



Politechnika Łódźka,
Wydział Elektrotechniki, Elektroniki,
Informatyki i Automatyki
Instytut Informatyki Stosowanej



ROZPRAWA DOKTORSKA
streszczenie

**Estymacja parametrów przepływu grawitacyjnego
materiałów sypkich z zastosowaniem
elektrycznej tomografii pojemnościowej
i sztucznych sieci neuronowych**

Hela GARBAA

Promotor:

Prof. dr hab. inż. Lidia Jackowska-Strumiłło

Promotor pomocniczy:

Dr inż. Andrzej Romanowski

Łódź, 2016

1. WSTĘP

Pomiar i monitorowanie grawitacyjnego przepływu materiałów sypkich w silosach jest istotny w wielu zastosowaniach przemysłowych, na przykład w przemyśle chemicznym, spożywczym, farmaceutycznym czy w budownictwie. Docelowo, kluczowe parametry przepływu powinny być monitorowane na bieżąco, aby zapobiec ewentualnym niepożądanym zjawiskom. Odpowiednie monitorowanie zachowania granulatu pozwala na uniknięcie problemów występujących podczas procesu opróżniania silosu (Niedostatkiwicz i inni, 2009), (Chaniecki i inni, 2006), (Grudzień i inni, 2010).

Zachowanie struktur granulatu i zmian objętości sypkich materiałów stałych zależy jest od początkowej gęstości upakowania, poziomu naprężeń wewnętrznych, średniej średnicy ziaren, wielkości próbki i kierunku oraz szybkości propagacji odkształcenia. Monitorowanie stanu procesu *online*, szczególnie wtedy, gdy czynniki zewnętrzne wpływające na proces (wilgotność, temperatura) zmieniają się w jego trakcie, wymaga gruntownej wiedzy i zrozumienia zjawisk fizycznych zachodzących podczas przepływu grawitacyjnego materiału sypkiego. Wizualizacja rozkładu materiału w silosie wydaje się być najlepszą opcją dla zrozumienia i monitorowania przepływu. Bardzo pomocne są tutaj systemy tomograficzne, które pozwalają na wgląd do wnętrza procesu w postaci obrazu, a następnie określenie ważnych parametrów procesu bez konieczności ingerencji w sam przepływ.

Elektryczną tomografię pojemnościową (z ang. *Electrical Capacitance Tomography* - ECT) uznano za najbardziej odpowiednią technikę wizualizacji dla procesów z wykorzystaniem substancji sypkich i granulatów. Zaletami tej techniki jest to, że jest ona nieinwazyjnym i nieniszczącym narzędziem stosowanym do pomiaru i monitorowania procesów w niebezpiecznych lub niedostępnych obszarach (wysoka temperatura, wysokie ciśnienie), oraz fakt, że jest tania w porównaniu z innymi narzędziami tomograficznymi, a ponadto charakteryzuje się szybkim czasem reakcji. Natomiast ograniczeniem tej techniki jest niska rozdzielczość uzyskanego obrazu (Zhang i inni, 2014), (Tapp i inni, 2003), (Abdul Wahab i inni, 2015).

Celem niniejszej rozprawy doktorskiej było opracowanie nowych metod i algorytmów, które pozwoliłyby na bieżące monitorowanie grawitacyjnego przepływu materiałów stałych przy zwiększeniu ich szybkości w stosunku do obecnie istniejących metod. Nowe podejście powinno być także dostatecznie dokładne do rozwiązania powyższego zadania.

Proces modelowania i identyfikacji rozważano w celu przewidywania wahań charakterystycznych parametrów procesu.

Zaproponowane w ramach niniejszej pracy badawczej podejście oparte jest na Sztucznych Sieciach Neuronowych (z ang. *Artificial Neural Network* – SNN) jako uniwersalnych aproksymatorach i odpowiednich narzędziach do rozwiązywania problemów nieliniowych (Haykin, 1999).

Tezę niniejszej rozprawy doktorskiej sformułowano w następujący sposób:

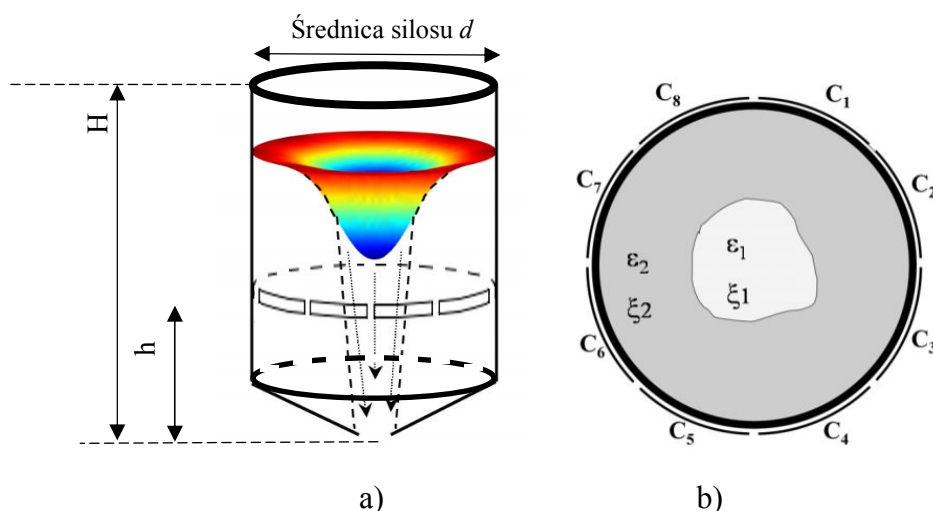
Estymacja parametrów komina dla procesu przepływu grawitacyjnego materiałów sypkich z zastosowaniem sztucznych sieci neuronowych jest szybsza od znanych z literatury metod monitorowania stosowanych w elektrycznej tomografii pojemnościowej w czasie rzeczywistym i na tym samym poziomie dokładności.

Aby dowieść niniejszej tezy, projekt pracy doktorskiej wymagał zrealizowania następujących zadań:

- 1) Zaprojektowania modelu procesu i doboru jego istotnych parametrów,
- 2) Zaproponowania modelu i zaprojektowania algorytmu do oceny parametrów oraz wybrania odpowiednich narzędzi (SNN),
- 3) Przygotowania danych do uczenia SNN, które są wystarczająco dokładne do zbudowania odpowiedniego modelu opartego na SNN,
- 4) Budowy i przetestowania modeli SNN, które rozwiążą problem odwrotny i pozwolą na ocenę istotnych parametrów,
- 5) Przygotowania fizycznego modelu i przeprowadzenia doświadczeń w laboratorium TOMOKIS dla zaproponowanej metody i weryfikacji modeli,
- 6) Zaprojektowania, implementacji i przetestowania algorytmów do przewidywania wybranych parametrów procesu na podstawie pomiarów wykonanych dla grawitacyjnego przepływu kominowego materiałów sypkich.

