

Tomasz RYMARCZYK  
Grzegorz KŁOSOWSKI

## INNOVATIVE METHODS OF NEURAL RECONSTRUCTION FOR TOMOGRAPHIC IMAGES IN MAINTENANCE OF TANK INDUSTRIAL REACTORS

### NOWATORSKIE METODY NEURONOWEJ REKONSTRUKCJI OBRAZÓW TOMOGRAFICZNYCH W EKSPLOATACJI ZBIORNIKOWYCH REAKTORÓW PRZEMYSŁOWYCH\*

*The article presents an innovative concept of improving the monitoring and optimization of industrial processes. The developed method is based on a system of many separately trained neural networks, in which each network generates a single point of the output image. Thanks to the elastic net method, the implemented algorithm reduces the correlated and irrelevant variables from the input measurement vector; making it more resistant to the phenomenon of data noises. The advantage of the described solution over known non-invasive methods is to obtain a higher resolution of images dynamically appearing inside the reactor of artifacts (crystals or gas bubbles), which essentially contributes to the early detection of hazards and problems associated with the operation of industrial systems, and thus increases the efficiency of chemical process control.*

**Keywords:** electrical tomography, industrial processes, process control, neural networks, machine learning.

*W artykule przedstawiono nowatorską koncepcję usprawnienia monitoringu i optymalizacji procesów przemysłowych. Opracowana metoda bazuje na systemie osobno wytrenowanych wielu sieci neuronowych, w którym każda sieć generuje pojedynczy punkt obrazu wyjściowego. Dzięki zastosowaniu metody elastic net zaimplementowany algorytm redukuje z wejściowego wektora pomiarowego zmienne skorelowane i nieistotne, czyniąc go bardziej odpornym na zjawisko zaszumienia danych. Przewagą opisywanego rozwiązania nad znanymi metodami nieinwazyjnymi jest uzyskanie wyższej rozdzielczości obrazów dynamicznie pojawiających się wewnątrz reaktora artefaktów (kryształów lub pęcherzy gazowych), co zasadniczo przyczynia się do wczesnego wykrycia zagrożeń i problemów związanych z eksploatacją systemów przemysłowych, a tym samym zwiększa efektywność sterowania procesami chemicznymi.*

**Słowa kluczowe:** tomografia elektryczna, procesy przemysłowe, sterowanie procesami, sieci neuronowe, uczenie maszynowe.

#### 1. Introduction

Many chemical engineering products are created as a result of processes carried out using technological lines in which chemical reactors play a key role. A chemical reactor is a vessel adapted to carry out reactions taking place inside it. The purpose of industrial tank reactors is to ensure optimal economic parameters of chemical processes [18]. It can be achieved by the appropriate reactor design and by the skillful overlap of the three types of sub-processes occurring inside the reactor, namely the transfer of mass, momentum and heat. In this way, process control can be based on a dynamic selection of parameters such as: mixing intensity, temperature, pressure, substrate ratios and others. The presented research included reactors in which reactions take place between solid and liquid as well as gas and liquid. The tank reactor diagram is shown in Fig. 1.

The first type of reaction concerns the crystallization of solids in a liquid environment. It covers industrial processes of synthesis and purification of solid substances and changes in particle properties. The reactors in which crystallization occurs are used in many branches of the economy, including: chemical, food [9], metallurgy and waste utilization [27]. One of the monitoring systems tasks of such processes is to provide precise information on the quantity, size and location of crystals formed in the liquid in real time.




Fig. 1. Diagram of a tank reactor with a mixing system

The second type of reaction relates to the gas phase and the liquid phase. Such processes type are used, inter alia, in the production of biogas. Physicochemical fermentation reactors are a key element of biogas installations. Methane fermentation of organic waste takes place inside these reactors. The correct operation of technical systems is one of the crucial conditions for obtaining an adequate level of reliability of industrial processes [10].

There are two main reasons to monitor the state of dynamic processes. The first one is the detection of impending failures [11] which

(\*) Tekst artykułu w polskiej wersji językowej dostępny w elektronicznym wydaniu kwartalnika na stronie [www.ein.org.pl](http://www.ein.org.pl)

can include damage to technical infrastructure, excessive deviation of critical process parameters or interruption of its continuity. An effective monitoring system is designed to identify the problem early enough for effective corrective action to be taken.

The second reason for monitoring industrial processes is the need to control the course of the industrial process [29]. This is necessary for ensuring an adequate level of quality. In order to effectively control multiphase processes in which participate substances that can dynamically change the states of aggregation, effective monitoring methods should be applied. This is a difficult task, taking into account the aggressive conditions in which reactions take place inside the reactor. Using invasive sensors, the problem is the inability to directly examine any part of the interior of the reactor, point accuracy of measurements, the need to use many different monitoring systems simultaneously and high uncertainty in determining the dynamic state of the process based on incomplete data (indirect method). Among the non-invasive methods used in monitoring industrial processes can be distinguished: electric capacitive tomography [2, 4, 5, 13, 14, 16, 20, 26] electrical impedance tomography [3, 8, 28], magnetoacoustic tomography [30], ultrasound and radio tomography [21], X-ray tomography [1] and many more. Recently, more and more research in the field of industrial systems takes into account the use of various computational methods, such as: intelligent prediction methods [25], fuzzy logic [6], machine learning [22], numerical modeling [15], deep learning [8, 19] and binary programming [12].

Currently used techniques of non-invasive monitoring of industrial processes do not fully meet current operational needs. Obtained mapping of images of studied phenomena and processes can be unsharp, ambiguous, difficult to interpret, burdened with inaccuracies both in terms of the number of artefacts (crystals or gas bubbles) detected in the reactor as well as their size and location. As a result, redundant systems are used to obtain precise information about the status of the monitored process, which significantly increases the operating costs.

The above-mentioned difficulties and imperfections of the monitoring methods of chemical tank reactors are the reason for their improvement. The use of an improved monitoring method will increase the reliability of processes occurring inside the reactors and will reduce the operating costs of industrial systems.

The aim of this study is to introduce an improved method of monitoring and optimization of chemical processes occurring in heterogeneous tank reactors in which reactions take place between solid and liquid as well as gas and liquid. The applied method concerns electrical tomography [22]. The innovation is an original method of parallel use of a hybrid system that is a combination of the elastic net





Fig. 2. The test stand: a) hybrid tomograph, b) reactor with connected electrodes

method and artificial neural networks [7, 23]. An advantage of the described concept over other known non-invasive methods is increased resistance to interference during measurements, higher accuracy of reconstruction, unlimited imaging resolution, low cost and high speed of operation. The description of the multiply neural system enabling effective monitoring of chemical reactions using electrical tomography is presented in the further part of this study.



Fig. 3. The physical EIT model with the electrodes: a) schematic drawing, b) reactor with artifacts immersed in liquid electrodes



2. Models, methods, algorithms

Electrical impedance tomography (EIT), like as electrical capacitance tomography (ECT), are non-invasive diagnostic methods of technical objects [15, 22]. The EIT method used in the described studies processes data generated by a system of 16 electrodes installed on the surface of the reactor. Fig. 2 and 3 present a research position with a physical model with an electrode system and a hybrid tomograph adapted for EIT measurements.

Fig. 4 presents the method of measuring the voltages generated by the arrangement of 16 electrodes. Due to the unknown value of voltage drops between the tested object and the electrodes to which the electric current source (I) is connected, these electrodes are not taken into account during the measurements. For each projection angle 12 independent voltage measurements (V) can be obtained between individual pairs of adjacent electrodes. This number results from the following calculation:  $n-4 = 12$ , where  $n = 16$  is the total number of electrodes in the system, while 4 is the number of electrodes excluded from measurements within the projection angle. In this way, the total number of measurements is  $(n - 4)(n / 2) = 12 \times 8 = 96$ .




Fig. 4. The method of voltage measurement in a system of 16 electrodes: a) first measuring cycle, b) next measurement cycle

2.1. Hybrid neural algorithm

Dynamic progress in the field of low-cost technological solutions and access to advanced computational methods cause that the costs of using computing power and storage media are falling [16]. The popularity of computational techniques using parallel computations and requiring the processing of large data sets is growing [3]. As a result, there are less and less frequent situations in which researchers and designers of tomographic systems are forced to shorten the calculation time at the cost of the quality of results [17]. The presented tomographic system converts a vector of 96 voltages into an image with a

resolution of 2883 pixels. Because the designed algorithm uses 2883 parallel-acting multiply neural networks, computing power is an important factor determining the speed of the measurement system. Fig. 5 shows the model of one of the 2883 hybrid subsystems to generate the actual value of a single point of the reconstructed image.

The algorithm for training a hybrid multiply neural system has the following sequence:

1. set-up the initial conditions:
  - a) number of pixels in the mesh of the output image:  $m=2883$ ;
  - b) the size of the measurement vector  $X_n$  for each of the reconstructions:  $n=96$ ;
  - c) the number of cases that is required for neural networks training:  $N=99900$ ;
  - d) neural networks structure:  $\tilde{n}_0 - 10 - 1$ , where  $\tilde{n}_0$  means the reduced by the elastic net number of measurements at the input of the neural network generating  $v$ -th pixel, 10 neurons in the hidden layer and 1 neuron in the output layer. Logistic transfer functions were used in both layers;
2. using the elastic net method, generate a matrix of individually reduced measurement vectors for each pixel of the output image separately:
 

$X_n \rightarrow \text{elastic net} \rightarrow X_{\tilde{n},v}$ , where  $n = 96$ ,  $n > \tilde{n} > 0$ . You can use a subset with a number of cases much smaller than  $N$ , for example, 3000 randomly selected cases from the training set;
3. for  $v=1$  to  $m$  train neural network  $ANN_v$  using the training set of the cardinality  $N$ ;
4. save trained 2883 neural networks to the structural variable.

