

**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:

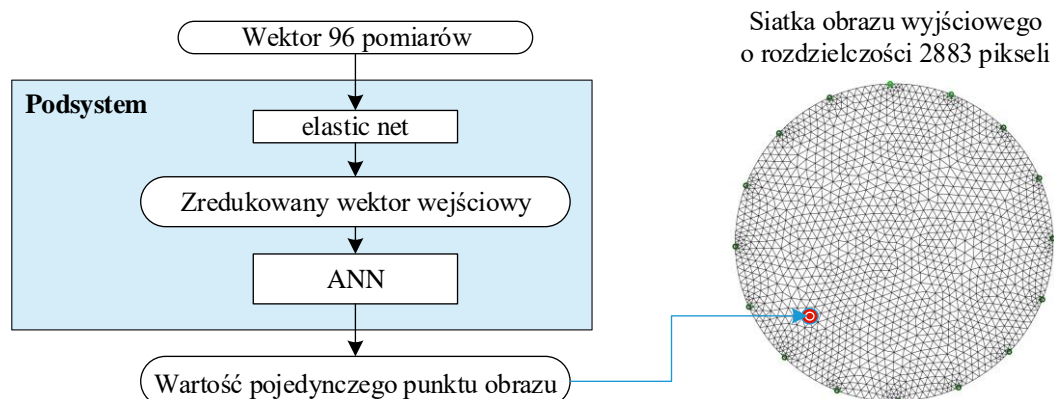
a) pierwszy cykl pomiarowy, b) kolejny cykl pomiarowy

## 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:

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

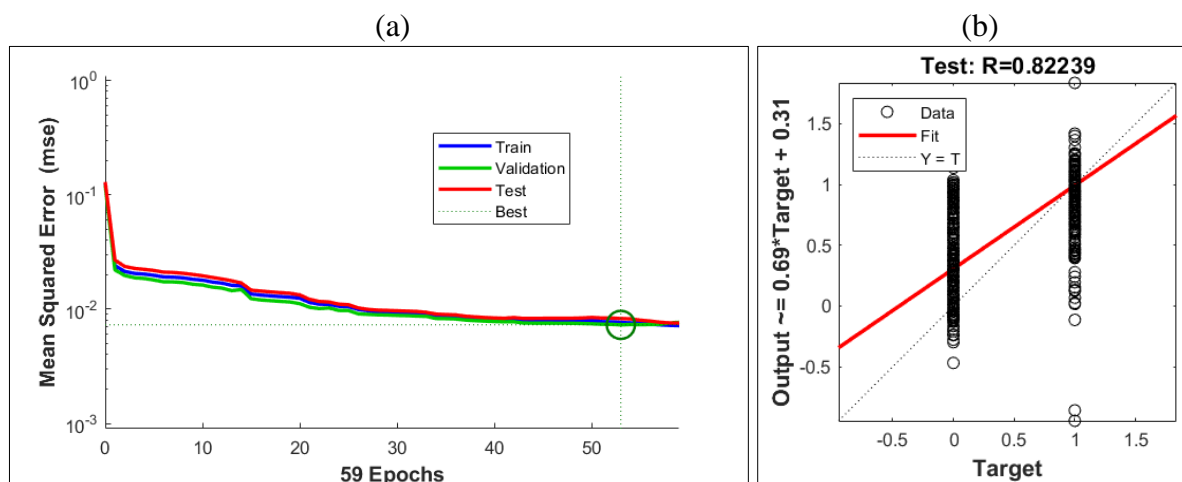
gdzie:  $n$  – rozdzielczość obrazu;  $y'_i$  – wartość referencyjna  $i$ -tego piksela;  $y^*_i$  – wartość rekonstrukcyjna  $i$ -tego piksela.

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 nieznanych 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)