2. Koncepcja

Zachowanie materiału podczas procesu opróżniania silosu zależy od właściwości granulek oraz od konstrukcji silosu [(Romanowski, Grudzień and Williams, 2006), (Grudzień i inni, 2006)]. Rozróżnia się dwa główne typy przepływu: przepływ masowy, w którym materiał porusza się z tą samą prędkością w całym przekroju poprzecznym silosu i przepływ kominowy, gdzie materiał porusza się tylko w środkowej części przekroju poprzecznego (Romanowski, Grudzień i Williams, 2006). W obu sytuacjach mogą występować niepożądane zjawiska. Przedstawione podejście dotyczy przepływu kominowego. Dla tego typu opróżniania silosu najbardziej niepożądanymi zjawiskami są wysklepianie/zawieszanie się materiału (zablokowany komin – zatrzymanie procesu opróżniania), tworzenie się martwego otworu w środku silosa (z ang. *rat holing* – pusty lej – zatrzymanie procesu opróżniania). W celu uniknięcia takich sytuacji, obszar komina powinien być monitorowany. Ruch materiału w środkowej części przekroju poprzecznego pojemnika charakteryzuje się mniejszym upakowaniem materiału niż w jego innych obszarach (Rys. 1). Obszar ten nazywany jest przepływem kominowym i charakteryzuje się zmianami kształtu i wielkości w trakcie opróżniania silosu.



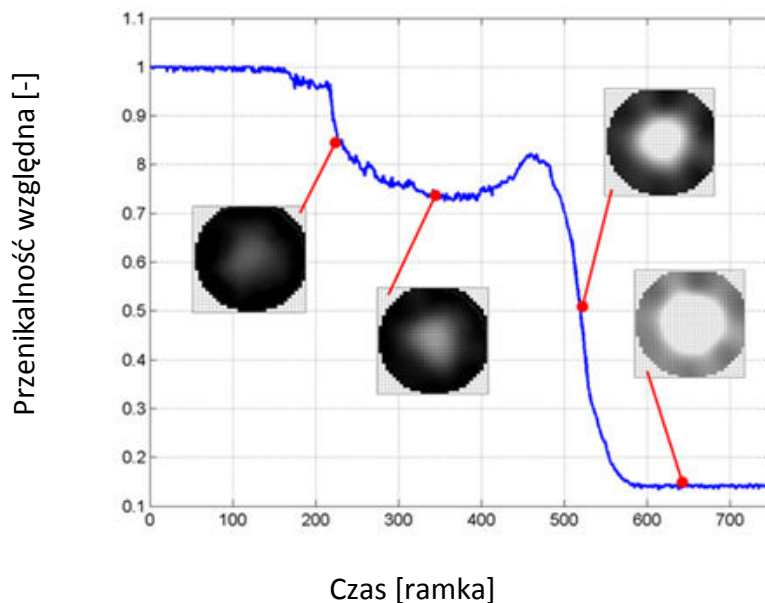
Rys. 1 Geometryczny model silosu, a) uproszczony diagram opróżniania silosu – przepływ kominowy, (Grudzień i inni, 2006), b) Geometryczne modelowanie opróżnianego zbiornika w przekroju poprzecznym. Zestaw ocenianych parametrów $\eta = \{\xi_1, \varepsilon_1, \xi_2, \varepsilon_2\}$, (Romanowski, Grudzień i Williams, 2006); gdzie: H – wysokość silosu, h – wysokość umieszczenia czujnika ECT nad wylotem silosu.

W celu stworzenia modelu przepływu w silosie, wyróżnia się dwa oddzielne regiony w przekroju poprzecznym podczas opróżniania pojemnika: komin w środku i pozostały

obszar w pobliżu ściany. Pierwszy region odpowiada przesuwającemu się materiałowi, czyli kominowi przepływu, natomiast drugi odpowiada strefie stagnacji materiału. Ocenianymi parametrami były: wielkość komina ξ_1 , przenikalność elektryczna w obszarze komina ε_1 , oraz wielkość ξ_2 i przenikalność elektryczna ε_2 drugiego obszaru.

Kształt komina aproksymowano za pomocą koła, a jego wielkość oceniono na podstawie obszaru należącego do mniejszej przenikalności ε_1 w środku przekroju poprzecznego silosu. Ta forma modelowania może również pozwolić na bezpośrednią ocenę parametrów procesu i uczynić proces monitorowania bardziej efektywnym.

Zestaw parametrów takich jak koncentracja materiału sypkiego, która odpowiada przenikalności w strefie komina i wielkości obszaru komina charakteryzują dynamikę przepływu zbiornika samowyladowczego (Grudzień i inni, 2006). Informacja ta potwierdza poprawny/niepoprawny przepływ w opróżnianym zbiorniku. Typową charakterystykę zmian koncentracji materiału podczas procesu opróżniania silosu w przypadku przepływu kominowego przedstawiono na Rys. 2.



Rys. 2 Zmiany w rozkładzie koncentracji materiału (rozkład przenikalności elektrycznej) wewnątrz czujnika (Grudzień i inni, 2006)

Rozkład przenikalności znormalizowano między $\langle 0$ i $1 \rangle$. Charakterystykę przygotowano na podstawie pomiaru zmian danych (zmian pojemności) przyjętych jako średnia dla każdego punktu w czasie, dla przeciwnych par elektrod. Przedstawiony przykład sekwencji zrekonstruowanych obrazów umieszczonych na wykresie charakterystyk przepływu w silosie

pokazuje koncentrację materiału (poprzez odpowiadający jej rozkład przenikalności elektrycznej wewnątrz czujnika). Zmiany zmierzonych pojemności związane są z pojawieniem się komina w środkowej części obszaru poprzecznego zbiornika, a te odpowiadają zmniejszonej koncentracji materiału w tej części. W rozważanym przypadku, najważniejszy zakres czasowy procesu opróżniania silosu, z punktu widzenia sterowania procesem, wynosi od 200 do 500 klatek. Zatem, monitorowanie wielkości komina jest najważniejszym elementem w zapobieganiu niedrożnościom, zatrzymaniom i niebezpiecznym wypadkom.

