



Zachodniopomorski
Uniwersytet Technologiczny
w Szczecinie



Grzegorz Psuj, Barbara Grochowalska, Przemysław Łopato,
Michał Maciusowicz, Michał Herbko

Głębokie uczenie w zastosowaniu do oceny stanu i charakteryzacji materiałów

Centrum Inżynierii Pól Elektromagnetycznych i Techniki
Wysokich Częstotliwości, Wydział Elektryczny,
Zachodniopomorski Uniwersytet Technologiczny w Szczecinie

Centrum Inżynierii Pól Elektromagnetycznych i Technik Wysokich Częstotliwości



Centrum rozpoczęło działalność 1 stycznia 2021 roku. Do głównych zadań Centrum należą badania podstawowe i stosowane w zakresie fal elektromagnetycznych wysokiej częstotliwości (pasma radiowe, mikrofalowe, terahercowe, podczerwone) oraz inżynierii pola elektromagnetycznego, w tym magnetyzmu, oddziaływania pól silnych oraz dynamiki namagnesowania i towarzyszących mu zjawisk termicznych.

Laboratoria:

- **Laboratorium Aktywnej Termografii Podczerwonej**
- **Laboratorium Anten i Technik Wysokich Częstotliwości**
- **Laboratorium Pomiarów Magnetycznych**
- **Laboratorium Techniki Mikrofalowej**
- **Pracownia Badań i Certyfikacji EMC**
- **Pracownia Prototypowania, Obróbki i Inspekcji Wizualnej**



Centrum Inżynierii
Pól Elektromagnetycznych
i Technik Wysokich
Częstotliwości




Plan prezentacji



- **Wstęp**
- **Metoda Aktywnej termografii (IRT) – podejście nr 1 – płytkie sieci neuronowe**
 - Próbki i układ pomiarowy
 - Model numeryczny – przykładowe wyniki
 - Koncepcja sieci neuronowej i przygotowanie bazy danych
 - Wyniki działania sieci neuronowej dla danych numerycznych i eksperymentalnych
- **Metoda Aktywnej termografii (IRT) – podejście nr 2 – model uogólniony i sieci LSTM**
 - Próbki
 - Uogólniony model numeryczny
 - Koncepcja sieci
 - Przykładowe wyniki
- **Połączone metody – IRT i inspekcji terahercowej**
 - Układ pomiarowy
 - Rejestracja danych z dwóch systemów
 - Architektura wybranej sieci neuronowej
 - Przykładowe wyniki

Wstęp

- Druk 3D, zwany także wytwarzaniem addytywnym (AM), jest obecnie szeroko stosowany w wielu gałęziach przemysłu.
- Rozwój technik druku 3D spowodował, że wytwarzane w ten sposób struktury coraz częściej są również produktem finalnym. Takie wykorzystanie tych materiałów sprawia, że ważna jest ocena ich jakości.
- W naszych pracach skupiamy się głównie na kontroli jakości w końcowym etapie produkcji druku 3D.
- Do jakościowej i ilościowej oceny drukowanej struktury wykorzystujemy tutaj dwie nieniszczące techniki badań (NDT) - aktywną termografię w podczerwieni (IRT) oraz obrazowanie terahercowe (THz).
- **Nasze cele:**
 - **zbudowanie modelu numerycznego, wykorzystanie wyników numerycznych do trenowania sieci neuronowej, walidacja wydajności sieci na podstawie wyników eksperymentalnych.**
 - **Połączenie dwóch metod inspekcji w celu uzyskania lepszych wyników oceny próbek**