The mentioned above algorithm was implemented using the Matlab code, while the grid of the output image was modeled using the Eiders toolbox. Table 1 presents the results of the training process of one of 2883 neural networks, generating a real number determining the color of an example pixel on a tomographic image mesh. The pixel 600 was randomly chosen for the following test. Input data are included in the matrix  $X_n$  with dimensions of  $96 \times 99900$  (96 measurements,

Table 1. The results of the training process along with the division of data

Division of the data set	The number of cases in a given set	Mean Square Error (MSE)	Regression (R)
1	2	3	4
Training set (70%)	69930	$7.65053 \cdot 10^{-3}$	0.813877
Validating set (15%)	14985	$7.27605 \cdot 10^{-3}$	0.806954
Testing set (15%)	14985	$8.27152 \cdot 10^{-3}$	0.822387




Fig. 5. The model of one of 2883 subsystems generating a single point of the image

99900 cases). The input file was a vector  $Y_v$  with dimensions of  $1 \times 99900$  (a single pixel of the image  $v = 600$ , 99900 cases). Before training the network, the input vector was reduced from  $n = 96$  to  $\tilde{n} = 30$  using the elastic net method. The structure of the single neural network for point 600 was therefore:  $ANN_{600} = 30 - 10 - 1$ .

A simulated collection of 99900 data have been divided into 3 parts: training, validating and testing in proportions 70/15/15, which is reflected in the first two columns of Table 1. Columns 3 and 4 contain information about error MSE and regression R for all 3 subsets that have been used in the network learning

process. The low value of MSE and R value close to 1 testify to the good quality of the trained network.

Formula (1) presents the method of calculating MSE:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y'_i - y^*_i)^2 \quad (1)$$

where:  $n$  – image resolution;  $y'_i$  – the reference value of the  $i$ -th pixel;  $y^*_i$  – the reconstructive value of the  $i$ -th pixel.

The method of calculating the regression coefficient  $R$  is the formula (2):

$$R(y', y^*) = \frac{cov(y', y^*)}{\sigma_{y'} \sigma_{y^*}} \quad (2)$$

where:  $\sigma_{y'}$  – standard deviation of reference values,  $\sigma_{y^*}$  – standard deviation of reconstructed values.

Fig. 6a shows the training progress of the selected ANN. The homogeneous hyperbolic shape of the graph line indicates that the network has not been overtrained. The lack of fluctuations and line compliance for all 3 data sets (learning, validation and test) indicates lack of overfitting and the network's ability to generalize. The graph also shows the moment when network learning process stopped. It happened after the 53-th epoch, when the MSE of the validating set reached the value of 0.0072761. The same value can also be read from column 3 of Table 1. The validating set was used to determine the condition of stop training ANN. This condition is met if the MSE of validation set does not decrease for 6 successive epochs.

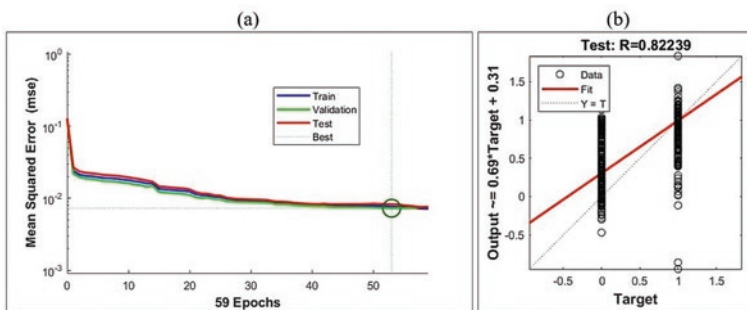


Fig. 6. Training process results for the selected network: a) MSE charts for the training, validating and testing set, b) regression statistics for the testing set

Information on the trained network is supplemented by Fig. 6b, which shows the graph of regression statistics for the testing set. The testing set gives the most reliable results regarding the quality of the received network, because the data contained therein did not have any impact on the learning process. As you can see,  $R = 0.82239$  is consistent with the information from Table 1 contained in the bottom row of column 4. The characteristic way of data distribution in Fig. 6b results from the fact that the reference output image reflects only 2 values: 1 for background color and 0 for artifact (crystals or gas bubbles).

## 2.2. Improving the quality of measurement data using the elastic net

In the case of reconstruction of tomographic images of real objects with relatively low conductivity, the data from the electrodes are usually noisy. This is the result of the imperfection of electrode insulation,

the effects of fast-changing and low currents generated by multiplexers, the influence of electromagnetic fields and many other factors. An example of technical facilities, from which tomographic data show a high level of noise are also industrial chemical reactors [18]. Disturbances of electrical signals are one of the main barriers hindering the development of tomographic methods for such objects [23].

To make the input data resistant to distortions and noise, the elastic net regularization was used [22]. In this method, we assume a certain linear system that can be described by means of the state equation (3):

$$Y = X\beta + \varepsilon \quad (3)$$

where  $Y \in R^n$  is a matrix of output variables (reconstruction),  $X \in R^{n \times (k+1)}$  represents the matrix of input variables, the coefficient  $\beta \in R^{k+1}$  means a vector with unknown parameters, and  $\varepsilon \in R^n$  reflects the sequence interference. If the linear task (4) has a solution in which the regression line intersects the y axis, then the first column of the matrix X in the linear equation (3) is a unitary column vector.

In the case when the predictors introduced into the regression model are strongly correlated with each other, a possible way to determine linear regression is to solve the problem (4):

$$\min_{(\beta_0, \beta') \in R^{k+1}} \frac{1}{2n} \sum_{i=1}^n (y_i - \beta_0 - x_i \beta')^2 + \lambda P_\alpha(\beta') \quad (4)$$

where:  $x_i = (x_{i1}, \dots, x_{ik})$ ,  $\beta' = (\beta_1, \dots, \beta_k)$  dla  $1 \leq i \leq n$

$P_\alpha$  – elastic net penalty function is defined by the equation (3):

$$P_\alpha(\beta') = (1-\alpha) \frac{1}{2} \|\beta'\|_{L_2} + \alpha \|\beta'\|_{L_1} = \sum_{j=1}^k \left( \frac{1-\alpha}{2} \beta_j^2 + \alpha |\beta_j| \right) \quad (5)$$

It can be seen that the penalty in this case is a linear combination of the  $L_1$  and  $L_2$  norms from unknown  $\beta'$  parameters. The introduction of the parameter-dependent penalties function to the objective function reduces the predictions of unknown parameters. The parameter  $\lambda$  in the task (5) represents the penalty factor. Entering the  $0 \leq \alpha \leq 1$  parameter causes the task (4) to compromise between Lasso (least absolute shrinkage and selection operator) and ridge regression. If  $\alpha = 0$  we deal with pure ridge regression called Tikhonov regularization. Ridge regression is a popular method of regularization of linear models [22].

If  $\alpha = 1$  there is a pure Lasso method in task (4). Lasso is a statistical method that allows selection of independent variables

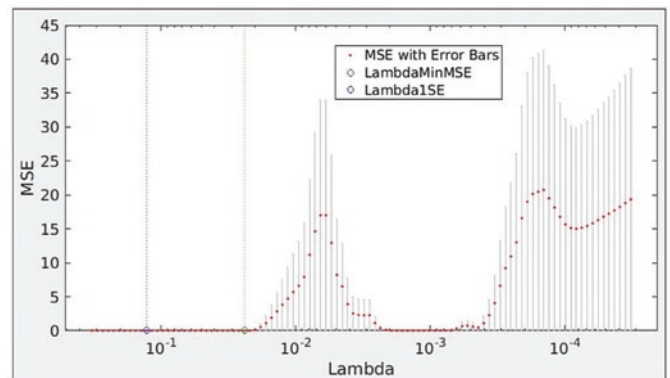


Fig. 7. Selection of Lambda parameter in the elastic net method with  $\alpha = 0.25$  based on the minimum mean square error (MSE)

and regularization of linear models. In the case of ridge regression, the coefficient of penalties is calculated in the  $L_1$  norm and for Lasso in  $L_2$  norm. Lasso is also indifferent to the correlation of predictors.

Figure 7 presents the process of selecting the parameter  $\lambda$  (lambda) in the elastic net method with the assumed  $\alpha = 0.25$  for one of the pixels of the output image. Two lambda values are marked with a green and blue dotted lines. The green line indicates the lambda value with the minimum mean square error (MSE) obtained using the cross-validation. This value has been marked with the LambdaMinMSE variable. The blue dotted line indicates the largest Lambda value, which is within the standard deviation of the minimum MSE (Lambda1SE). This lambda value means that even the worst of the tested models (with the largest MSE) still has a relatively low error value. In the described case  $\lambda = 0.129$  for  $MSE = 0.0154$  was assumed. The measurement vector has 96 values of voltage drops. In the considered case, thanks to the use of elastic net, the input vector has been reduced from 96 to 30 measurements.

### 3. Results

Fig. 8 presents a comparison of tomographic images obtained with two methods: ANN and a hybrid method combining elastic net with ANN.

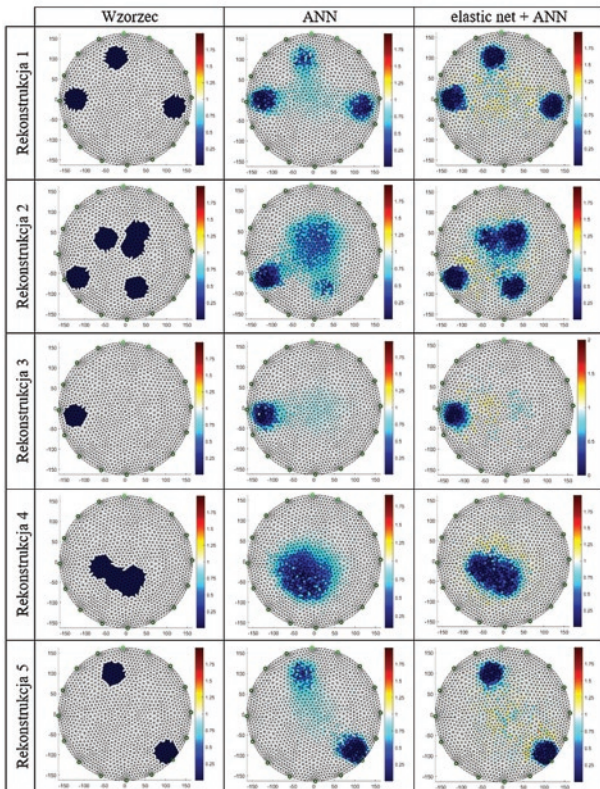


Fig. 8. Comparison of reconstructive images for ANN methods and "elastic net + ANN"

The first column contains reference images for the five tested cases. The test stand was calibrated in such a way that the value in the output, corresponding to the conductance of the reference liquid (water) equals 1. The values of the image pixels corresponding to the artefacts is 0. Next, using the physical model, real measurements were made by the ANN and elastic net + ANN (hybrid algorithm).