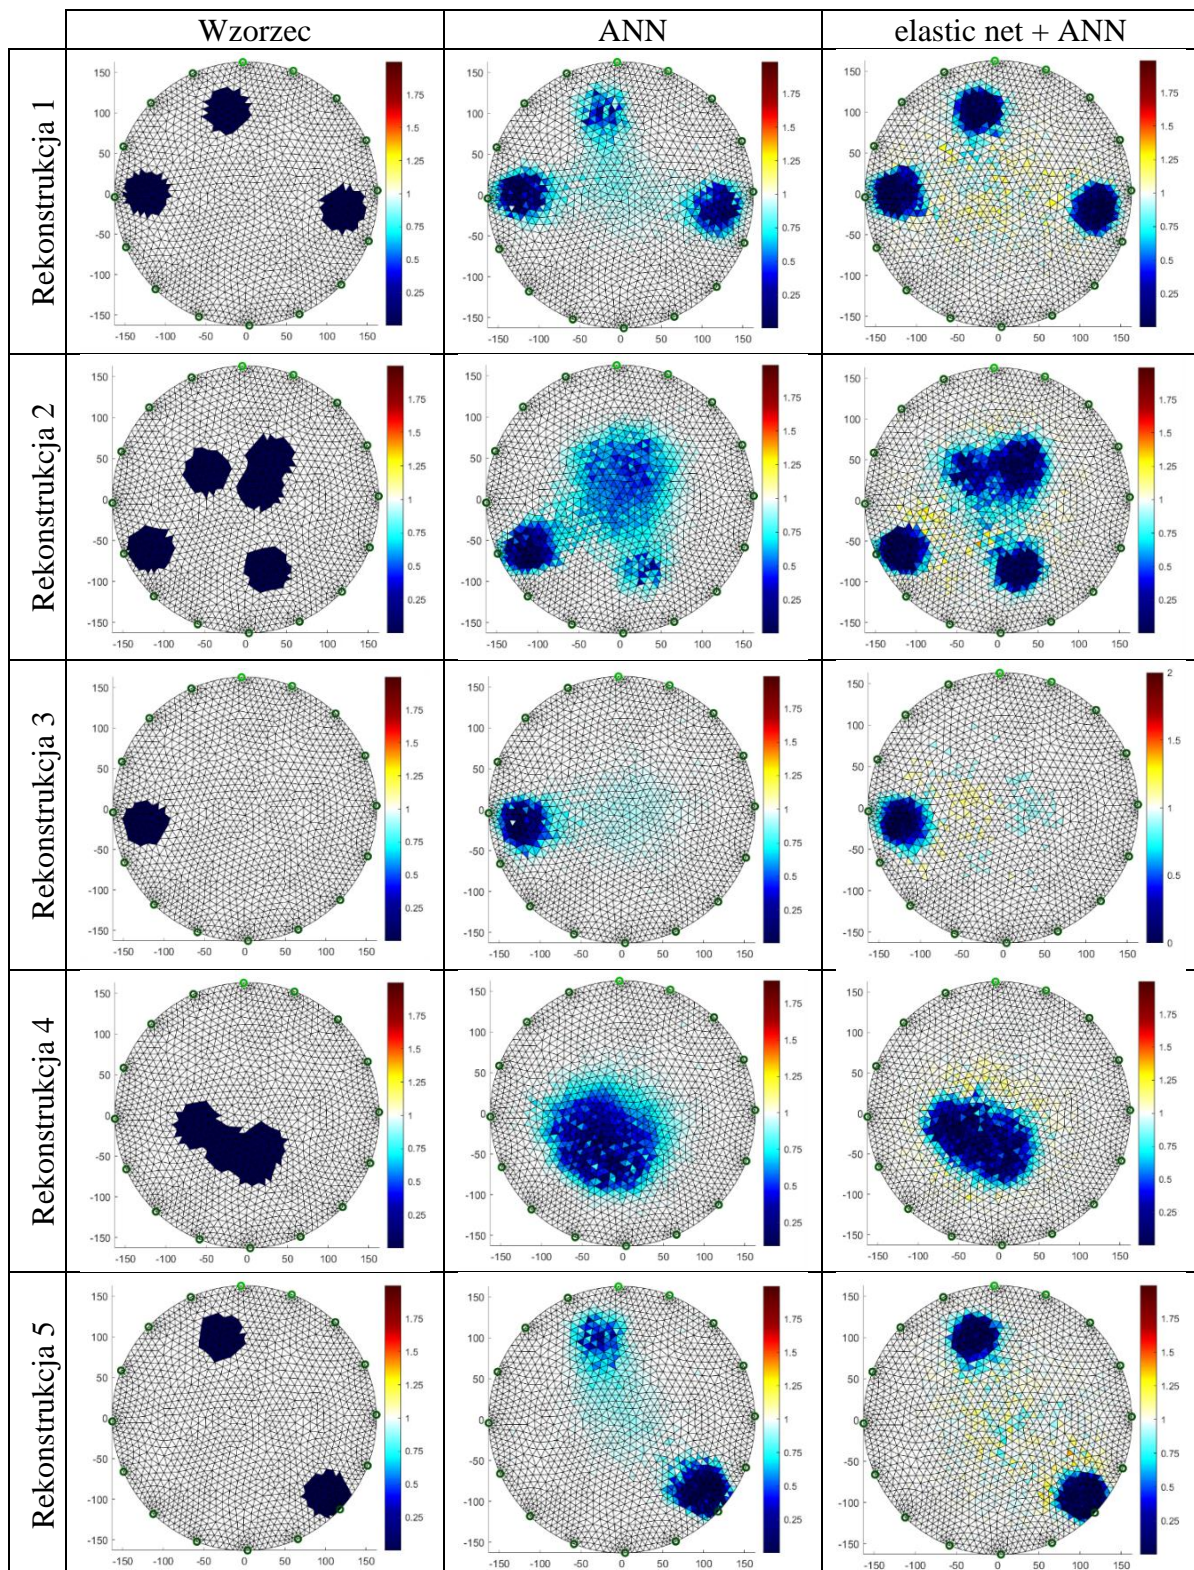
Rysunek 7 przedstawia proces doboru parametru  $\lambda$  (lambda) w metodzie elastic net z przyjętym  $\alpha = 0.25$  dla jednego z punktów obrazu wyjściowego. Dwie wartości Lambdy oznaczone są zieloną i niebieską linią przerywaną. Linia zielona wskazuje wartość Lambda z minimalnym błędem średniokwadratowym (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 obciążonych 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, Zywicki 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.