Klasyczne podejścia rozwiązują zagadnienie odwrotne poprzez rekonstrukcję pikseli w obrazie przepływu. Potrzebny jest odpowiedni algorytm przetwarzania obrazu w celu interpretacji otrzymanego obrazu i uzyskanie przydatnej informacji (Rys.3.a) takiej jak parametry przepływu w procesie monitorowania, np. wielkości obszaru komina przepływu, koncentracji materiału w obszarze komina i położenia komina.

W większości przypadków zagadnienia odwrotne związane są z niewłaściwie postawionymi problemami, ponieważ liczba dostępnych obserwacji lub pomiarów potrzebnych do rozwiązania danego zadania jest ograniczona lub też rozwiązanie charakteryzuje się niestabilnością (Kabanikhin, 2008). Metody oparte na SNN znane są jako odpowiednie narzędzia w modelowaniu systemów nieliniowych. Stosowane były do rozwiązania problemów odwrotnych i odwzorowania złożonych nieliniowych związków w zbiorze danych.

Jedną z klas takich problemów jest identyfikacja małych cylindrycznych inkluzji w materiale. Zagadnienia odwrotne kształtu są zwykle trudne do rozwiązania na drodze analitycznej, a metody numeryczne są złożone i czasochłonne. Jackowska-Strumiłło i inni (2002) zaproponowali zastosowanie SNN typu MLP do identyfikacji inkluzji, tj. otworów cylindrycznych w kwadratowej płytce.


SNN zostały też pomyślnie zastosowane do rekonstrukcji obrazów w Tomografii Impedancyjnej (EIT- z ang. *Electrical Impedance Tomography*) [(Ratajewicz-Mikołajczak i inni, 1998), (Ratajewicz-Mikołajczak i Sikora, 2002), oraz (Stasiak i inni, 2007)].

Sztuczne Sieci Neuronowe stosowane są zarówno do rozwiązywania problemu prostego jak i zagadnienia odwrotnego w ECT, ponieważ stanowią one efektywne narzędzie przydatne do zajmowania się złożonymi i nieliniowymi obliczeniami. Typy stosowanych sieci neuronowych różnią się w zależności od celu badań.


W porównaniu do iteracyjnych technik rekonstrukcji obrazów ECT, algorytmy oparte na

SNN są szybkie, jednak dla pełnej rekonstrukcji obrazu, należy zastosować sieć neuronową o bardzo dużym rozmiarze lub dużą liczbę mniejszych sieci. Dokładne algorytmy rekonstrukcji obrazu są obarczone dużą złożonością obliczeniową i nie są odpowiednie dla długoterminowego monitorowania dynamicznie zmieniających się procesów w czasie rzeczywistym.

W niniejszej pracy docelową informację uzyskuje się w sposób bezpośredni, jak pokazano na schemacie ideowym na Rys.3.b. Sztuczna sieć neuronowa wyznacza bezpośrednio parametry komina przepływu, kiedy znane są pomiary pojemności wprowadzane do warstwy wejściowej SSN.



a) istniejące metody oparte na przetwarzaniu i rekonstrukcji obrazu



b) proponowana metoda oparta na Sztucznych Sieciach Neuronowych


Rys. 3 Różne podejścia do określania parametrów przepływu z danych pojemnościowych:
 (a) istniejące metody oparte na przetwarzaniu i rekonstrukcji obrazu,
 (b) proponowana metoda oparta na Sztucznych Sieciach Neuronowych.

3. Symulacje

Dane do uczenia SNN przygotowano na drodze symulacji komputerowych. Symulacje przeprowadzono przy użyciu zestawu narzędzi Matlab i ECTSIM toolbox, [(Smolik i Radomski, 2008), (Ectsim.ire.pw.edu.pl, 2012)]. ECTSIM toolbox został zaprojektowany do badania istniejących algorytmów rekonstrukcji obrazu stosowanych w dziedzinie ECT, takich jak algorytmy: Landwebera, Levenberga-Marquardta (LM), czy też metody liniowej projekcji wstecznej (LBP). ECTSIM toolbox wykorzystywano tylko do generowania pojemności na wyjściu czujnika.

Wykonane symulacje można opisać w 2 głównych krokach: (1) modelowanie czujnika

elektro-pojemnościowego i generowanie pojemności przy użyciu ECTSIM toolbox, (2) estymacja parametrów przepływu za pomocą Sztucznej Sieci Neuronowej: SSN typu perceptron wielowarstwowy (MLP), która została zastosowana do estymacji różnych parametrów przepływu dla kilku rozważanych zadań (Rys.4).



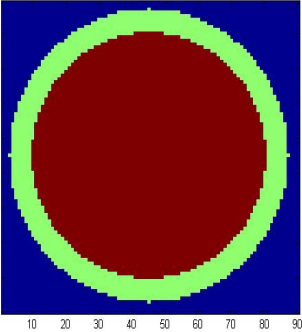
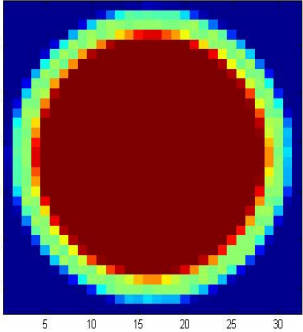
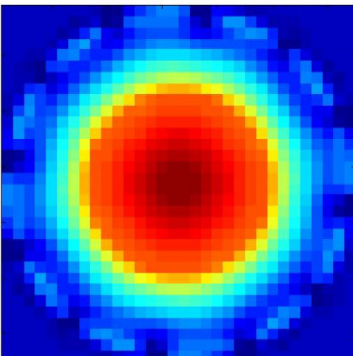
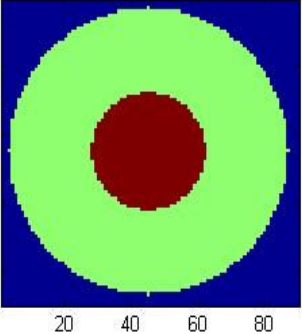
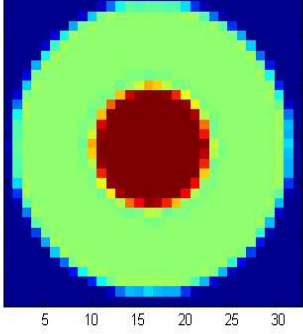
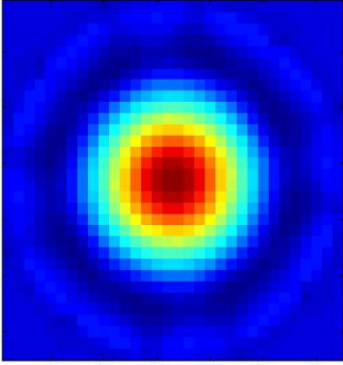
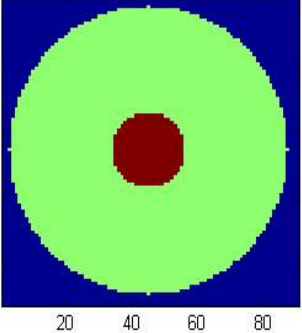
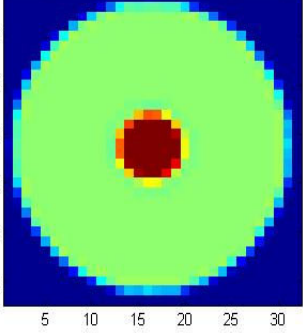
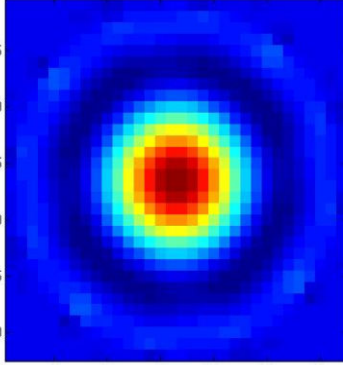
Rys. 4 Symulacja zagadnienia prostego i odwrotnego