By comparing the images obtained with two methods, it can be noticed that in the hybrid approach, despite the reduction of the input measurement vector by almost 70% for each neural network, the visual quality of reconstruction is not worse than for pure ANN. It

should also be noted that the algorithm reconstructs the worst artifacts located near the center of the reactor. This is most likely related to the distance of the recognized objects from the electrodes. Better reconstructions are obtained for artifacts that are localized closer to the electrodes.

Visual evaluation of reconstruction is not precise and insufficient for an objective comparison of the two analyzed methods. For this reason, three quantitative imaging quality indicators were introduced: MSE (Mean Squared Error), RIE (Relative Image Error) and ICC (Image Correlation Coefficient).

The relative RIE imaging error is calculated according to the formula (6):

$$RIE = \frac{\|Y^* - Y'\|}{\|Y'\|} \quad (6)$$

where:  $Y'$  – probability distribution of the pattern image pixels;  $Y^*$  – values of reconstructed pixels.

Formula (7) shows how to calculate the ICC image correlation coefficient:

$$ICC = \frac{\sum_{i=1}^l (y_i^* - \bar{Y}^*) (y_i' - \bar{Y}')}{\sqrt{\sum_{i=1}^l (y_i^* - \bar{Y}^*)^2 \sum_{i=1}^l (y_i' - \bar{Y}')^2}} \quad (7)$$

where:  $\bar{Y}'$  – average probability distribution of the pattern image pixels;  $\bar{Y}^*$  – average value of reconstructed pixels.

The smaller are the values of MSE and RIE coefficients, the better is the reconstruction quality. In the case of ICC, the opposite is true - the closer 1, the better the correlation of the output image with the reference image, which means a more accurate reconstruction.

Table 2 contains a summary of all three reconstruction quality indicators divided into tested methods and cases. The upper part of the table contains precisely calculated MSE, RIE and ICC values. In the right-hand column there are averaged values giving the possibility to make a generalized assessment of all five cases with one indicator. In order to facilitate the choice of the better method, the bottom part of the table contains a boolean classification of all indicators. Three questions have been formulated in such a way that in the case of an affirmative answer ("truth") a better method is "elastic net + ANN". In the case of a negative response ("false"), the index would prefer the pure ANN method.

As can be seen from Table 2, in all 18 cases, including responses and average values, the hybrid method „elastic net + ANN” turned out to be better.

### 4. Discussion and conclusions

The paper presents the results of research on the development of an improved algorithm for the reconstruction of images in the field of process tomography. In particular, the focus has been placed on imaging the cross-section of industrial tank reactors in which the processes of crystallization and anaerobic digestion occur in biogas installations. To make an objective assessment of the quality of the hybrid algorithm (elastic net + ANN), comparative studies were carried out using the physical laboratory model. Equal cases of artifact systems were prepared, and then voltage drops were read from the electrode system. Due to the fact that while reading data, many current-voltage states are transient, the data contained a certain level of noise. Af-



Table 2. Comparison of reconstruction indicators

Quality indicator of reconstruction		Number of reconstruction					Mean
		1	2	3	4	5	
ANN	MSE	0.0232	0.0573	0.0061	0.0337	0.0198	0.0280
	RIE	0.1587	0.2547	0.0795	0.1913	0.1451	0.1658
	ICC	0.8319	0.6715	0.8694	0.7301	0.7982	0.7802
elastic net + ANN	MSE	0.0158	0.0388	0.0047	0.0238	0.0115	0.0189
	RIE	0.1312	0.2096	0.0695	0.1610	0.1107	0.1364
	ICC	0.8804	0.7892	0.8987	0.8177	0.8907	0.8553
Is the MSE of the hybrid algorithm smaller than the MSE of pure ANN?		TRUE	TRUE	TRUE	TRUE	TRUE	TRUE
Is the RIE hybrid algorithm smaller than RIE of pure ANN?		TRUE	TRUE	TRUE	TRUE	TRUE	TRUE
Is the ICC of the hybrid algorithm greater than the ICC of pure ANN?		TRUE	TRUE	TRUE	TRUE	TRUE	TRUE

ter filtering the data using the background reference values (reactor without artefacts) obtained results were illustrated and converted into quality indicators: MSE, RIE and ICC.

Normally, if the clear measurement data used for the imaging were simulated and did not contain interference, removing 70% of the predictors (eg, reduction from 96 to 30) would result in poor image quality. The carried out experiments showed that it was different in the case of data with a certain level of noise. Although the obtained reconstructions, both for pure ANN and for the hybrid method, are still not perfect, they are nevertheless sufficiently accurate to determine the amount, shape and location of the artifacts. The time of reconstruction in all investigated cases with the Intel Core i7 processor machine did not exceed 1 second. This means that the developed algorithm can also be used in processes with high reaction dynamics and even in flow systems [24].

It is significant that in Table 2, in all cases tested and for all three quality indicators, better results were obtained using the “elastic net

+ ANN” algorithm, not pure ANN. It turns out that the application of elastic net caused that along with the removal of 70% of input variables, a lot of noisy data was deleted, generating various types of disturbances in the output image. This fact is proof that the newly developed hybrid algorithm “cleanses” the data and makes the tomographic system immune to various types of interference and noisy data.

The results of the research have proved that the use of the described solution enables a higher resolution of images of crystals or gas bubbles appearing inside the reactor, which essentially contributes to the early detection of hazards and facilitates solving the operational problems of industrial systems.

#### Acknowledgements

*the authors would like to thank the authorities and employees of the Faculty of Mathematics, Physics and Computer Science of UMCS in Lublin for sharing supercomputing resources.*

#### References

1. Babout L, Grudzień K, Wiącek J, Niedostatkiewicz M, Karpiński B, Szkodo M. Selection of Material for X-Ray Tomography Analysis and DEM Simulations: Comparison between Granular Materials of Biological and Non-Biological Origins. *Granular Matter* 2018; 20 (3): 38, <https://doi.org/10.1007/s10035-018-0809-y>.
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. Dusek J, Hladky D, Mikulka J. Electrical Impedance Tomography Methods and Algorithms Processed with a GPU. *Progress In Electromagnetics Research Symposium - Spring (PIERS)* 2017; 1710–14, <https://doi.org/10.1109/PIERS.2017.8262025>.
4. Garbaa H, Jackowska-Strumiłło L, Grudzień K, Romanowski A. Application of Electrical Capacitance Tomography and Artificial Neural Networks to Rapid Estimation of Cylindrical Shape Parameters of Industrial Flow Structure. *Archives of Electrical Engineering* 2016; 65 (4): 657–69, <https://doi.org/10.1515/ae-2016-0046>.
5. Grudzien K, Chaniecki Z, Romanowski A, Sankowski D, Nowakowski J, Niedostatkiewicz M. Application of Twin-Plane ECT Sensor for Identification of the Internal Imperfections inside Concrete Beams. *IEEE International Instrumentation and Measurement Technology Conference Proceedings* 2016; May, 1–6, <https://doi.org/10.1109/I2MTC.2016.7520512>.
6. Kłosowski G, Gola A, Świć A. Application of Fuzzy Logic Controller for Machine Load Balancing in Discrete Manufacturing System. In *International Conference on Intelligent Data Engineering and Automated Learning* 2015; 256–63, [https://doi.org/10.1007/978-3-319-24834-9\\_31](https://doi.org/10.1007/978-3-319-24834-9_31).
7. Kłosowski G, Rymarczyk T, Gola A. Increasing the Reliability of Flood Embankments with Neural Imaging Method. *Applied Sciences* 2018; 8 (9): 1457, <https://doi.org/10.3390/app8091457>.
8. Kłosowski G, Rymarczyk T. Using neural networks and deep learning algorithms in electrical impedance tomography. *Informatyka Automatyka Pomiary w Gospodarce i Ochronie Środowiska* 2017; 7 (3): 99–102, <https://doi.org/10.5604/01.3001.0010.5226>.

