonstruowanymi, przedstawionymi w tabeli 2a. Skala kolorystyczna na ilustracjach w tabeli 2b odzwierciedla różnice konduktywności pomiędzy elementami obrazów wzorcowych, a elementami obrazów zrekonstruowanych.

Tabela 2a. Rezultaty obrazowania w 2D

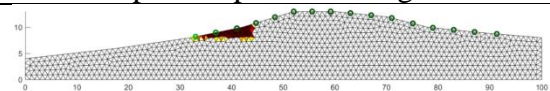
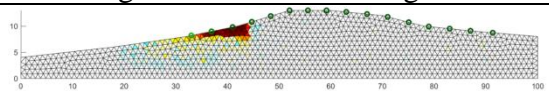
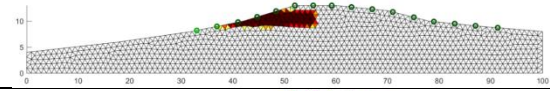
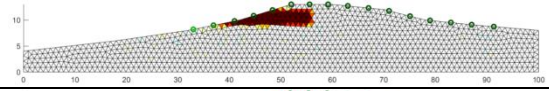
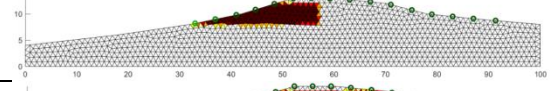
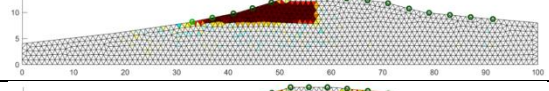
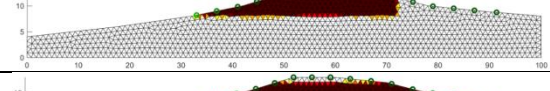
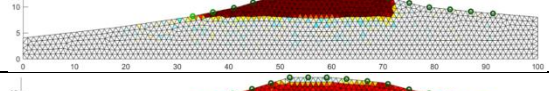
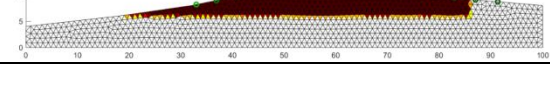
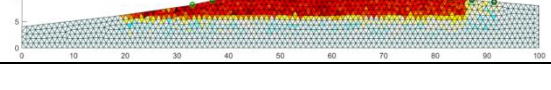
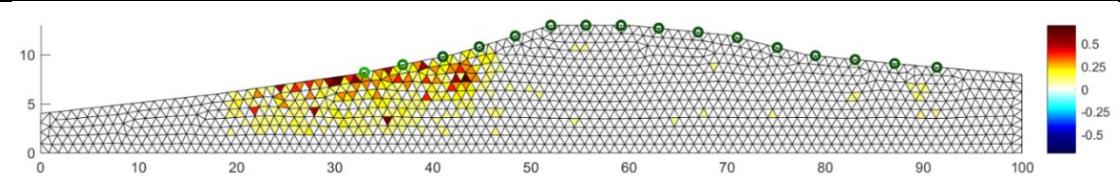
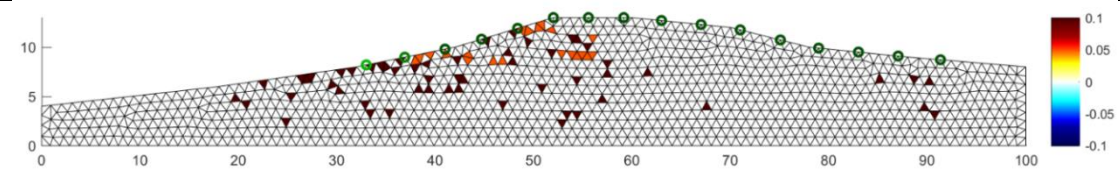
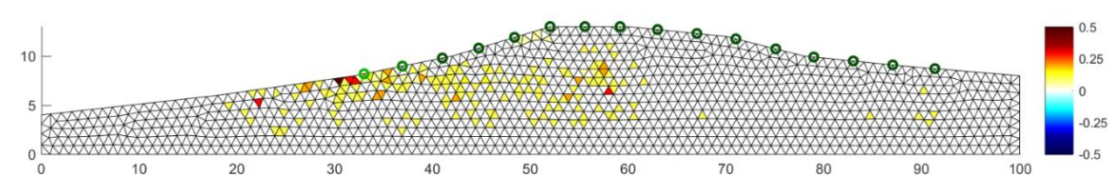
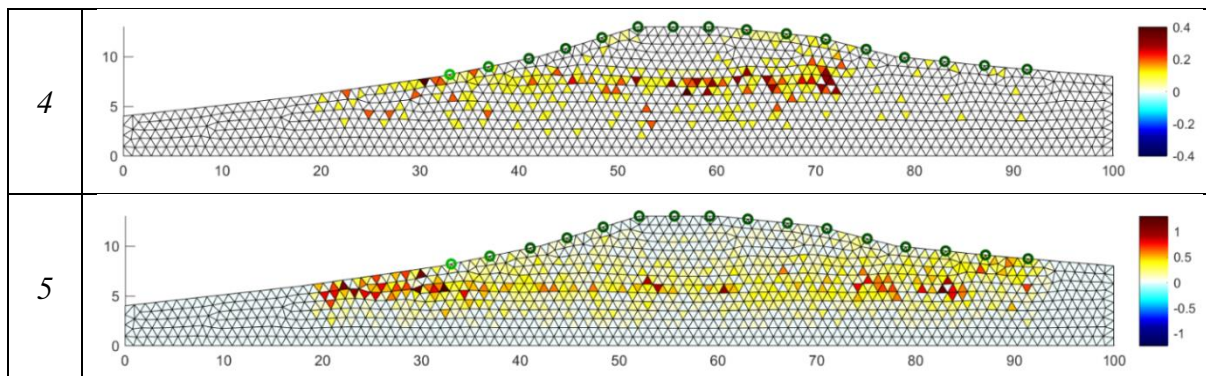
Lp	Wzorec przekroju wału przeciwpowodziowego	Obraz zrekonstruowany za pomocą generatora neuronowego
1		
2		
3		
4		
5		