Zaproponowano uproszczony model geometrii grawitacyjnego przepływu ciał stałych – materiałów sypkich i dobrano istotne parametry przepływu potrzebne w procesie monitorowania, takie jak obszar przepływu kominowego, koncentracja materiału w kominie i położenie komina. Kształt przekroju poprzecznego komina modelowano kołem. Wykonano dużą liczbę symulacji w celu wygenerowania danych dla uczenia i testowania SNN oraz do oceny działania SNN. Zaproponowana metoda z zastosowaniem SNN przeznaczona jest do rozwiązywania problemu odwrotnego w ECT i oceny parametrów przepływu cylindrycznego na podstawie nieprzetworzonych danych uzyskanych bezpośrednio z tomografu pojemnościowego.

4. Estymacja parametrów przepływu

W pierwszej kolejności estymowano promień rozważanego obiektu cylindrycznego (komina). Otrzymane wyniki dla czujnika ECT z 12 elektrodami były obiecujące przy zastosowaniu prostej struktury MPL (66-10-1), tj. 66 wejść, 10 neuronów w warstwie ukrytej i jedno wyjście. Do uczenia SSN zastosowano algorytm wstecznej propagacji błędów. Podejście oparte na SNN pozwoliło na rozwiązanie problemu odwrotnego w czasie krótszym, w przybliżeniu 120 razy, w porównaniu z iteracyjnym algorytmem Levenberga-Marquardta (LM) (patrz Tabela 1).

Tabela 1 Obrazy zrekonstruowane przy zastosowaniu MLP i algorytmu Levenberga-Marquardta

Dany fantom/ Rozkład	Obraz zrekonstruowany przy zastosowaniu MLP	Obraz zrekonstruowany metodą Levenberga-Marquardta
<p>object radius (R) = 35.25mm FOV= 42mm</p> 	<p>estimated object radius (Re) = 35.325mm FOV= 42mm</p> 	
	<p>czas rekonstrukcji (s) 0.07</p>	<p>czas rekonstrukcji (s) 10.22</p>
<p>object radius (R) = 17.125mm FOV= 42mm</p> 	<p>estimated object radius (Re) = 17.2053mm FOV= 42mm</p> 	
	<p>czas rekonstrukcji (s) 0.076</p>	<p>czas rekonstrukcji (s) 9.91</p>
<p>object radius (R) = 10.875mm FOV= 42mm</p> 	<p>estimated object radius (Re) = 9.7895mm FOV= 42mm</p> 	
	<p>czas rekonstrukcji (s) 0.08</p>	<p>czas rekonstrukcji (s) 10.11</p>

Dokładność estymacji wielkości obiektu cylindrycznego metodą SNN porównano z dwiema znanymi z literatury metodami: metodą Liniowej Propagacji Wstecznej LBP, która jest szybka i bezpośrednia, ale jej wadą jest mała rozdzielczość zrekonstruowanego obrazu, oraz z metodą Levenberga-Marquarda, która jest dokładna, ale czasochłonna. Wyniki w Tabeli 2 wskazują, że promienie trzech zbadanych fantomów estymowane za pomocą MLP są bliskie pożądanym rzeczywistym wartościom. Przy użyciu MLP osiągnięto też mniejsze względne błędy estymacji niż miało to miejsce w przypadku LBP czy LM, tzn. przynajmniej kilka razy mniejsze dla małych obiektów i nawet 25 razy mniejsze niż uzyskane metodą LM oraz 93 razy mniejsze niż metodą LBP zastosowaną dla większych obiektów.


Tabela 2 Porównanie dokładności różnych metod

Method r [mm]	MLP		LBP		LM	
	\hat{r} [mm]	E_r [%]	\hat{r} [mm]	E_r [%]	\hat{r} [mm]	E_r [%]
35.25	35.32	0.19	29.01	17.7	33.54	4.85
17.125	17.20	0.44	12.84	25.02	18.73	9.37
10.875	9.79	9.98	12.48	14.76	16.4	50.8

Działanie metody opartej o MLP sprawdzono następnie w środowisku zaszumionym (szum dodano do pomiarów pojemności stanowiących dane wejściowe wybranej sieci neuronowej). Zastosowana metoda SNN okazała się odporna na sygnał szumu, osiągając standardowe odchylenie nie większe niż 7%.

Następnie zwiększano liczbę estymowanych parametrów przepływu. W kolejnym etapie badań oprócz wielkości komina (promień) wyznaczano też współrzędne jego położenia (x, y). Przykłady różnych położenia oraz różnych promieni fantomów rozważanych w symulacji przedstawiono na Rys. 5. Otrzymane wyniki potwierdzają poprawność podejścia opartego na sztucznych sieciach neuronowych w zastosowaniu do oceny wybranych parametrów przepływu bezpośrednio z danych tomograficznych bez fazy pełnej rekonstrukcji i przetwarzania obrazu. Badane parametry przepływu grawitacyjnego estymowano

w skróconym czasie obliczeniowym, 26 razy szybciej niż za pomocą metody Landwebera, co umożliwia monitorowanie procesu *online*.



Rys. 5 Przykłady różnych położenia i różnych promieni fantomów rozważanych w symulacji

Tabela 3 Porównanie dokładności estymacji położenia i promienia kolumna za pomocą metod: MLP, LM i LBP.