9. Korzeniewska E, Gałązka-Czarnecka I, Czarnecki A, Piekarska A, Krawczyk A. Influence of PEF on Antocyanins in Wine. *Przeegląd Elektrotechniczny* 2018; 1 (1): 59–62, <https://doi.org/10.15199/48.2018.01.15>.
10. Korzeniewska E, Walczak M, Rymaszewski J. Elements of Elastic Electronics Created on Textile Substrate, *Proceedings of the 24th International Conference Mixed Design of Integrated Circuits and Systems - MIXDES 2017*; 2017, 447-45, <https://doi.org/10.23919/MIXDES.2017.8005250>.
11. Kosicka E, Kozłowski E, Mazurkiewicz D. Intelligent Systems of Forecasting the Failure of Machinery Park and Supporting Fulfilment of Orders of Spare Parts. In: Burduk A., Mazurkiewicz D. (eds) *Intelligent Systems in Production Engineering and Maintenance – ISPEM 2017*. ISPEM 2017. *Advances in Intelligent Systems and Computing*, vol 637. Springer, Cham, 2018, [https://doi.org/10.1007/978-3-319-64465-3\\_6](https://doi.org/10.1007/978-3-319-64465-3_6).
12. Kozłowski E., Mazurkiewicz D., Kowalska B., Kowalski, D. Binary Linear Programming as a Decision-Making Aid for Water Intake Operators. In: Burduk A., Mazurkiewicz D. (eds) *Intelligent Systems in Production Engineering and Maintenance – ISPEM 2017*. ISPEM 2017. *Advances in Intelligent Systems and Computing*, vol 637. Springer, Cham, 2018, [https://doi.org/10.1007/978-3-319-64465-3\\_20](https://doi.org/10.1007/978-3-319-64465-3_20).
13. Kryszyn J, Smolik W T, 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>.
14. Kryszyn J, Waldemar S. Toolbox for 3d Modelling and Image Reconstruction in Electrical Capacitance Tomography. *Informatics Control Measurement in Economy and Environment Protection* 2017; 7 (1).
15. Lopato P, Tomasz C, Sikora R, Gratkowski S, Ziolkowski M. Full Wave Numerical Modelling of Terahertz Systems for Nondestructive Evaluation of Dielectric Structures. *COMPEL - The International Journal for Computation and Mathematics in Electrical and Electronic Engineering* 2013; 32 (3): 736–49, <https://doi.org/10.1108/03321641311305719>.
16. Majchrowicz M, Kapusta P, Jackowska-Strumiłło L, Sankowski D. Acceleration of image reconstruction process in the electrical capacitance tomography 3d in heterogeneous, multi-GPU system. *Informatics Control Measurement in Economy and Environment Protection* 2017; 7 (1): 37–41, <https://doi.org/10.5604/01.3001.0010.4579>.
17. Mikulka J. Accelerated Reconstruction of T2 Maps in Magnetic Resonance Imaging. *Measurement Science Review* 2015; 4: 210–18, <https://doi.org/10.1515/msr-2015-0029>.
18. Park S, Na J, Kim M, Lee J M. Multi-Objective Bayesian Optimization of Chemical Reactor Design Using Computational Fluid Dynamics. *Computers & Chemical Engineering* 2018; 119 : 25–37, <https://doi.org/10.1016/j.compchemeng.2018.08.005>.
19. Psuj G. Multi-Sensor Data Integration Using Deep Learning for Characterization of Defects in Steel Elements. *Sensors* 18 (2): 292, <https://doi.org/10.3390/s18010292>.
20. Romanowski A. Big Data-Driven Contextual Processing Methods for Electrical Capacitance Tomography. *IEEE Transactions on Industrial Informatics* 2018; 1–1, <https://doi.org/10.1109/TII.2018.2855200>.
21. Rymarczyk T, Adamkiewicz P, Polakowski K, Sikora J. Effective Ultrasound and Radio Tomography Imaging Algorithm for Two-Dimensional Problems. *Przeegląd Elektrotechniczny* 2018; 94 (6): 62–69.
22. Rymarczyk T, Kłosowski G, Kozłowski E. A Non-Destructive System Based on Electrical Tomography and Machine Learning to Analyze the Moisture of Buildings. *Sensors* 2018; 18 (7): 2285.
23. Rymarczyk T, Kłosowski G. Application of Neural Reconstruction of Tomographic Images in the Problem of Reliability of Flood Protection Facilities. *Eksploatacja i Niezawodność - Maintenance and Reliability* 2018; 20 (3): 425–34, <https://doi.org/10.17531/ein.2018.3.11>.
24. Rymarczyk T, Sikora J. Applying Industrial Tomography to Control and Optimization Flow Systems. *Open Physics* 2018; 16 (1): 332–45, <https://doi.org/10.1515/phys-2018-0046>.
25. Sobaszek Ł, Gola A, Świć A. Predictive Scheduling as a Part of Intelligent Job Scheduling System: in, 358–67. Springer, Cham 2018, [https://doi.org/10.1007/978-3-319-64465-3\\_35](https://doi.org/10.1007/978-3-319-64465-3_35).
26. Soleimani M, Mitchell C N, Banasiak R, Wajman R, Adler A. Four-dimensional electrical capacitance tomography imaging using experimental data. *Progress In Electromagnetics Research* 2009; 90: 171–86, <https://doi.org/10.2528/PIER09010202>.
27. Tian G, Yang B, Dong M, Zhu R, Yin F, Zhao X, Wang Y, Xiao W, Wang Q, Zhang W. The Effect of Temperature on the Microbial Communities of Peak Biogas Production in Batch Biogas Reactors. *Renewable Energy* 2018; 123: 15–25, <https://doi.org/10.1016/j.renene.2018.01.119>.
28. Voutilainen A, Lehtikoinen A, Vauhkonen M, Kaipio J P. Three-Dimensional Nonstationary Electrical Impedance Tomography with a Single Electrode Layer. *Measurement Science and Technology* 2010; 21 (3): 035107, <https://doi.org/10.1088/0957-0233/21/3/035107>.
29. Wang Mi. *Industrial Tomography: Systems and Applications*. Edited by Elsevier Ltd. Woodhead Publishing 2015.
30. Ziolkowski M, Gratkowski S, Zywicka A R. Analytical and Numerical Models of the Magnetoacoustic Tomography with Magnetic Induction. *COMPEL - The International Journal for Computation and Mathematics in Electrical and Electronic Engineering* 2018; 37 (2): 538–48, <https://doi.org/10.1108/COMPEL-12-2016-0530>.

---

**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

**Grzegorz KŁOSOWSKI**

Lublin University of Technology  
Department of Organization of Enterprise  
ul. Nadbystrzycka 38D, 20-618 Lublin, Poland

E-mails: [tomasz@rymarczyk.com](mailto:tomasz@rymarczyk.com), [g.klosowski@pollub.pl](mailto: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](mailto: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](mailto:g.klosowski@pollub.pl)

**Nowatorskie metody neuronowej rekonstrukcji obrazów tomograficznych  
w eksploatacji zbiornikowych reaktorów przemysłowych**

***Słowa kluczowe:** tomografia elektryczna, procesy przemysłowe, sterowanie procesami, sieci neuronowe, uczenie maszynowe*


**Streszczenie:** W artykule przedstawiono nowatorską koncepcję usprawnienia monitoringu i optymalizacji procesów przemysłowych. Opracowana metoda bazuje na systemie osobno wytrenowanych wielu sieci neuronowych, w którym każda sieć generuje pojedynczy punkt obrazu wyjściowego. Dzięki zastosowaniu metody elastic net zaimplementowany algorytm redukuje z wejściowego wektora pomiarowego zmienne skorelowane i nieistotne, czyniąc go bardziej odpornym na zjawisko zaszumienia danych. Przewagą opisywanego rozwiązania nad znanymi metodami nieinwazyjnymi jest uzyskanie wyższej rozdzielczości obrazów dynamicznie pojawiających się wewnątrz reaktora artefaktów (kryształów lub pęcherzy gazowych), co zasadniczo przyczynia się do wczesnego wykrycia zagrożeń i problemów związanych z eksploatacją systemów przemysłowych, a tym samym zwiększa efektywność sterowania procesami chemicznymi.

**1. Wprowadzenie**

Wiele produktów inżynierii chemicznej powstaje jako rezultat procesów realizowanych przy użyciu ciągów technologicznych, w których kluczową rolę pełnią chemiczne reaktory przemysłowe. Reaktor chemiczny jest naczyniem przystosowanym do przeprowadzania reakcji zachodzących wewnątrz niego. Zadaniem zbiornikowych reaktorów przemysłowych jest zapewnienie optymalnych parametrów ekonomicznych procesów chemicznych [18]. Można to osiągnąć poprzez odpowiednią konstrukcję reaktora oraz poprzez umiejętne nakładanie się trzech rodzajów podprocesów zachodzących wewnątrz reaktora, a mianowicie na przenoszeniu masy, pędu i ciepła. W ten sposób sterowanie procesem można oprzeć na dynamicznym doborze parametrów, takich jak: intensywność mieszania, temperatura, ciśnienie, proporcje substratów i innych. Przedstawione badania obejmowały reaktory, w których reakcje zachodzą



między ciałem stałym i cieczą oraz gazem i cieczą. Schemat reaktora zbiornikowego przedstawiono na Rys. 1.



Rys. 1. Schemat reaktora zbiornikowego z systemem mieszania

Pierwszy rodzaj reakcji dotyczy krystalizacji ciał stałych w otoczeniu cieczy. Obejmuje on przemysłowe procesy syntezy i oczyszczania substancji stałych oraz zmiany właściwości cząstek. Reaktory, w których następuje krystalizacja znajdują zastosowanie w wielu gałęziach gospodarki, w tym: w branży chemicznej, spożywczej [9], metalurgicznej oraz utylizacji odpadów [27]. Jednym z zadań układów monitorujących tego rodzaju procesy jest dostarczanie precyzyjnej informacji o ilości, wielkości i położeniu kryształów powstających w cieczy w czasie rzeczywistym.

Drugi rodzaj reakcji dotyczy fazy gazowej i fazy ciekłej. Procesy tego rodzaju są wykorzystywane między innymi przy produkcji biogazu. Fizykochemiczne reaktory fermentacyjne są kluczowym elementem instalacji biogazowych. Wewnątrz tych reaktorów dokonuje się fermentacja metanowa odpadów organicznych. Prawidłowa eksploatacja systemów technicznych jest jednym z kluczowych warunków uzyskania odpowiedniego poziomu niezawodności procesów przemysłowych [10].

Istnieją dwa zasadnicze powody aby monitorować stany procesów dynamicznych. Pierwszym z nich jest wykrywanie zbliżających się awarii [11], do których zaliczyć można uszkodzenie infrastruktury technicznej, ponadnormatywne odchylenie krytycznych parametrów procesu lub przerwanie jego ciągłości. Efektywny system monitoringu ma za zadanie umożliwić identyfikację problemu na tyle wcześnie, aby możliwe było podjęcie skutecznych działań korygujących.