Tabela 2b. Różnice wyników obrazowania w 2D

Lp	Różnice pomiędzy obrazem wzorca a obrazem zrekonstruowanym
1	
2	
3	



W tabeli 3a w podobny sposób zestawiono wzorce i zrekonstruowane obrazy wygenerowane przez sterownik 3D. W tabeli 3b zaprezentowano graficzną reprezentację różnic wartości poszczególnych pikseli pomiędzy przestrzennymi obrazami wzorcowymi i obrazami zrekonstruowanymi, przedstawionymi w tabeli 3a.

Tabela 3a. Rezultaty obrazowania w 3D

Lp	Wzorec przekroju wału przeciwpowodziowego	Obraz zrekonstruowany za pomocą generatora neuronowego
1		
2		
3		


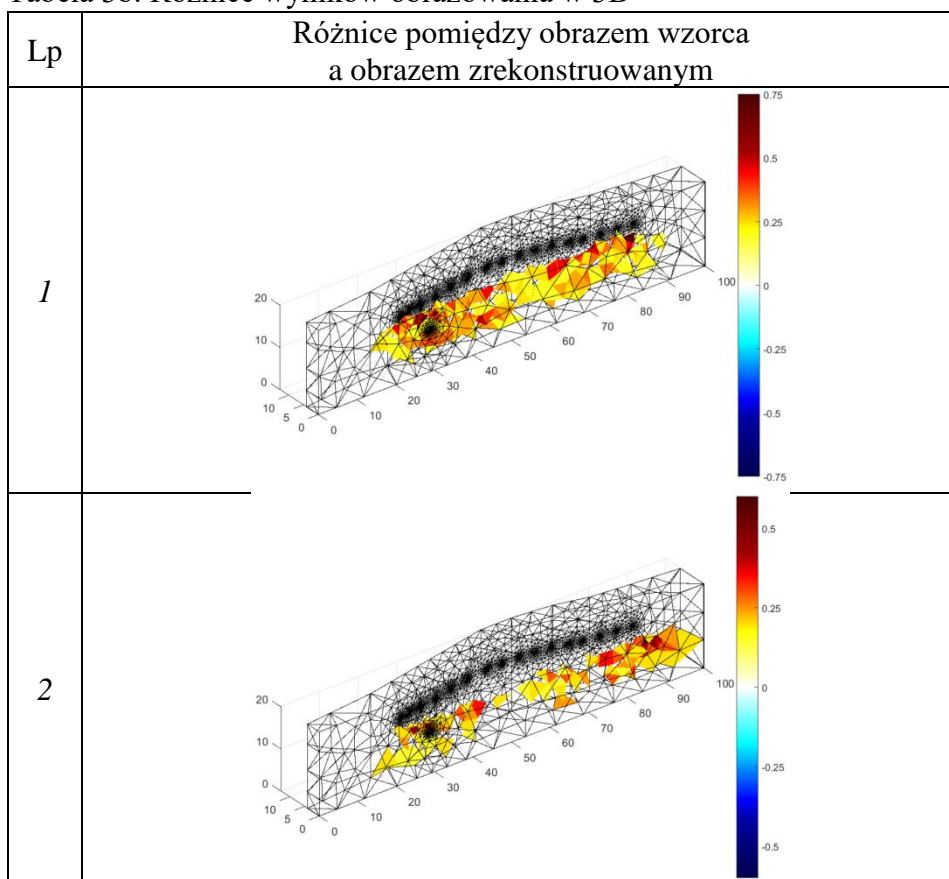
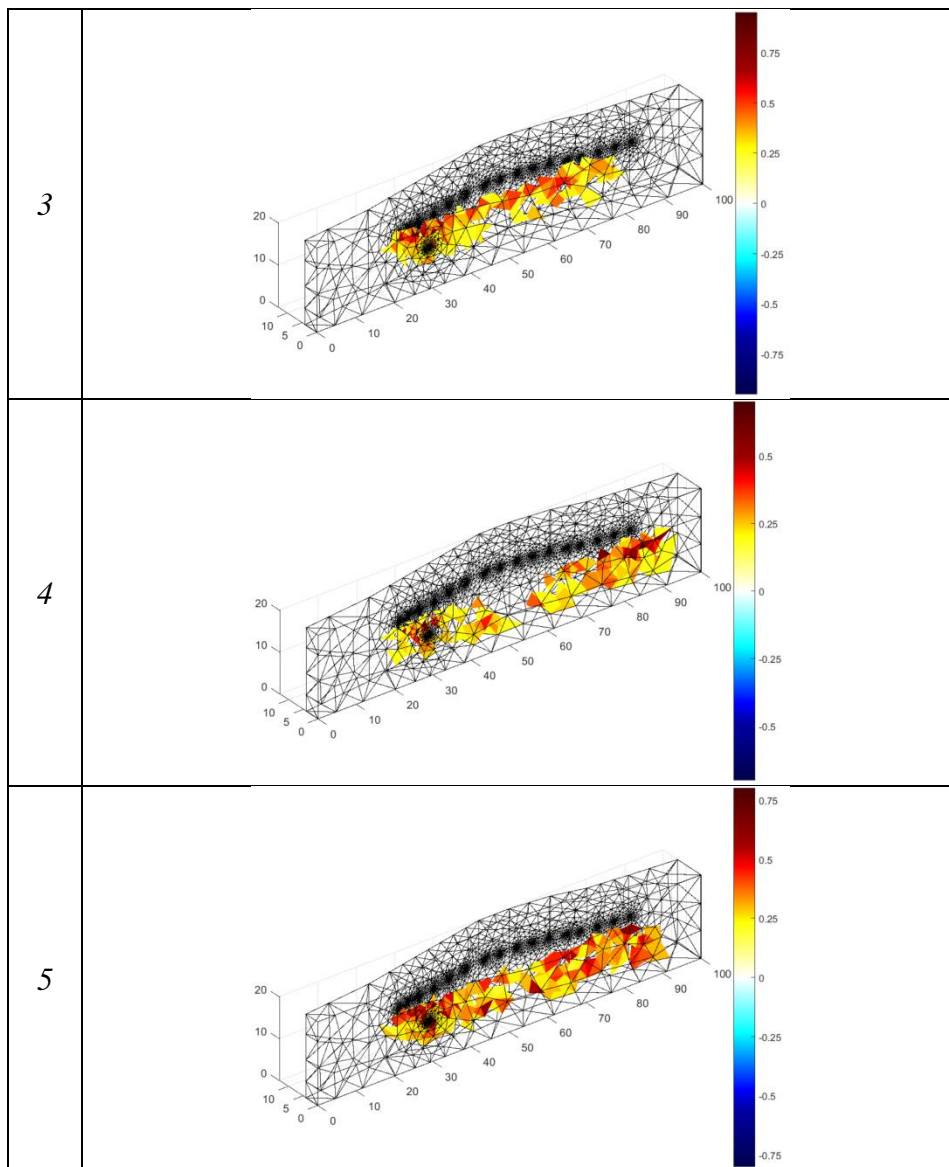