Fantom	Metoda $p = \begin{bmatrix} r \\ x_0 \\ y_0 \end{bmatrix} [\text{mm}]$	MLP		LBP		LM	
		$\hat{p} = \begin{bmatrix} \hat{r} \\ \hat{x}_0 \\ \hat{y}_0 \end{bmatrix} [\text{mm}]$	E_p [%]	$\hat{p} = \begin{bmatrix} \hat{r} \\ \hat{x}_0 \\ \hat{y}_0 \end{bmatrix} [\text{mm}]$	E_p [%]	$\hat{p} = \begin{bmatrix} \hat{r} \\ \hat{x}_0 \\ \hat{y}_0 \end{bmatrix} [\text{mm}]$	E_p [%]
1	$\begin{bmatrix} 28.88 \\ 30 \\ 40 \end{bmatrix}$	$\begin{bmatrix} 29.37 \\ 29.11 \\ 40.83 \end{bmatrix}$	$\begin{bmatrix} 1.69 \\ 2.96 \\ 2 \end{bmatrix}$	$\begin{bmatrix} 24.81 \\ 15.90 \\ 53.35 \end{bmatrix}$	$\begin{bmatrix} 14.09 \\ 47 \\ 33.37 \end{bmatrix}$	$\begin{bmatrix} 27.73 \\ 25.71 \\ 50.62 \end{bmatrix}$	$\begin{bmatrix} 3.98 \\ 14.3 \\ 26.55 \end{bmatrix}$
2	$\begin{bmatrix} 24.75 \\ 70 \\ 70 \end{bmatrix}$	$\begin{bmatrix} 24.63 \\ 69.24 \\ 69.74 \end{bmatrix}$	$\begin{bmatrix} 0.48 \\ 1 \\ 1 \end{bmatrix}$	$\begin{bmatrix} 20.78 \\ 78.64 \\ 74.17 \end{bmatrix}$	$\begin{bmatrix} 16.17 \\ 12.34 \\ 5.96 \end{bmatrix}$	$\begin{bmatrix} 17.96 \\ 78.74 \\ 73.94 \end{bmatrix}$	$\begin{bmatrix} 27.43 \\ 12.48 \\ 5.63 \end{bmatrix}$
3	$\begin{bmatrix} 25.25 \\ 20 \\ 60 \end{bmatrix}$	$\begin{bmatrix} 25.45 \\ 19.55 \\ 61.52 \end{bmatrix}$	$\begin{bmatrix} 0.8 \\ 2.25 \\ 2.52 \end{bmatrix}$	$\begin{bmatrix} 20.12 \\ 14.59 \\ 67.05 \end{bmatrix}$	$\begin{bmatrix} 20.32 \\ 27.05 \\ 11.75 \end{bmatrix}$	$\begin{bmatrix} 18.01 \\ 14.40 \\ 64.50 \end{bmatrix}$	$\begin{bmatrix} 28.71 \\ 28 \\ 7.5 \end{bmatrix}$

Zaletą zaproponowanego algorytmu jest również wyższy poziom dokładności, jaki zapewnia podejście oparte na SNN (patrz Tabela 3): najmniejszy błąd względny uzyskany dla metody MLP wynosi 0.48% wobec, odpowiednio, 6% i 4% dla metod LBP i LM. Największy względny błąd uzyskany dla metody MLP wynosi 3%, podczas gdy jest on rzędu 33% i 29%, odpowiednio dla LBP and LM.

W kolejnym kroku oprócz poprzednio wymienionych parametrów badano zmiany koncentracji materiału w kominie. Koncentrację materiału można ocenić za pomocą ECT na podstawie pomiaru rozkładu przenikalności elektrycznej. Symulacje komputerowe wykonano dla czujnika ECT z 8 elektrodami. Zaprojektowano SSN o strukturze MLP (28-14-4), przeznaczoną do estymacji czterech parametrów przepływu. Zwiększenie liczby estymowanych parametrów miało na celu zapewnienie bardziej trafnej i wartościowej informacji, a co za tym idzie dokładniejszego monitorowania procesu. Dokładność i szybkość nowej metody porównano z istniejącymi podejściami opartymi o rekonstrukcję obrazu. Metoda z zastosowaniem MLP pozwalała na szybszą ocenę badanych parametrów procesu niż metody stosowane obecnie: ponad 4000 szybszą niż metoda nieliniowa Levenberga-Marquardta, 2800 razy szybszą niż metoda Landwebera i 15 niż metoda liniowej projekcji wstecznej LBP. Uzyskana dokładność metody MLP jest na tym samym poziomie co metoda LM i jest co najmniej kilka razy lepsza w porównaniu z metodą LBP. Zaletą podejścia opartego o metodę SNN jest też możliwość estymacji czwartego parametru przepływu, tzn. przenikalności elektrycznej komina na podstawie nieprzetworzonych danych pomiarowych, co jest trudnym problemem w przypadku innych metod.

We wszystkich rozpatrywanych przypadkach, podejście oparte na MLP zapewniało uzyskanie dokładnych wartości parametrów przepływu kominowego. Wyniki są na tym samym poziomie dokładności lub nawet lepsze niż uzyskane przy pomocy najnowocześniejszych znanych w literaturze metod, a czas obliczeń jest znacząco krótszy, co potwierdza sformułowaną tezę rozprawy.

Otrzymane wyniki dla różnych modeli przepływu kominowego są obiecujące, szybkość jaką uzyskano jest wystarczająca, co umożliwi monitorowanie procesów przemysłowych *online* w czasie rzeczywistym. Czas potrzebny od oceny parametrów jest około 30 razy krótszy niż czas gromadzenia danych w tradycyjnym systemie pomiarowym ECT oraz jest około 3 razy krótszy w porównaniu z wysokimi osiągnięciami najnowszych systemów ECT.

W ramach części doświadczalnej wykonano pomiary w Laboratorium Tomografii Procesowej Tomasza Dyakowskiego w Instytucie Informatyki Stosowanej, Politechniki Łódzkiej, w celu przetestowania zaproponowanego podejścia w rzeczywistym środowisku pomiarowym. Zbudowano fizyczny model komina przepływu grawitacyjnego, a dane pomiarowe wprowadzono do wybranej sieci MLP, którą wcześniej uczono na podstawie danych uzyskanych z symulacji komputerowych przeprowadzonych z użyciem zestawu narzędzi ECTsim i Matlab.



Rys. 6 Zastosowany fantom przepływu kominowego – czujnik ECT z 8 elektrodami i obiektem wewnątrz.