Drugim powodem stosowania monitoringu stanów procesów przemysłowych jest konieczność sprawowania kontroli nad przebiegiem procesu przemysłowego [29]. Jest to niezbędne z punktu widzenia zapewnienia odpowiedniego poziomu jakości. Aby skutecznie sterować procesami wielofazowymi, w których uczestniczą substancje mogące dynamicznie zmieniać stany skupienia, należy zastosować efektywne metody monitoringu. To trudne zadanie, biorąc pod uwagę agresywne warunki w jakich zachodzą reakcje wewnątrz reaktora. Stosując czujniki inwazyjne, problemem jest brak możliwości bezpośredniego zbadania dowolnego fragmentu wnętrza reaktora, punktowość prowadzonych pomiarów, konieczność stosowania wielu różnych systemów monitoringu jednocześnie oraz duża niepewność w określaniu stanu dynamicznego procesu na podstawie niepełnych danych (metoda pośrednia). Wśród nieinwazyjnych metod wykorzystywanych w monitorowaniu procesów przemysłowych można wyróżnić: elektryczną tomografię pojemnościową [2, 4, 5, 13, 14, 16, 20, 26] elektryczną tomografię impedancyjną [3, 8, 28], tomografię magnetoakustyczną [30], ultradźwiękową i radiową [21], tomografię promieniami X [1] i wiele innych. Ostatnio, coraz więcej prac badawczych z zakresu eksploatacji systemów przemysłowych uwzględnia zastosowanie różnorodnych metod obliczeniowych, takich jak: inteligentne metody predykcyjne [25], logika rozmyta [6], uczenie maszynowe [22], modelowanie numeryczne [15], głębokie uczenie [8, 19] oraz programowanie binarne [12].

Obecnie stosowane techniki nieinwazyjnego monitorowania procesów przemysłowych nie w pełni zaspokajają bieżące potrzeby eksploatacyjne. Otrzymywane odwzorowania obrazów badanych zjawisk i procesów bywają nieostre, niejednoznaczne, trudne do zinterpretowania, obarczone niedokładnościami zarówno w zakresie ilości wykrytych w reaktorze artefaktów (kryształów lub pęcherzy gazu), jak również ich rozmiarów i położenia. W rezultacie, aby otrzymać precyzyjne informacje odnośnie stanu monitorowanego procesu stosuje się systemy redundantne, co znacząco podnosi koszty eksploatacji.

Wyżej wymienione utrudnienia i niedoskonałości stosowanych metod monitoringu zbiornikowych reaktorów chemicznych są powodem, z którego wynika potrzeba ich doskonalenia. Zastosowanie ulepszonej metody monitorowania spowoduje wzrost niezawodności procesów zachodzących wewnątrz reaktorów oraz obniży koszty eksploatacji systemów przemysłowych.


Celem niniejszego opracowania jest zaprezentowanie udoskonalonej metody monitoringu i optymalizacji procesów chemicznych zachodzących w zbiornikowych reaktorach heterogenicznych, w których reakcje zachodzą pomiędzy ciałem stałym i cieczą oraz gazem i cieczą. Zastosowana metoda dotyczy tomografii elektrycznej [22], a innowacją jest oryginalny sposób równoległego wykorzystania systemu hybrydowych modułów stanowiących kombinację metody elastic net i sztucznych sieci neuronowych [7, 23]. Przewagą opisywanej koncepcji nad innymi, znanymi metodami nieinwazyjnymi jest zwiększona odporność na zakłócenia powstające w trakcie pomiarów, wyższa dokładność rekonstrukcji, nieograniczona rozdzielczość obrazowania, niski koszt oraz duża szybkość działania. W dalszej części niniejszego opracowania przedstawiono opis systemu neuronowego umożliwiającego efektywny monitoring reakcji chemicznych z wykorzystaniem tomografii elektrycznej.

## 2. Modele, metody, algorytmy

Elektryczna tomografia impedancyjna (EIT – electrical impedance tomography), podobnie jak elektryczna tomografia pojemnościowa (ECT – electrical capacitance tomography) należą do nieinwazyjnych metod diagnostyki obiektów technicznych [15, 22]. Zastosowana w opisywanych badaniach metoda EIT przetwarza dane generowane przez układ 16 elektrod umieszczonych na powierzchni reaktora. Na Rys. 2 i 3 przedstawiono stanowisko badawcze, fizyczny model z układem elektrod oraz tomograf hybrydowy przystosowany do pomiarów EIT.




Rys. 2. Stanowisko badawcze:  
a) tomograf hybrydowy, b) reaktor z podłączonymi elektrodami



Rys. 3. Model fizyczny z układem elektrod EIT:

a) rysunek schematyczny, b) reaktor z zanurzonymi w cieczy artefaktami

Na Rys. 4 przedstawiono sposób pomiaru napięć generowanych za pomocą układu 16 elektrod. Z uwagi na nieznaną wartość spadków napięć między badanym obiektem a elektrodami, do których podłączone jest źródło prądu elektrycznego (I), elektrody te nie są uwzględniane podczas pomiarów. Dla każdego kąta projekcji można uzyskać 12 niezależnych pomiarów napięcia (V) pomiędzy poszczególnymi parami sąsiadujących ze sobą elektrod. Liczba ta wynika z następującego wyliczenia:  $n-4=12$ , gdzie  $n=16$  jest całkowitą liczbą elektrod w układzie, natomiast 4 jest liczbą elektrod wyłączonych z pomiarów w ramach kąta projekcji. W ten sposób, całkowita liczba pomiarów wynosi  $(n - 4)(n/2) = 12 \times 8 = 96$ .



Rys. 4. Sposób pomiaru napięć w układzie 16 elektrod:

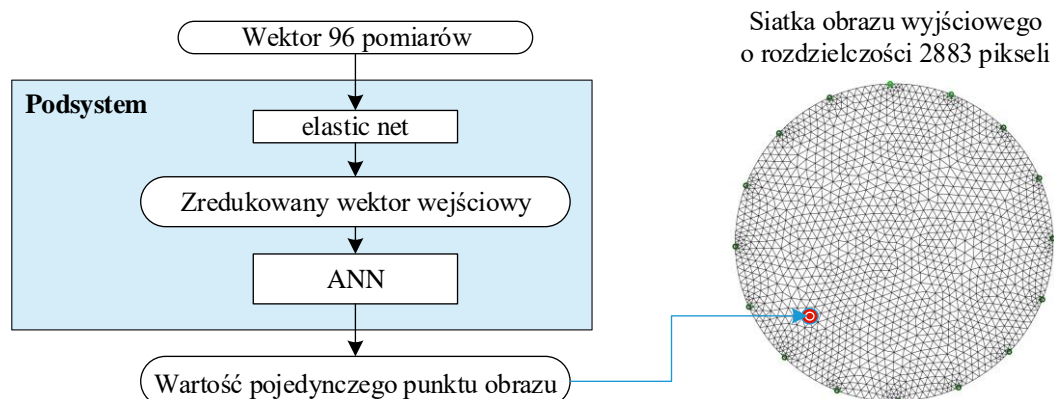
a) pierwszy cykl pomiarowy, b) kolejny cykl pomiarowy

## 2.1. Hybrydowy algorytm neuronowy

Dynamiczny postęp w dziedzinie tanich rozwiązań technologicznych i dostęp do zaawansowanych metod obliczeniowych sprawia, że koszty wykorzystania mocy obliczeniowej i nośników pamięci spadają [16]. Rośnie popularność technik obliczeniowych wykorzystujących obliczenia równoległe i wymagających przetwarzania dużych zbiorów danych [3]. Dzięki temu, coraz rzadziej mają miejsce sytuacje, w których badacze i projektanci systemów tomograficznych są zmuszeni skracać czas obliczeń kosztem jakości wyników [17]. Prezentowany system tomograficzny przetwarza wektor 96 wartości napięć na obraz o rozdzielczości 2883 pikseli. Ponieważ zaprojektowany algorytm wykorzystuje 2883 równoległe działające sieci neuronowe, moc obliczeniowa jest istotnym czynnikiem determinującym szybkość działania układu pomiarowego. Na Rys. 5 przedstawiono model



jednego z 2883 hybrydowych podsystemów do generowania wartości rzeczywistej pojedynczego punktu rekonstruowanego obrazu.



Rys. 5. Model jednego z 2883 podsystemów generujący pojedynczy punkt obrazu

Algorytm trenowania hybrydowego systemu neuronowego ma następujący przebieg:

1. ustal warunki początkowe:
  - a. liczba pikseli na siatce obrazu wyjściowego:  $m=2883$ ;
  - b. licznosc wektora pomiarów  $\mathbf{X}_n$  dla każdej z rekonstrukcji:  $n=96$ ;
  - c. liczba przypadków uczących potrzebnych do wytrenowania sieci neuronowej:  $N=99900$ ;
  - d. struktura sieci neuronowej:  $\tilde{n}_v-10-1$ , gdzie  $\tilde{n}_v$  oznacza zredukowaną metodą elastic net liczbę pomiarów na wejściu dla sieci neuronowej generującej  $v$ -ty piksel, 10 neuronów w warstwie ukrytej oraz 1 neuron w warstwie wyjściowej. W obu warstwach zastosowano logistyczne funkcje transferowe;
2. wykorzystując metodę elastic net wygeneruj macierz indywidualnie zredukowanych wektorów pomiarowych dla każdego piksela obrazu wyjściowego osobno:  $\mathbf{X}_n \rightarrow \text{elastic net} \rightarrow \mathbf{X}_{\tilde{n},v}$ , gdzie  $n = 96, n > \tilde{n} > 0$ . Można do tego celu użyć podzbioru o licznosci znacznie mniejszej niż wynosi  $N$ , np. 3000 losowo wybranych przypadków ze zbioru uczącego;
3. dla  $v=1$  do  $m$  trenuj sieć neuronową  $\text{ANN}_v$  z wykorzystaniem zbioru uczącego o licznosci  $N$ ;
4. zapisz wytrenowane 2883 sieci neuronowe do zmiennej strukturalnej.