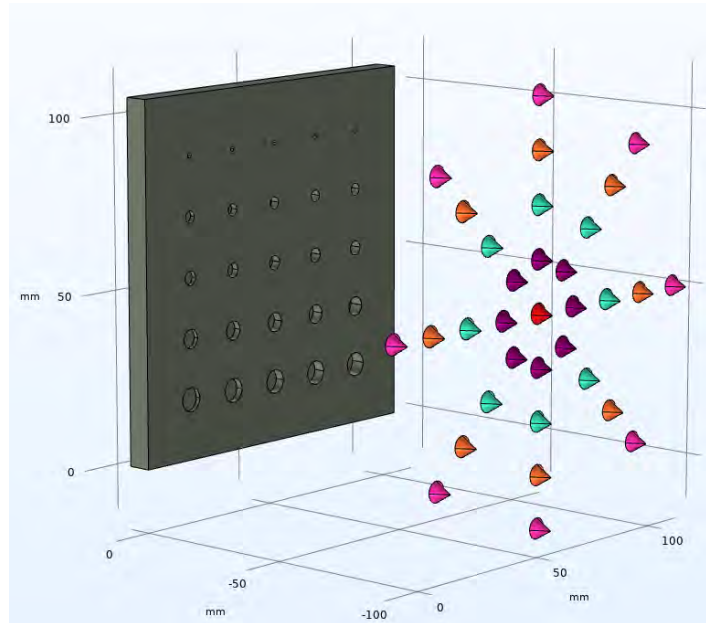


Technika IRT – podejście nr 1 Próbki oraz układ eksperymentalny



Technika IRT – podejście nr 1

Model numeryczny





- Model został przygotowany w środowisku COMSOL.
- Uproszczony model zakłada, że przepływ ciepła od źródła do próbki jest realizowany tylko poprzez radiację.
- Źródło ciepła zostało zamodelowane jako macierz źródeł punktowych, których moc spada liniowo w kierunku radialnym.
- Model odwzorowuje układ laboratoryjny, stąd zastosowano technikę transmisyjną.
- Tak samo jak w badaniach eksperymentalnych założono, że czas grzania wynosi 60 s, po których następuje 300 s. naturalnego, konwekcyjnego ochładzania.



Technika IRT – podejście nr 1

Przykładowe wyniki –
porównanie między
wynikami
numerycznymi,
a eksperymentalnymi




Wyniki numeryczne



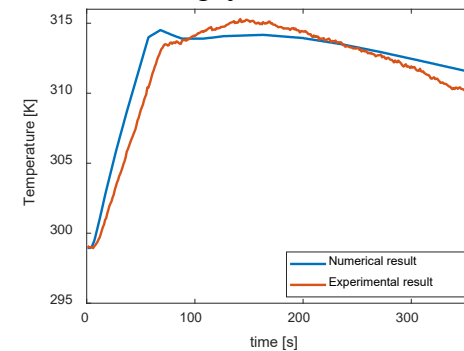
Wyniki eksperymentalne



Wybrane punkty: środki defektów




Porównanie dla defektu D1 –
fi 7 mm, głębokość 4.2 mm



Technika IRT – podejście nr 1

Koncepcja sieci neuronowej

- Użyta została sieć neuronowa rozpoznająca wzorce (zaimplementowana w środowisku MATLAB)
- Zadanie – wykrycie defektów
- Wejście – charakterystyki czasowo – temperaturowe (na 1 piksel przypada jedna taka funkcja)
- Wyjście – dwie klasy: „defekt”, „bez defektu”

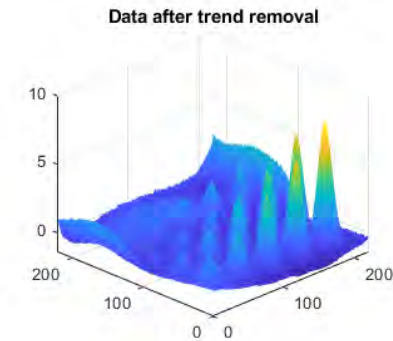
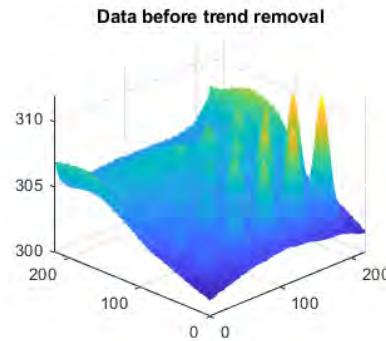
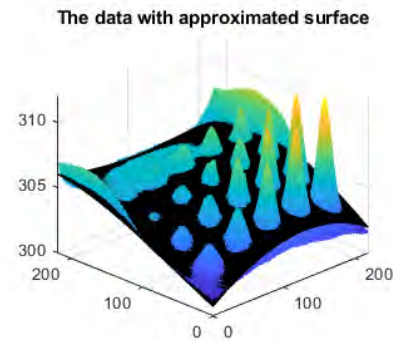
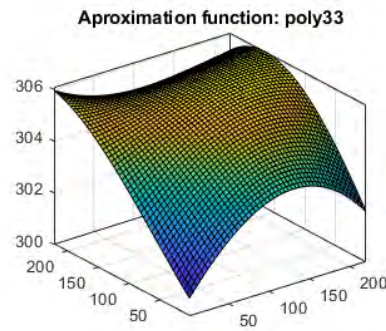


Szczegóły projektu sieci:

- 70% danych użytych w procesie uczenia, 15% na walidację i 15% na testowanie. Dane podzielono w sposób losowy
- W procesie uczenia zastosowano metodę gradientu sprzężonego
- Do oceny sieci w każdej epoce użyto entropii krzyżowej