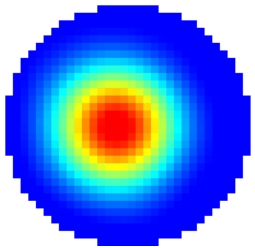
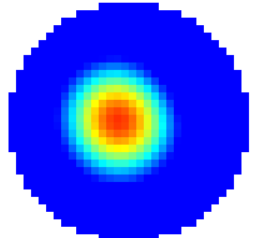
Tabela 4 Parametry czujników i fantomów rozpatrywanych podczas symulacji i odpowiadające im struktury MLP

Badane parametry	Średnica czujnika	Liczba elektrod	Średnica obiektu	Przenikalność obiektu	Przenikalność tła	Struktura MLP
r	84	12	<4; 84>	3	1	(66-10-1)
r, x, y	84	12	<20; 84>	3	1	(66-14-3)
r, x, y, ϵ	142	8	<40; 142>	[1.6, 2]	1	(28-14-4)

Parametry czujników i fantomów rozważane w przeprowadzonych symulacjach, takie jak: średnica czujnika, liczba elektrod, wielkość obiektu, przenikalność elektryczna komina oraz przenikalność elektryczna obszaru w pobliżu ściany zestawiono w Tabeli 4. Podano również strukturę najbardziej wydajnej struktury MLP. Podczas eksperymentów w laboratorium rozpatrywano tylko trzeci przypadek: czujnik o średnicy 142 mm, z 8 elektrodami i przenikalnością elektryczną $\epsilon = 1$. Zmierzone pojemności wprowadzono do sieci typu MLP o strukturze (28-14-4) w celu przetestowania jej działania w środowisku rzeczywistym.

Dokładność estymacji promienia i przenikalności obiektu przy użyciu MLP wynosi przeciętnie ok. 11% dla każdego wyznaczanego parametru, w przypadku obiektu umiejscowionego w centrum rury, co odpowiada przypadkowi przepływu kominowego.

Tabela 5 Wynik estymacji parametrów z pomiarów rzeczywistych z użyciem struktury MLP (28-14-4) dla różnych fantomów

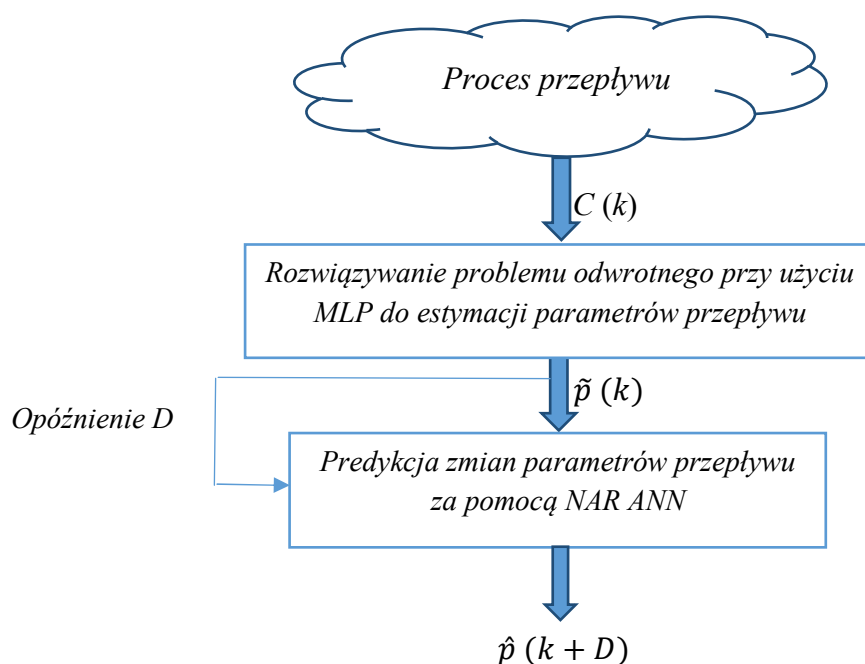
Fantom	Rozpatrywany fantom	Parametry fantomu	Parametry estymowane przez MLP	Błędy względne [%]	Parametry estymowane metodą Landwbera	Błędy względne [%]
1		$P = \begin{bmatrix} 31 \\ 65 \\ 75 \\ 2 \end{bmatrix}$	$\hat{P} = \begin{bmatrix} 27,5 \\ 64,1 \\ 64,7 \\ 1,8 \end{bmatrix}$	$\begin{bmatrix} 11,3 \\ 1,38 \\ 13,7 \\ 10 \end{bmatrix}$	$\hat{P} = \begin{bmatrix} 40 \\ 45,78 \\ 49,75 \\ - \end{bmatrix}$	$\begin{bmatrix} 29 \\ 29,56 \\ 33,66 \\ - \end{bmatrix}$
2		$P = \begin{bmatrix} 25 \\ 62 \\ 68 \\ 2 \end{bmatrix}$	$\hat{P} = \begin{bmatrix} 27,4 \\ 64,3 \\ 64,7 \\ 1,8 \end{bmatrix}$	$\begin{bmatrix} 9,6 \\ 3,7 \\ 4,85 \\ 10 \end{bmatrix}$	$\hat{P} = \begin{bmatrix} 31 \\ 44,8 \\ 49,6 \\ - \end{bmatrix}$	$\begin{bmatrix} 24 \\ 27,78 \\ 27,06 \\ - \end{bmatrix}$

W pierwszym przypadku, obiekt ma średnicę 62 mm, $r = 31$ mm, i jest umieszczony blisko środka rury. Względny błąd estymacji promienia przy użyciu MLP wynosi 11.3% oraz 10% dla estymacji przenikalności, które to wartości są zadowalające. Największy błąd względny uzyskano dla współrzędnej położenia y_0 , 13.7%, ale i tak jest on znacznie mniejszy niż błąd

estymacji tego parametru, uzyskanego w wyniku przetwarzania i analizy obrazu zrekonstruowanego metodą Landwebera (33,7%). Mniejsze błędy względne uzyskano dla mniejszego obiektu o średnicy $d=50$ mm; błędy względne nie przekraczają 10% dla estymacji promienia i przenikalności, a średnio 5% dla estymacji współrzędnych położenia. Poziom dokładności metody opartej na SNN jest wyższy niż dla metody Landwebera.