Tabela 3b. Różnice wyników obrazowania w 3D





Analogicznie jak w tabeli 2b, skala kolorystyczna na ilustracjach w tabeli 3b odzwierciedla różnice konduktywności pomiędzy elementami obrazów wzorcowych, a elementami obrazów rekonstruowanych.

Analizując tabelę 2a można zauważyć, że obrazy wynikowe z dużą dokładnością odwzorowują kształty i barwy obrazów wzorcowych. W przypadku modelu 2D wartości liczbowe pikseli obrazu wzorcowego były liczbami rzeczywistymi należącymi do przedziału od 1 do 3. Z tabeli 2b można odczytać wartości błędów obrazów rekonstruowanych względem ich wzorców. Widać, że większość pikseli na siatce nie zawiera błędów (brak koloru). W przypadku odchyłeń większych od zera, większość błędów nie przekracza wartości 0.2.

W tabeli 3a przedstawiono analizę porównawczą rekonstruowanych obrazów 3D. Tu również widoczna jest wysoka dokładność odwzorowań dla wszystkich pięciu prezentowanych przypadków. Siatka przestrzenna modelu 3D liczy aż 17869 punktów. Wartości liczbowe pikseli obrazu wzorcowego były liczbami rzeczywistymi należącymi do przedziału od 1 do 2. Z tabeli 3b można odczytać wartości błędów obrazów rekonstruowanych względem ich wzorców. Większość pikseli na siatce nie zawiera błędów (brak koloru). Podobnie jak w modelu 2D odchylenia niezerowe w większości przypadków nie przekraczają wartości 0.2.