Technika IRT – podejście nr 1

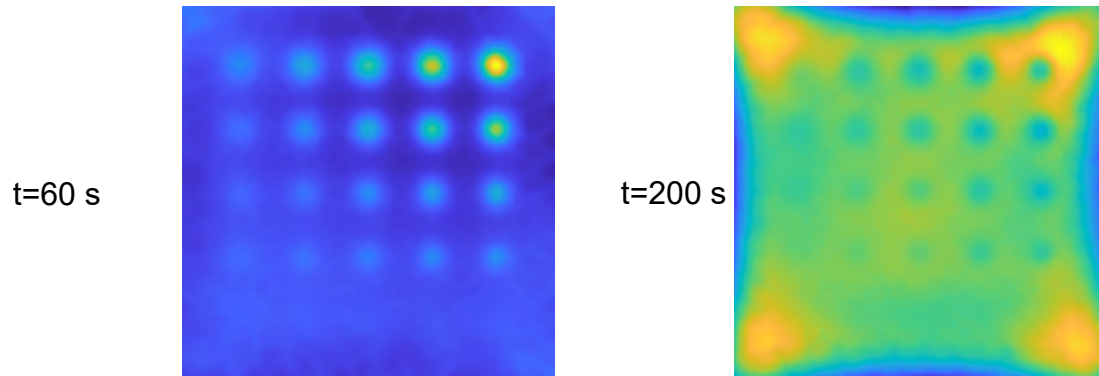
Przygotowanie bazy danych: usunięcie trendu




- Dla każdego termogramu w sekwencji dopasowywana jest powierzchnia
- Dopasowana powierzchnia jest następnie odejmowana od oryginalnego termogramu
- Normalizacja
- Taka sama procedura została zastosowana dla danych numerycznych i eksperymentalnych

Technika IRT –
podejście nr 1
Przygotowanie
bazy danych:
usunięcie
trendu


Wyniki numeryczne



Wyniki eksperymentalne






Porównanie dla defektu D1 –
fi 7 mm, głębokość 4.2 mm



Technika IRT – podejście nr 1


Przygotowanie bazy danych: wybór obszarów



- Znana była dokładna lokalizacja defektów, co pozwoliło na precyzyjny wybór obszarów z defektami
- Wszystkie piksele z obszarów z defektami i bez defektów zostały zgrupowane w osobnych macierzach
- W rezultacie otrzymano 1605 charakterystyk dla defektów 46795 funkcji dla obszarów bez defektów

Technika IRT – podejście nr 1

Przygotowanie bazy danych: dodawanie szumu do sygnałów



- W celu uzupełnienia bazy danych do otrzymanych sygnałów został dodany biały szum
- W rezultacie utworzono bazę danych zawierającą 964 605 charakterystyk dla obszarów z defektami, i 982 695 charakterystyk dla obszarów bez defektów

Technika IRT – podejście nr 1

Wynik uczenia sieci neuronowej – wykrycie defektów dla danych numerycznych



	Samples	CE	%E
Training:	1363110	2.24683e-0	2.18720e-0
Validation:	292095	6.30100e-0	2.24961e-0
Testing:	292095	6.30123e-0	2.26022e-0

Training Confusion Matrix

Output Class \ Target Class	1	2	Accuracy
1	669133 49.1%	23757 1.7%	96.6% 3.4%
2	6057 0.4%	664163 48.7%	99.1% 0.9%
Overall	99.1% 0.9%	96.5% 3.5%	97.8% 2.2%

Validation Confusion Matrix

Output Class \ Target Class	1	2	Accuracy
1	143299 49.1%	5165 1.8%	96.5% 3.5%
2	1406 0.5%	142225 48.7%	99.0% 1.0%
Overall	99.0% 1.0%	96.5% 3.5%	97.8% 2.2%





Test Confusion Matrix

Output Class \ Target Class	1	2	Accuracy
1	143255 49.0%	5147 1.8%	96.5% 3.5%
2	1455 0.5%	142238 48.7%	99.0% 1.0%
Overall	99.0% 1.0%	96.5% 3.5%	97.7% 2.3%



All Confusion Matrix

Output Class \ Target Class	1	2	Accuracy
1	955687 49.1%	34069 1.7%	96.6% 3.4%
2	8918 0.5%	948626 48.7%	99.1% 0.9%
Overall	99.1% 0.9%	96.5% 3.5%	97.8% 2.2%



Technika IRT –
podejście nr 1

Wynik uczenia sieci
neuronowej –
wykrycie defektów
dla danych
numerycznych






- Poprawienie kontrastu
- Widoczność najmniejszych defektów




Technika IRT – podejście nr 1

Walidacja wyuczonej sieci na danych eksperymentalnych




40dB – 20dB



40dB – 15dB






40dB – 10dB






Technika IRT – podejście nr 1

Walidacja wyuczonej sieci na danych eksperymentalnych




40dB – 5dB



40dB – 0dB



40dB – -5dB






**Technika IRT –
podejście nr 1**
Walidacja wyuczonej
sieci na danych
eksperymentalnych

40dB – -10dB

Confusion Matrix

1	831 1.7%	2088 4.3%	28.5% 71.5%
2	774 1.8%	44707 92.4%	98.3% 1.7%
	51.8% 48.2%	95.0% 4.5%	94.1% 5.9%
		Target Class	