5. Przewidywanie dynamiki przepływu

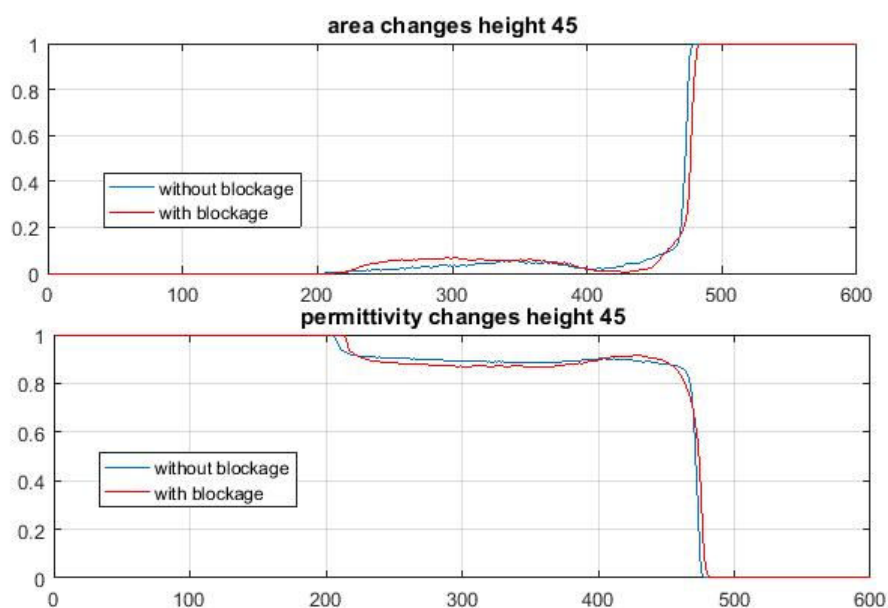
Ponadto, zaproponowano nowy model oparty na SNN przeznaczony do zastosowania w ECT do przewidywania zmian charakterystycznych parametrów przepływu grawitacyjnego materiałów sypkich. Elektryczna tomografia pojemnościowa (ECT) stosowana jest do nieinwazyjnego monitorowania procesu, natomiast sekwencja sztucznych sieci neuronowych: MLP i nieliniowej autoregresyjnej sieci neuronowej NAR (ang. *Nonlinear Autoregressive Neural Network*) do estymacji i przewidywania zmian ważnych parametrów przepływu na podstawie zmierzonych pojemności (Rys. 7). Pierwsza SNN typu MPL rozwiązuje problem odwrotny w ECT poprzez bezpośrednie odwzorowanie nieliniowego związku między zbiorem danych wejściowych (zmierzone pojemności) i danych wyjściowych – istotne parametry rozpatrywanego przepływu grawitacyjnego materiałów sypkich.



Rys. 7 Proponowane podejście oparte na SNN do estymacji i przewidywania zmian parametrów przepływu

Estymowane parametry otrzymane na wyjściu MLP są następnie przesyłane do drugiej sieci neuronowej typu NAR, która przewiduje zmiany parametrów i dynamikę przepływu kominowego. Proponowane podejście zapewniło szybką identyfikację parametrów przepływu kominowego. Symulację procesu opróżniania silosu wykonano opierając się na pomiarach dla rzeczywistego przebiegu przepływu uzyskanych z poprzednich badań (Romanowski i inni, 2006). Symulowane dane zastosowano do przetestowania i weryfikacji nowego podejścia z zastosowaniem SSN.

Rozpatrzono dwa przypadki opróżniania silosu: przepływu prawidłowego (normalnego) i przepływu z blokadą, kiedy obecna jest strefa stagnacji wewnątrz silosu. Wyznaczone zmiany obszaru wielkości komina i jego przenikalności elektrycznej względnej na wysokości 45 mm dla obu przypadków: z blokadą i bez pokazano na Rys. 8. Daje się zauważyć opóźnienie zmian parametrów (kilka ramek) i małe zmiany wielkości sygnału, kiedy podczas procesu opróżniania silosu pojawia się przeszkoda.




Rys. 8 Zmiany wielkości obszaru i przenikalności elektrycznej w obszarze komina dla dwóch przypadków przepływu kominowego: z blokadą i bez przy tej samej wysokości czujnika ($h=45\text{mm}$).

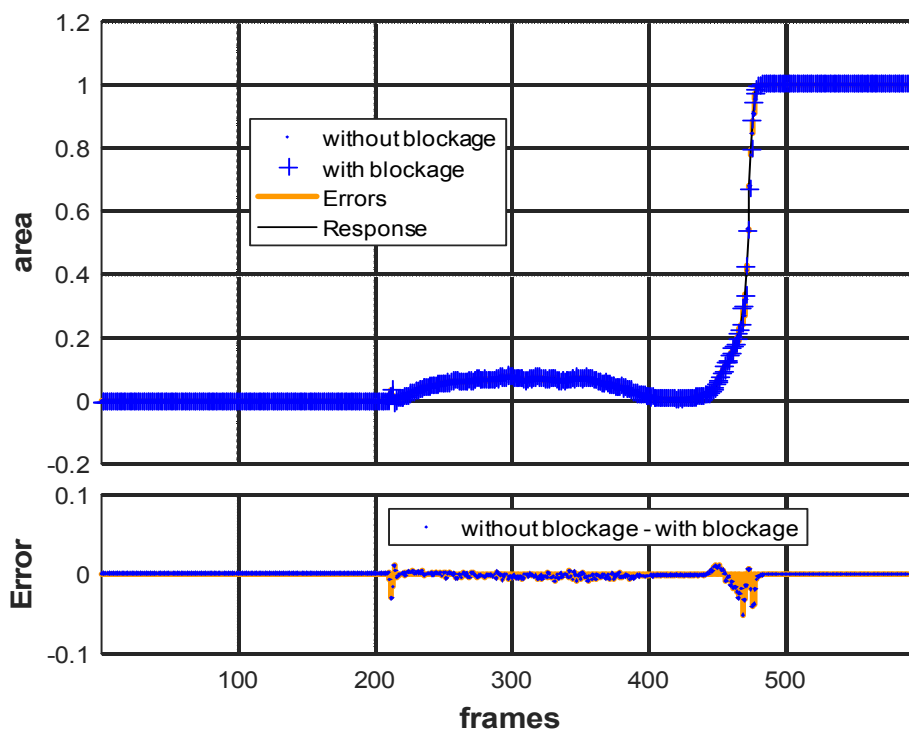
Istotnymi parametrami przepływu rozważanymi podczas eksperymentów są koncentracja materiału i obszar komina. Założono, że relacja między koncentracją materiału w obszarze komina a jego przenikalnością elektryczną jest liniowa. Zgodnie z zaproponowanym podejściem (Rys.7), parametry komina są najpierw estymowane przez MLP, a następnie wprowadzane do sieci neuronowej typu NAR, która przewiduje ich przyszłe zmiany. Sieć

typu NAR i przewidywanie zmian parametrów zaimplementowano za pomocą pakietu obliczeniowego Matlab i biblioteki Neural Network Toolbox. Zastosowano algorytm Levenberga-Marquardta do uczenia sieci NAR, a jej wagi początkowe wygenerowano przy użyciu funkcji losowej.