Powyższy algorytm został zaimplementowany za pomocą języka Matlab, natomiast siatkę obrazu wyjściowego zamodelowano przy użyciu pakietu Eidors. W Tabeli 1 przedstawiono rezultaty procesu uczenia jednej z 2883 sieci neuronowych, generujących liczbę rzeczywistą determinującą kolor przykładowego piksela na siatce obrazu tomograficznego. Do poniższego testu wybrano punkt nr 600. Dane wejściowe zawarto w macierzy  $\mathbf{X}_n$  o wymiarach  $96 \times 99900$  (96 pomiarów, 99900 przypadków). Zbiorem wyjściowym był wektor  $\mathbf{Y}_v$  o wymiarach  $1 \times 99900$  (1 punkt obrazu  $v=600$ , 99900 przypadków). Przed wytrenowaniem sieci, zredukowano wektor wejściowy z  $n = 96$  do  $\tilde{n} = 30$  stosując metodę elastic net. Struktura sieci neuronowej dla punktu nr 600 była więc następująca:  $\text{ANN}_{600}=30-10-1$ .

Wygenerowany symulacyjnie zbiór 99900 danych został podzielony na 3 części: uczącą, walidacyjną i testową w proporcjach 70/15/15, co znajduje swoje odzwierciedlenie w pierwszych dwóch kolumnach Tabeli 1. Kolumny 3 i 4 zawierają informacje o błędzie MSE oraz regresji R dla wszystkich 3 zbiorów, jakie zostały osiągnięte w procesie uczenia sieci. Niska wartość MSE i R zbliżona do 1 świadczą o dobrej jakości wytrenowanej sieci.

Tabela 1. Rezultaty procesu uczenia wraz z podziałem danych

Podział zbioru danych	Liczba przypadków w danym zbiorze	Błąd średniokwadratowy (MSE)	Regresja (R)
1	2	3	4
Zbiór uczący (70%)	69930	$7.65053 \cdot 10^{-3}$	0.813877
Zbiór walidacyjny (15%)	14985	$7.27605 \cdot 10^{-3}$	0.806954
Zbiór testowy (15%)	14985	$8.27152 \cdot 10^{-3}$	0.822387

Formuła (1) przedstawia sposób wyliczenia MSE:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y'_i - y^*_i)^2 \quad (1)$$

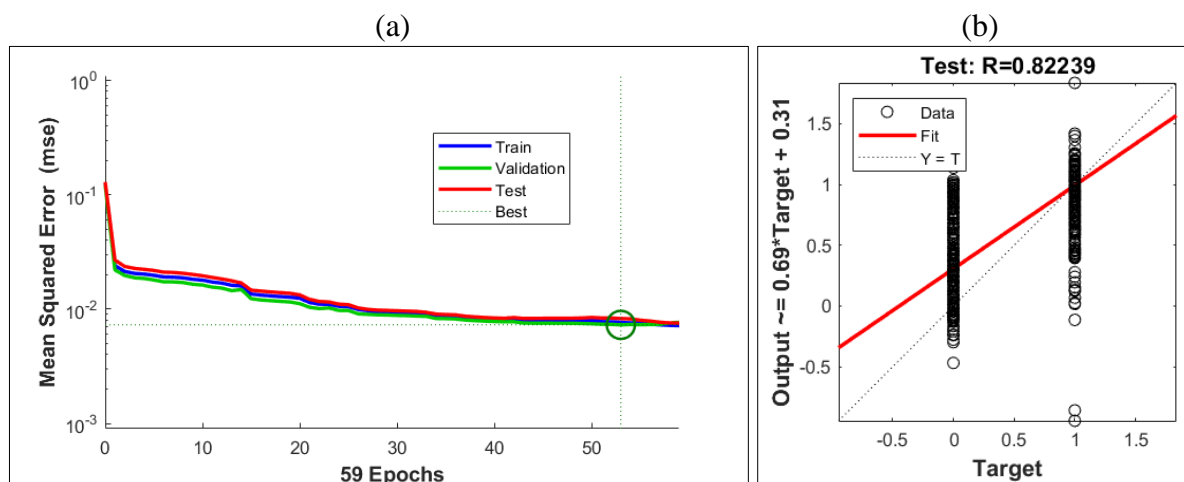
gdzie:  $n$  – rozdzielczość obrazu;  $y'_i$  – wartość referencyjna  $i$ -tego piksela;  $y^*_i$  – wartość rekonstrukcyjna  $i$ -tego piksela.

Sposób kalkulacji współczynnika regresji R przedstawia formuła (2):

$$R(y', y^*) = \frac{cov(y', y^*)}{\sigma_{y'} \sigma_{y^*}} \quad (2)$$

gdzie:  $\sigma_{y'}$  – odchylenie standardowe wartości referencyjnych,  $\sigma_{y^*}$  – odchylenie standardowe wartości zrekonstruowanych.

Na Rys. 6a przedstawiono wykres przebiegu uczenia wybranej ANN. Jednorodny, hiperboliczny kształt linii wykresu świadczy o braku przeuczenia sieci. Brak fluktuacji oraz zgodność linii dla wszystkich 3 zbiorów danych (uczącego, walidacyjnego i testowego) świadczy o braku przeuczenia oraz o zdolności sieci do generalizacji. Wykres przedstawia także moment, w którym nastąpiło zatrzymanie uczenia sieci. Miało to miejsce po 53 epoce, kiedy MSE zbioru walidacyjnego osiągnęło wartość 0.0072761. Tę samą wartość można również odczytać z kolumny 3 Tabeli 1. Zbiór walidacyjny został wykorzystany do ustalenia warunku zatrzymania uczenia ANN. Warunek ten jest spełniony, jeśli przez 6 kolejnych epok MSE zbioru walidacyjnego nie zmniejsza się.



Rys. 6. Rezultaty procesu uczenia dla wybranej sieci: a) wykresy błędów MSE dla zbioru uczącego, walidacyjnego i testowego, b) statystyka regresyjna dla zbioru testowego

Informacje na temat wytrenowanej sieci uzupełnia Rys. 6b, na którym przedstawiono wykres statystyki regresyjnej dla zbioru testowego. Zbiór testowy daje najbardziej wiarygodne rezultaty odnośnie jakości otrzymanej sieci, bowiem dane w nim zawarte nie miały żadnego wpływu na proces uczenia. Jak widać  $R=0.82239$  jest zgodna z informacją z Tabeli 1 zawartą w dolnym rzędzie kolumny 4. Charakterystyczny sposób rozmieszczenia danych na Rys. 6b wynika z faktu, że wzorcowy obraz wyjściowy odzwierciedla jedynie 2 wartości: 1 – dla koloru tła oraz 0 – kolor artefaktu (kryształu lub pęcherza gazu).

## 2.2. Poprawa jakości danych pomiarowych metodą elastic net

W przypadku rekonstrukcji obrazów tomograficznych obiektów rzeczywistych o stosunkowo niskiej przewodności, dane z elektrod są zazwyczaj zaszumione. Jest to wynikiem niedoskonałości izolacji elektrod, wpływom szybkozmiennych prądów o niskim natężeniu generowanych przez multipleksery, wpływom pól elektromagnetycznych oraz wielu innych czynników. Przykładem obiektów technicznych, z których dane tomograficzne wykazują wysoki poziom szumu są także przemysłowe reaktory chemiczne [18]. Zakłócenia sygnałów elektrycznych są jedną z głównych barier utrudniających opracowanie metod tomograficznych dla takich obiektów [23].

Aby uodpornić dane wejściowe na zakłócenia i zniekształcenia, zastosowano regularyzację elastic net [22]. W metodzie tej zakładamy pewien system liniowy, który może być opisany za pomocą równania stanu (3),

$$Y = X\beta + \varepsilon \quad (3)$$

gdzie  $Y \in R^n$  jest macierzą zmiennych wyjściowych (rekonstrukcji),  $X \in R^{n \times (k+1)}$  reprezentuje macierz zmiennych wejściowych, współczynnik  $\beta \in R^{k+1}$  oznacza wektor o nieznanym parametrach, a  $\varepsilon \in R^n$  odzwierciedla sekwencję zakłóceń. Jeżeli zadanie liniowe (4) posiada rozwiązanie, w którym prosta regresji przecina oś y, wtedy pierwsza kolumna macierzy X w równaniu liniowym (3) jest jednostkowym wektorem kolumnowym.

W przypadku gdy predyktory wprowadzane do modelu regresji są ze sobą silnie skorelowane, możliwym sposobem określenia regresji liniowej jest rozwiązanie zadania (4).

$$\min_{(\beta_0, \beta') \in R^{k+1}} \frac{1}{2n} \sum_{i=1}^n (y_i - \beta_0 - x_i \beta')^2 + \lambda P_\alpha(\beta') \quad (4)$$

gdzie:  $x_i = (x_{i1}, \dots, x_{ik})$ ,  $\beta' = (\beta_1, \dots, \beta_k)$  dla  $1 \leq i \leq n$


$P_\alpha$  – funkcja kary elastic net określona równaniem (3).

$$P_\alpha(\beta') = (1-\alpha) \frac{1}{2} \|\beta'\|_{L_2}^2 + \alpha \|\beta'\|_{L_1} = \sum_{j=1}^k \left( \frac{1-\alpha}{2} \beta_j^2 + \alpha |\beta_j| \right) \quad (5)$$

Można zauważyć, że kara w tym przypadku jest liniową kombinacją norm  $L_1$  i  $L_2$  z nieznanymi parametrami  $\beta'$ . Wprowadzenie funkcji kar zależnych od parametrów do funkcji celu redukuje prognozy nieznanymi parametrami. Parametr  $\lambda$  w zadaniu (5) reprezentuje współczynnik kary. Wprowadzenie parametru  $0 \leq \alpha \leq 1$  sprawia, że zadanie (4) zachowuje kompromis między Lasso (ang. least absolute shrinkage and selection operator) i regresją grzbietową. Jeżeli  $\alpha = 0$  mamy do czynienia z czystą regresją grzbietową zwaną regularyzacją Tichonowa. Regresja grzbietowa jest popularną metodą regularyzacji modeli liniowych [22].



Jeżeli  $\alpha = 1$ , w zadaniu (4) występuje czysta metoda Lasso. Lasso to metoda statystyczna, która umożliwia dobór zmiennych niezależnych i regularyzację modeli liniowych. W przypadku regresji grzbietowej współczynnik kar obliczany jest w normie  $L_1$  a dla Lasso w  $L_2$ . Lasso jest także obojętna na korelację predyktorów.