5. Podsumowanie

W artykule zaprezentowano oryginalną koncepcję neuronowego systemu rekonstrukcji obrazów tomograficznych. Skuteczność metody została zweryfikowana w oparciu o uwarunkowania zapory Zbiornika Unieszkodliwiania Odpadów Wydobywczych Żelazny Most. Uwzględniając kluczowe cechy konstrukcyjne obiektu technicznego Żelazny Most, opracowano model fizyczny fragmentu zapory. Powyższy model wyposażono w układ elektrod oraz niezbędne urządzenia tomograficzne (EIT), które umożliwiły wykonanie wielu pomiarów wielkości elektrycznych oraz przyporządkowanie tym wielkościom obrazów przekrojów badanego modelu zapory. Uzyskane tą drogą dane zostały wykorzystane do wytrenowania systemu sieci neuronowych. Innowacyjną cechą przedmiotowego rozwiązania jest osobne wytrenowanie dużej liczby sieci neuronowych w ilości odpowiadającej rozdzielczości siatki obrazu rekonstruowanego. W trakcie badań laboratoryjnych opracowano dwa modele rekonstrukcji obrazów tomograficznych – płaski (2D) i przestrzenny (3D). Rezultaty wskazują, że prezentowana metoda obrazowania neuronowego może być skuteczna zarówno w przypadku rekonstrukcji dwu jak i trójwymiarowych. Zastosowanie układu wielu odrębnych sieci neuronowych działających jednocześnie w celu zobrazowania przekroju zapory przeciwpowodziowej umożliwiło wygenerowanie dokładnych odwzorowań zadanych wzorców. Jakość tych odwzorowań jest wystarczająca, aby prawidłowo zidentyfikować charakter zagrożeń, a także ocenić szybkość zmian zachodzących wewnątrz zapory.

Biorąc pod uwagę możliwość wykonywania pomiarów w stałych odstępach czasu, w prosty sposób można określić prędkość rozprzestrzeniania się przecieku. Powyższa informacja umożliwi nie tylko precyzyjną diagnozę przydatną do określania stopnia niezawodności zapory, lecz także skuteczną prognozę momentu nadchodzącej katastrofy. Dzięki informacjom uzyskanym za pomocą systemu obrazowania neuronowego, można odpowiednio zaplanować działania zapobiegające uszkodzeniom zabezpieczeń przeciwpowodziowych.

Podziękowanie: autorzy składają podziękowania władzom i pracownikom Wydziału Matematyki, Fizyki i Informatyki UMCS w Lublinie za udostępnienie zasobów superkomputerowych.

Literatura

1. Adedigba S A, Khan F, Yang M. Dynamic failure analysis of process systems using neural networks. *Process Safety and Environmental Protection* 2017; 111: 529-543.
2. Banasiak R, Wajman R, Sankowski D, Soleimani M. Three-Dimensional Nonlinear Inversion of Electrical Capacitance Tomography Data Using a Complete Sensor Model. *Progress In Electromagnetics Research (PIER)* 2010; 100: 219-234.
3. Beckers B, Schütt B. The elaborate floodwater harvesting system of ancient Resafa in Syria–Construction and reliability. *Journal of arid environments* 2013; 96: 31-47.
4. Bouzelha K, Hammoum H, Amirouche C, Chaouadi T. Reliability analysis of stability to sliding of earthen embankment under seismic effect. *Procedia Structural Integrity* 2017, 5: 77-84.
5. Curt C, Talon A. Assessment and control of the quality of data used during dam reviews by using expert knowledge and the ELECTRE TRI method. *Journal of Computing in Civil Engineering* 2011; 27.1: 10-17.
6. Gamse S, Zhou W H, Tan F, Yuen K V, Oberguggenberger M. Hydrostatic-season-time model updating using Bayesian model class selection. *Reliability Engineering & System Safety* 2018; 169: 40-50.