Przewidywane zmiany parametrów komina dla wysokości czujnika $h=45$ mm i w przypadku przeszkody obecnej wewnątrz silosu pokazano na Rys. 9 i Rys. 10. Można zauważyć większe błędy dla zmian charakterystycznych parametrów, co mogłoby być w przyszłości wykorzystywane do diagnozowania i wykrywania nieprawidłowości.



Rys. 9 Przewidywane zmiany w koncentracji materiału w obszarze komina i otrzymane błędy dla wysokości czujnika 45mm w przypadku blokady.



Rys. 10 Przewidywane zmiany wielkości obszaru komina i otrzymane błędy dla wysokości czujnika 45mm w przypadku blokady.

Uzyskana średnia dokładność $2 \cdot 10^{-7}$ jest satysfakcjonująca i dowodzi, iż zaproponowana metoda oparta na SNN pozwoli na śledzenie procesu opróżniania silosu *online* i wcześniejsze rozpoznanie faz procesu i jego nieprawidłowości.

6. Wnioski

Celem niniejszej rozprawy doktorskiej było opracowanie i implementacja nowych metod, które umożliwiają monitorowanie grawitacyjnego przepływu materiałów sypkich *online* w czasie rzeczywistym.

Głównym osiągnięciem niniejszej rozprawy jest opracowanie nowej metody estymacji istotnych parametrów przepływu w oparciu o sztuczne sieci neuronowe. Metoda posiada następujące zalety:

- 1) Parametry przepływu są estymowane bezpośrednio na podstawie zmierzonych pojemności bez potrzeby stosowania algorytmów rekonstrukcji obrazu, 2) jest szybsza niż istniejące metody rekonstrukcji obrazu oraz 3) wykazuje dużą dokładność w rozwiązywaniu problemu odwrotnego ECT.

We wszystkich rozpatrywanych przypadkach podejście oparte na MLP zapewniło dokładne wartości parametrów przepływu komin. Wyniki są na tym samym poziomie dokładności lub nawet lepsze niż uzyskane dla znanych z literatury metod klasycznych, a czas obliczeń jest znacząco krótszy, co potwierdza postawioną w ramach niniejszej rozprawy tezę.

Wyniki otrzymane dla różnych modeli przepływu kominowego są obiecujące, a zapewniona szybkość jest wystarczająca i oferuje możliwość monitorowania procesu przemysłowego *online* w czasie rzeczywistym. Czas potrzebny do estymacji parametrów jest w przybliżeniu trzydzieści razy krótszy niż czas gromadzenia danych przy użyciu tradycyjnego systemu pomiarowego ECT i około trzy razy krótszy w porównaniu z wysoko wydajnymi systemami ECT.

W przypadku środowiska rzeczywistego, dokładność estymacji promienia i przenikalności obiektu metodą MLP wynosi średnio około 11% dla każdego ocenianego parametru, dla przypadku obiektu umieszczonego w centrum rury, co odpowiada przypadkowi przepływu kominowego.

Ponadto, nową metodę opartą na SNN zaproponowano do przewidywania zmian parametrów przepływu grawitacyjnego materiałów sypkich podczas procesu opróżniania silosu, a otrzymana dokładność dowiodła, że proponowana metoda oparta na SNN pozwoli na monitorowanie procesu opróżniania silosu *online* i wcześniejsze rozpoznanie faz procesu oraz ewentualnych nieprawidłowości.

7. Bibliografia

Abdul Wahab, Y., Abdul Rahim, R., Fazalul Rahiman, M., Ridzuan Aw, S., Mohd Yunus, F., Goh, C., Abdul Rahim, H. and Ling, L. (2015). Non-invasive process tomography in chemical mixtures, A review. *Sensors and Actuators B: Chemical*, 210, pp.602-617

Chaniecki, Z., Dyakowski, T., Niedostatkiwicz, M. and Sankowski, D. (2006). Application of Electrical Capacitance Tomography for Bulk Solids Flow Analysis in Silos. *Part. Part. Syst. Charact.*, 23(3-4), pp.306-312.

Ectsim.ire.pw.edu.pl, (2012). *ECTSim Electrical Capacitance Tomography Simulator*. [online] Available at: <http://ectsim.ire.pw.edu.pl> [Accessed 19 Jan. 2016].

Grudzien, K., Romanowski, A., Chaniecki, Z., Niedostatkiwicz, M. and Sankowski, D.

(2010). Description of the silo flow and bulk solid pulsation detection using ECT. *Flow Measurement and Instrumentation*, 21(3), pp.198-206.

Haykin, S. (1999). *Neural networks*. Upper Saddle River, N.J.: Prentice Hall.

Jackowska-Strumillo, L., Sokolowski, J., Å»ochowski, A. and Henrot, A. (2002). On Numerical Solution of Shape Inverse Problems. *Computational Optimization and Applications*. *Computational Optimization and Applications*, 23(2), pp.231-255.

Kabanikhin, S. (2008). Definitions and examples of inverse and ill-posed problems. *Journal of Inverse and Ill-posed Problems*, 16(4).

Niedostatkiewicz, M., Tejchman, J., Chaniecki, Z. and GrudzieÅ,, K. (2009). Determination of bulk solid concentration changes during granular flow in a model silo with ECT sensors. *Chemical Engineering Science*, 64(1), pp.20-30.

Ratajewicz-Mikolajczak, E. and Sikora, J. (2002). Neural networks method for identification of the objects behind the screen. *IEEE Transactions on Medical Imaging*, 21(6), pp.613-619.

Ratajewicz-Mikolajczak, E., Shirkoohi, G. and Sikora, J. (1998). Two ANN reconstruction methods for electrical impedance tomography. *IEEE Trans. Magn.*, 34(5), pp.2964-2967.

Romanowski, A., Grudzien, K. and Williams, R. (2006). Analysis and Interpretation of Hopper Flow Behaviour Using Electrical Capacitance Tomography. *Part. Part. Syst. Charact.*, 23(3-4), pp.297-305.

Stasiak, M., Sikora, J., Filipowicz, S. and Nita, K. (2007). Principal component analysis and artificial neural network approach to electrical impedance tomography problems approximated by multi-region boundary element method. *Engineering Analysis with Boundary Elements*, 31(8), pp.713-720.

Tapp, H., Peyton, A., Kemsley, E. and Wilson, R. (2003). Chemical engineering applications of electrical process tomography. *Sensors and Actuators B: Chemical*, 92(1-2), pp.17-24.

Zhang, W., Wang, C., Yang, W. and Wang, C. (2014). Application of electrical capacitance tomography in particulate process measurement - A review. *Advanced Powder Technology*, 25(1), pp.174-188.