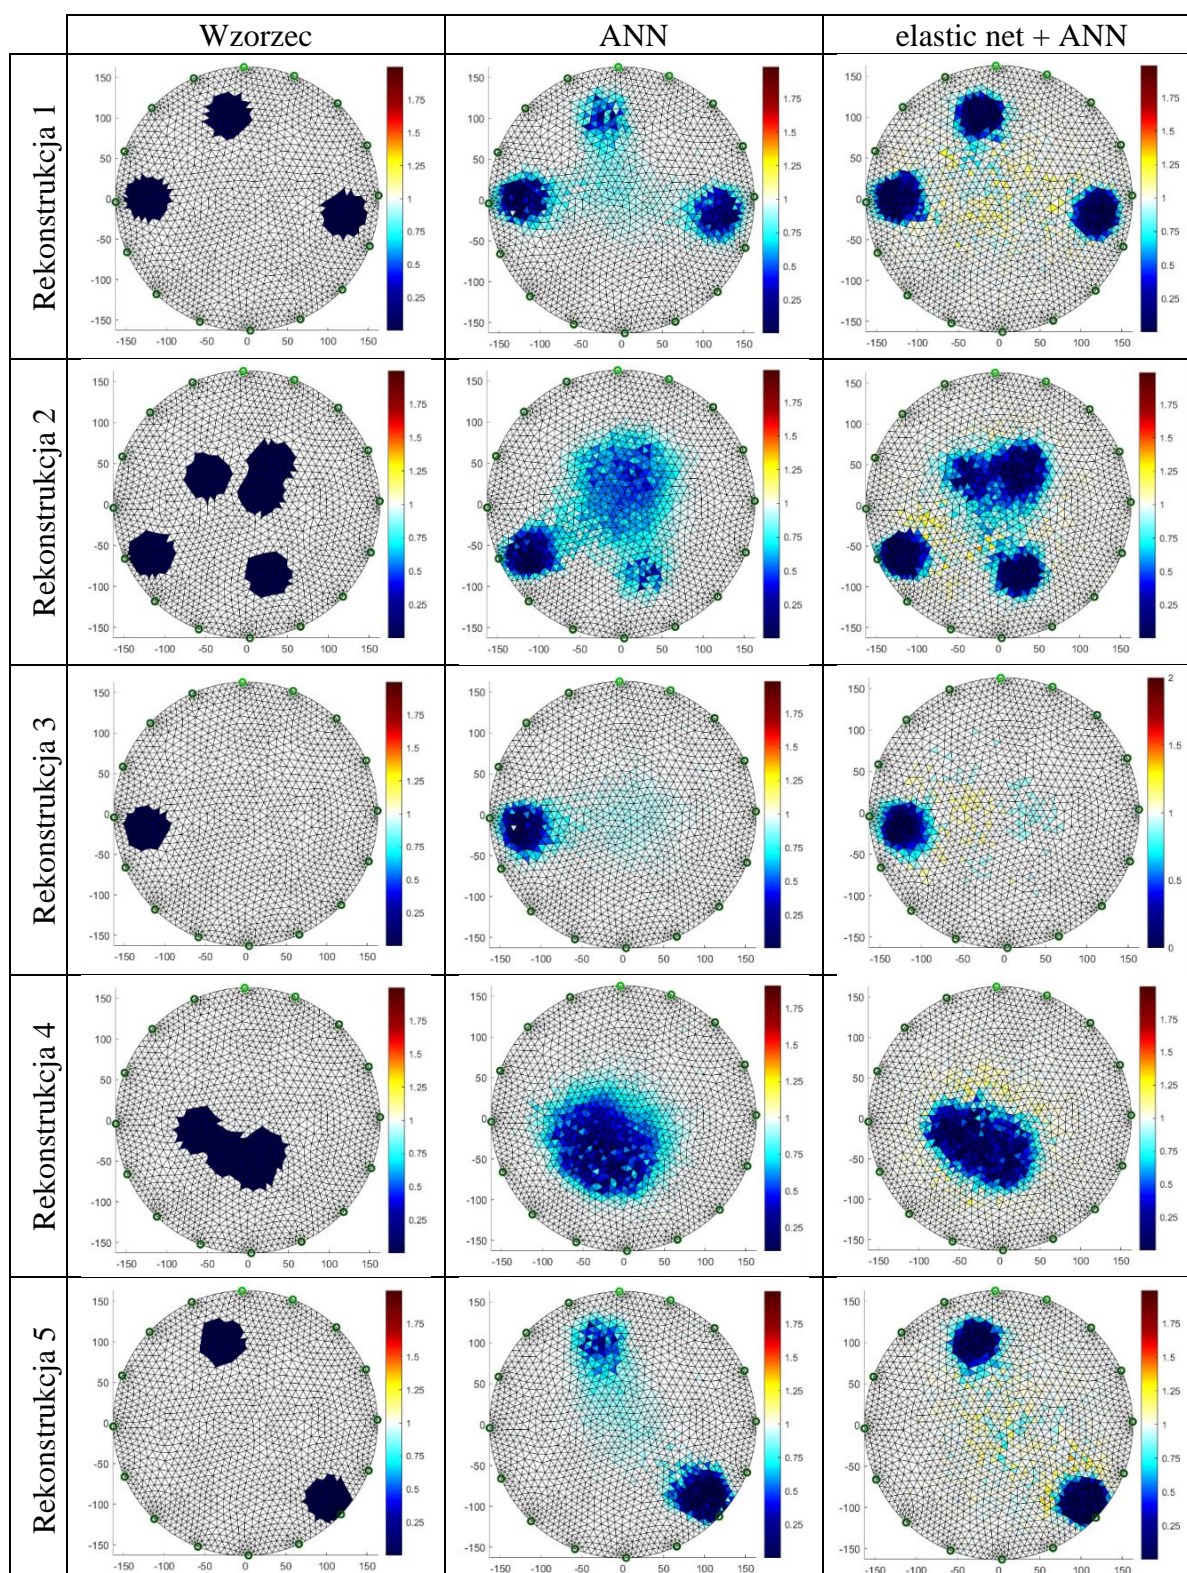
Rys. 7. Dobór parametru Lambda w metodzie elastic net z  $\alpha=0.25$  w oparciu o minimalny błąd średniokwadratowy (MSE)

Rysunek 7 przedstawia proces doboru parametru  $\lambda$  (lambda) w metodzie elastic net z przyjętym  $\alpha = 0.25$  dla jednego z punktów obrazu wyjściowego. Dwie wartości Lambdy oznaczone są zieloną i niebieską linią przerywaną. Linia zielona wskazuje wartość Lambda z minimalnym błędem średniokwadratowym (MSE) uzyskaną przy wykorzystaniu sprawdzianu krzyżowego (krosvalidacji). Wartość ta została oznaczona zmienną LambdaMinMSE. Niebieska linia przerywana wskazuje największą wartość Lambda, która mieści się w granicach odchylenia standardowego minimalnego MSE (Lambda1SE). Taka wartość Lambda sprawia, że nawet najgorszy z testowanych modeli (z największym MSE) ma wciąż relatywnie niską wartość błędu. W opisywanym przypadku przyjęto  $\lambda = 0.129$  dla  $MSE=0.0154$ . Wektor pomiarowy liczy 96 wartości spadków napięć. W prezentowanym przypadku, dzięki zastosowaniu elastic net zredukowano wektor wejściowy z 96 do 30 pomiarów.

### 3. Rezultaty

Na Rys. 8 przedstawiono porównanie obrazów tomograficznych uzyskanych dwoma metodami: ANN oraz metodą hybrydową, łączącą elastic net z ANN. W pierwszej kolumnie umieszczono obrazy wzorcowe dla pięciu testowanych przypadków. Stanowisko badawcze zostało wyskalowane w taki sposób, że wartość na wyjściu, odpowiadająca konduktancji cieczy referencyjnej (wody) wynosi 1. Z kolei wartość punktów obrazu odpowiadająca artefaktom wynosi 0. Następnie, wykorzystując model fizyczny dokonano pomiarów rzeczywistych metodami ANN oraz elastic net + ANN (algorytm hybrydowy).

Porównując obrazy uzyskane dwoma metodami, można zauważyć, że w podejściu hybrydowym, pomimo zredukowania wektora pomiarów wejściowych o prawie 70% dla każdej sieci neuronowej, wizualna jakość rekonstrukcji nie ustępuje czystej ANN. Należy także zauważyć, że algorytm najgorzej rekonstruuje artefakty zlokalizowane w pobliżu środka reaktora. Ma to najprawdopodobniej związek z odległością punktów siatki obrazu od elektrod. Lepsze rekonstrukcje uzyskiwane są dla artefaktów położonych bliżej elektrod.



Rys. 8. Porównanie obrazów rekonstrukcyjnych dla metod ANN i „elastic net + ANN”

Wizualna ocena rekonstrukcji jest mało precyzyjna i niewystarczająca do obiektywnego porównania dwóch analizowanych metod. W tym celu wprowadzono 3 ilościowe mierniki jakości obrazowania: MSE (Mean Squared Error), RIE (Relative Image Error), ICC (Image Correlation Coefficient).





Jak wynika z Tabeli 2, we wszystkich 18 przypadkach, łącznie z odpowiedziami obejmującymi wartości średnie, lepszą okazała się metoda hybrydowa „elastic net + ANN”.