7. Gottardi G, Gragnano C G, Rocchi I, Bittelli M. Assessing River Embankment Stability Under Transient Seepage Conditions. *Procedia Engineering* 2016; 158: 350-355.
8. Hawryluk M, Mrzygłód B. A durability analysis of forging tools for different operating conditions with application of a decision support system based on artificial neural networks (ANN). *Eksploracja i Niezawodność – Maintenance and Reliability* 2017; 19 (3): 338–348, <http://dx.doi.org/10.17531/ein.2017.3.4>.
9. Ji J, Chan C L. Long embankment failure accounting for longitudinal spatial variation—A probabilistic study. *Computers and Geotechnics* 2014; 61: 50-56.
10. Kłosowski G, Kozłowski E, Gola A. Integer linear programming in optimization of waste after cutting in the furniture manufacturing. *Advances in Intelligent Systems and Computing* 2018; 637: 260-270.
11. Kozłowski E, Kowalska B, Kowalski D, Mazurkiewicz D. Water demand forecasting by trend and harmonic analysis. *Archives of Civil and Mechanical Engineering* 2018; 18(1): 140-148.
12. Kryszyn J, Smolik W, Radzik B, Olszewski T, Szabatin R. Switchless Charge-Discharge Circuit for Electrical Capacitance Tomography. *Measurement Science and Technology* 2014; 25(11): 115009.
13. Low B K. FORM, SORM, and spatial modeling in geotechnical engineering. *Structural Safety* 2014; 49: 56-64.
14. Mazurkiewicz D. Maintenance of belt conveyors using an expert system based on fuzzy logic. *Archives of Civil and Mechanical Engineering*, 2015; 15.2: 412-418.
15. Nishimura S, Shimizu H. Reliability-based design of ground improvement for liquefaction mitigation. *Structural Safety* 2008; 30.3: 200-216.
16. Prajapati A, Ganesan S. Application of Statistical Techniques and Neural Networks in Condition-Based Maintenance. *Quality and Reliability Engineering International* 2013; 29(3): 439-461.
17. Rusek J. Application of Support Vector Machine in the analysis of the technical state of development in the LGOM mining area. *Eksploracja i Niezawodność – Maintenance and Reliability* 2017; 19 (1): 54–61, <http://dx.doi.org/10.17531/ein.2017.1.8>.
18. Rymarczyk T, Tchórzewski P, Adamkiewicz P, Duda K, Szumowski J, Sikora J. Practical Implementation of Electrical Tomography in a Distributed System to Examine the Condition of Objects. *IEEE Sensors Journal* 2017; 17(24): 8166-8186.
19. Rymarczyk T. New Methods to Determine Moisture Areas by Electrical Impedance Tomography. *International Journal of Applied Electromagnetics and Mechanics* 2016; 52:79-87.
20. Stefanek P, Romaniuk D. Zastosowanie monitoringu geotechnicznego i środowiskowego na obiekcie unieszkodliwiania odpadów wydobywczych Żelazny Most. *Inżynieria Morska i Geotechnika*; 2015, 3: 376--381.
21. Stefanek P, Serwicki A. Ograniczenie oddziaływania OUOW Żelazny Most na środowisko poprzez zmianę technologii składowania odpadów. *Bezpieczeństwo Pracy i Ochrona Środowiska w Górnictwie*; 2014, 6: 36--42.
22. Ung S T, Williams V, Bonsall S, Wang J. Test case based risk predictions using artificial neural network. *Journal of Safety Research* 2006; 37.3: 245-260.
23. Wu Z Y, Li Y L, Chen J K, Zhang H, Pei L. A reliability-based approach to evaluating the stability of high rockfill dams using a nonlinear shear strength criterion. *Computers and Geotechnics* 2013; 51: 42-49.
24. Yajun W, Wohua Z, Weiliang J, Changyu W, Dachun R. Fuzzy stochastic generalized reliability studies on embankment systems based on first-order approximation theorem. *Water Science and Engineering* 2008; 1.4: 36-47.

25. Zagrożenia okresowe występujące w Polsce, Wydział Analiz Rządowego Centrum Bezpieczeństwa, styczeń 2013
26. Zuber N, Bajrić R. Application of artificial neural networks and principal component analysis on vibration signals for automated fault classification of roller element bearings. *Eksploatacja i Niezawodność – Maintenance and Reliability* 2016; 18 (2): 299–306, <http://dx.doi.org/10.17531/ein.2016.2.19>.