#### 4. Dyskusja i konkluzje

W pracy przedstawiono wyniki badań nad opracowaniem ulepszanego algorytmu rekonstrukcji obrazów z zakresu tomografii procesowej. W szczególności, skoncentrowano się na obrazowaniu wnętrza modelu zbiornikowych reaktorów przemysłowych, w których zachodzą procesy krystalizacji i fermentacji beztlenowej w biogazowniach. Aby dokonać obiektywnej oceny jakości działania algorytmu hybrydowego (elastic net + ANN), przeprowadzono badania porównawcze wykorzystując fizyczny model laboratoryjny. Przygotowano jednakowe przypadki układów artefaktów, a następnie dokonano pomiarów spadków napięć odczytanych z układu elektrod. Z uwagi na to, że podczas odczytu danych wiele stanów prądowo-napięciowych jest nieustalonych, dane zawierały pewien poziom zaszumienia. Po przefiltrowaniu danych przy użyciu wartości referencyjnych tła (reaktora bez artefaktów) uzyskano rezultaty, które zostały zobrazowane i przeliczone na wskaźniki jakości: MSE, RIE i ICC.

Najprawdopodobniej, gdyby dane pomiarowe użyte do obrazowania były wygenerowane symulacyjnie i nie zawierały zakłóceń, usunięcie 70% predyktorów (np. redukcja z 96 do 30) spowodowałoby pogorszenie jakości obrazów. Przeprowadzone eksperymenty wykazały, że inaczej stało się w przypadku danych obarczonych pewnym poziomem zaszumienia. Choć uzyskane rekonstrukcje, zarówno dla czystej ANN jak i dla metody hybrydowej, wciąż nie są idealne, to jednak są wystarczająco dokładne aby określić ilość, kształt i lokalizację artefaktów. Czas uzyskiwania rekonstrukcji we wszystkich badanych przypadkach na maszynie z procesorem Intel i7 nie przekroczył 1 sekundy. Oznacza to, że opracowany algorytm może być stosowany także w procesach o dużej dynamice reakcji, a nawet w układach przepływowych [24].

Znamienne jest, że w Tabeli 2, we wszystkich testowanych przypadkach i dla wszystkich trzech wskaźników jakości, lepsze rezultaty otrzymano przy wykorzystaniu algorytmu „elastic net + ANN”, a nie czystej ANN. Okazuje się, że zastosowanie elastic net spowodowało, że wraz z usunięciem 70% zmiennych niezależnych, usunięto także wiele danych zaszumionych, generujących różnego rodzaju zaburzenia obrazu wyjściowego. Fakt ten jest dowodem na to, że nowo opracowany algorytm hybrydowy „oczyszcza” dane i uodparnia układ tomograficzny na różnego rodzaju zakłócenia i zaszumienie danych.

Rezultaty badań udowodniły, że zastosowanie opisywanego rozwiązania umożliwia uzyskanie wyższej rozdzielczości obrazów kryształów lub pęcherzy gazowych pojawiających się wewnątrz reaktora, co zasadniczo przyczynia się do wczesnego wykrycia zagrożeń i ułatwia rozwiązywanie problemów eksploatacyjnych systemów przemysłowych.

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

#### Literatura

1. Babout L, Grudzień K, Wiącek J, Niedostatkiwicz M, Karpiński B, Szkodo M. Selection of Material for X-Ray Tomography Analysis and DEM Simulations: Comparison between Granular Materials of Biological and Non-Biological Origins. *Granular Matter* 2018; 20 (3): 38.

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. Dusek J, Hladky D, Mikulka J. Electrical Impedance Tomography Methods and Algorithms Processed with a GPU. *Progress In Electromagnetics Research Symposium - Spring (PIERS)* 2017; 1710–14.
4. Garbaa H, Jackowska-Strumiłło L, Grudzień K, Romanowski A. Application of Electrical Capacitance Tomography and Artificial Neural Networks to Rapid Estimation of Cylindrical Shape Parameters of Industrial Flow Structure. *Archives of Electrical Engineering* 2016; 65 (4): 657–69.
5. Grudzien, Krzysztof, Zbigniew Chaniecki, Andrzej Romanowski, Dominik Sankowski, Jacek Nowakowski, and Maciej Niedostatkiwicz. Application of Twin-Plane ECT Sensor for Identification of the Internal Imperfections inside Concrete Beams. *IEEE International Instrumentation and Measurement Technology Conference Proceedings* 2016; May, 1–6.
6. Kłosowski G, Gola A, Świć A. Application of Fuzzy Logic Controller for Machine Load Balancing in Discrete Manufacturing System. In *International Conference on Intelligent Data Engineering and Automated Learning* 2015; 256–63.
7. Kłosowski G, Rymarczyk T, Gola A. Increasing the Reliability of Flood Embankments with Neural Imaging Method. *Applied Sciences* 2018; 8 (9): 1457.
8. Kłosowski G, Rymarczyk T. Using neural networks and deep learning algorithms in electrical impedance tomography. *Informatyka Automatyka Pomiary w Gospodarce i Ochronie Środowiska* 2017; 7 (3): 99–102.
9. Korzeniewska E, Gałązka-Czarnecka I, Czarnecki A, Piekarska A, Krawczyk A. Influence of PEF on Antocyanins in Wine. *Przegląd Elektrotechniczny* 2018; 1 (1): 59–62.
10. Korzeniewska E., Walczak M., Rymaszewski J., Elements of Elastic Electronics Created on Textile Substrate, *Proceedings of the 24th International Conference Mixed Design of Integrated Circuits and Systems - MIXDES* 2017; 2017, 447-45.
11. Kosicka E, Kozłowski E, Mazurkiewicz D. Intelligent Systems of Forecasting the Failure of Machinery Park and Supporting Fulfilment of Orders of Spare Parts. In: Burduk A., Mazurkiewicz D. (eds) *Intelligent Systems in Production Engineering and Maintenance – ISPEM 2017*. *ISPEM 2017. Advances in Intelligent Systems and Computing*, vol 637. Springer, Cham, 2018.
12. Kozłowski E., Mazurkiewicz D., Kowalska B., Kowalski, D. Binary Linear Programming as a Decision-Making Aid for Water Intake Operators. In: Burduk A., Mazurkiewicz D. (eds) *Intelligent Systems in Production Engineering and Maintenance – ISPEM 2017*. *ISPEM 2017. Advances in Intelligent Systems and Computing*, vol 637. Springer, Cham, 2018.

13. Kryszyn J, Smolik W T, Radzik B, Olszewski T, Szabatin R. Switchless Charge-Discharge Circuit for Electrical Capacitance Tomography. *Measurement Science and Technology* 2014; 25 (11): 115009.
14. Kryszyn J, Waldemar S. Toolbox for 3d Modelling and Image Reconstruction in Electrical Capacitance Tomography. *Informatics Control Measurement in Economy and Environment Protection* 2017; 7 (1).
15. Lopato P, Tomasz C, Sikora R, Gratkowski S, Ziolkowski M. Full Wave Numerical Modelling of Terahertz Systems for Nondestructive Evaluation of Dielectric Structures. *COMPEL - The International Journal for Computation and Mathematics in Electrical and Electronic Engineering* 2013; 32 (3): 736–49.
16. Majchrowicz M, Kapusta P, Jackowska-Strumiłło L, Sankowski D. Acceleration of image reconstruction process in the electrical capacitance tomography 3d in heterogeneous, multi-GPU system. *Informatics Control Measurement in Economy and Environment Protection* 2017; 7 (1): 37–41.
17. Mikulka J. Accelerated Reconstruction of T2 Maps in Magnetic Resonance Imaging. *Measurement Science Review* 2015; 4: 210–18.
18. Park S, Na J, Kim M, Lee J M. Multi-Objective Bayesian Optimization of Chemical Reactor Design Using Computational Fluid Dynamics. *Computers & Chemical Engineering* 2018; 119 : 25–37.
19. Psuj G. Multi-Sensor Data Integration Using Deep Learning for Characterization of Defects in Steel Elements. *Sensors* 18 (2): 292.
20. Romanowski, Andrzej. 2018. Big Data-Driven Contextual Processing Methods for Electrical Capacitance Tomography. *IEEE Transactions on Industrial Informatics* 2018; 1–1.
21. Rymarczyk T, Adamkiewicz P, Polakowski K, Sikora J. Effective Ultrasound and Radio Tomography Imaging Algorithm for Two-Dimensional Problems. *Przegląd Elektrotechniczny* 2018; 94 (6): 62–69.
22. Rymarczyk T, Kłosowski G, Kozłowski E. A Non-Destructive System Based on Electrical Tomography and Machine Learning to Analyze the Moisture of Buildings. *Sensors* 2018; Vol. 18, Page 2285 18 (7): 2285.
23. Rymarczyk T, Kłosowski G. Application of Neural Reconstruction of Tomographic Images in the Problem of Reliability of Flood Protection Facilities. *Eksploatacja i Niezawodność - Maintenance and Reliability* 2018; 20 (3): 425–34.
24. Rymarczyk T, Sikora J. Applying Industrial Tomography to Control and Optimization Flow Systems. *Open Physics* 2018; 16 (1): 332–45.



25. Sobaszek Ł, Gola A, Świć A. Predictive Scheduling as a Part of Intelligent Job Scheduling System: in, 358–67. Springer, Cham 2018;
26. Soleimani M, Mitchell C N, Banasiak R, Wajman R, Adler A. Four-dimensional electrical capacitance tomography imaging using experimental data. *Progress In Electromagnetics Research* 2009; 90: 171–86.
27. Tian G, Yang B, Dong M, Zhu R, Yin F, Zhao X, Wang Y, Xiao W, Wang Q, Zhang W. The Effect of Temperature on the Microbial Communities of Peak Biogas Production in Batch Biogas Reactors. *Renewable Energy* 2018; 123: 15–25.
28. Voutilainen A, Lehtikoinen A, Vauhkonen M, Kaipio J P. Three-Dimensional Nonstationary Electrical Impedance Tomography with a Single Electrode Layer. *Measurement Science and Technology* 2010; 21 (3): 035107.
29. Wang Mi. *Industrial Tomography: Systems and Applications*. Edited by Elsevier Ltd. Woodhead Publishing 2015.
30. Ziolkowski M, Gratkowski S, Zywicka A R. Analytical and Numerical Models of the Magnetoacoustic Tomography with Magnetic Induction. *COMPEL - The International Journal for Computation and Mathematics in Electrical and Electronic Engineering* 2018; 37 (2): 538–48.