Technika IRT –
podejście nr 2
Próbki




(a)




(b)



(c)



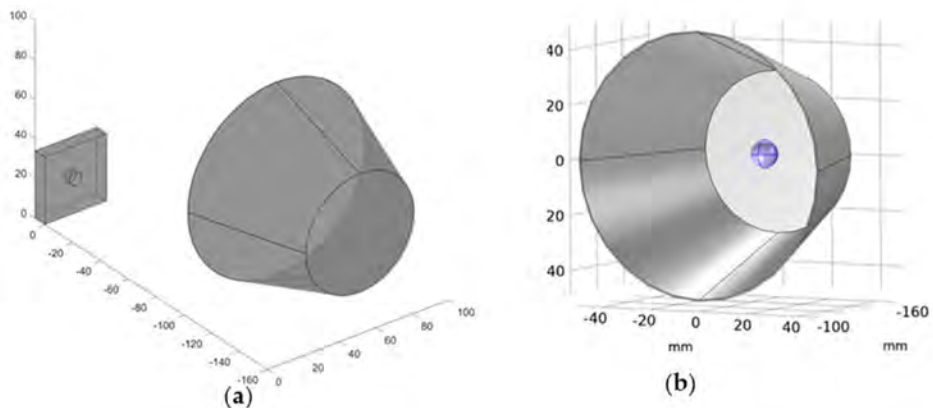
(a)




(b)

Próbki drukowane z różnym wypełnieniem – 100% i 30%

Technika IRT –
podejście nr 2
Uogólniony model
numeryczny





Widok geometrii modelu w programie COMSOL

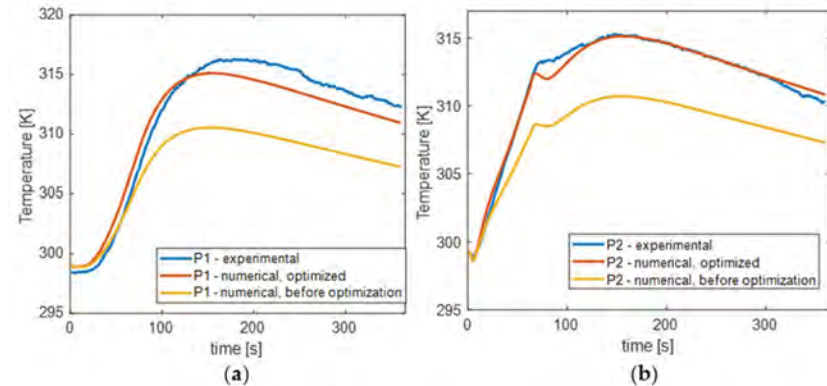
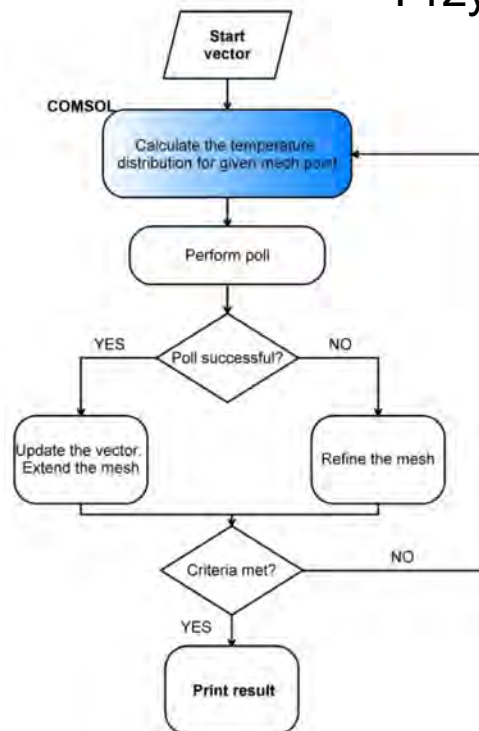


Parametryzacja modelu – wymiary geometryczne wady i położenie źródła
względem wady – rezultat – 885 modeli numerycznych

Technika IRT –
 podejście nr 2
 Dopasowanie
 modelu -
 optymalizacja




Przykładowe porównywane obszary




Porównanie wyników przed i po
 optymalizacji dla wybranych
 obszarów

Schemat blokowy algorytmu
 optymalizacji – pattern search

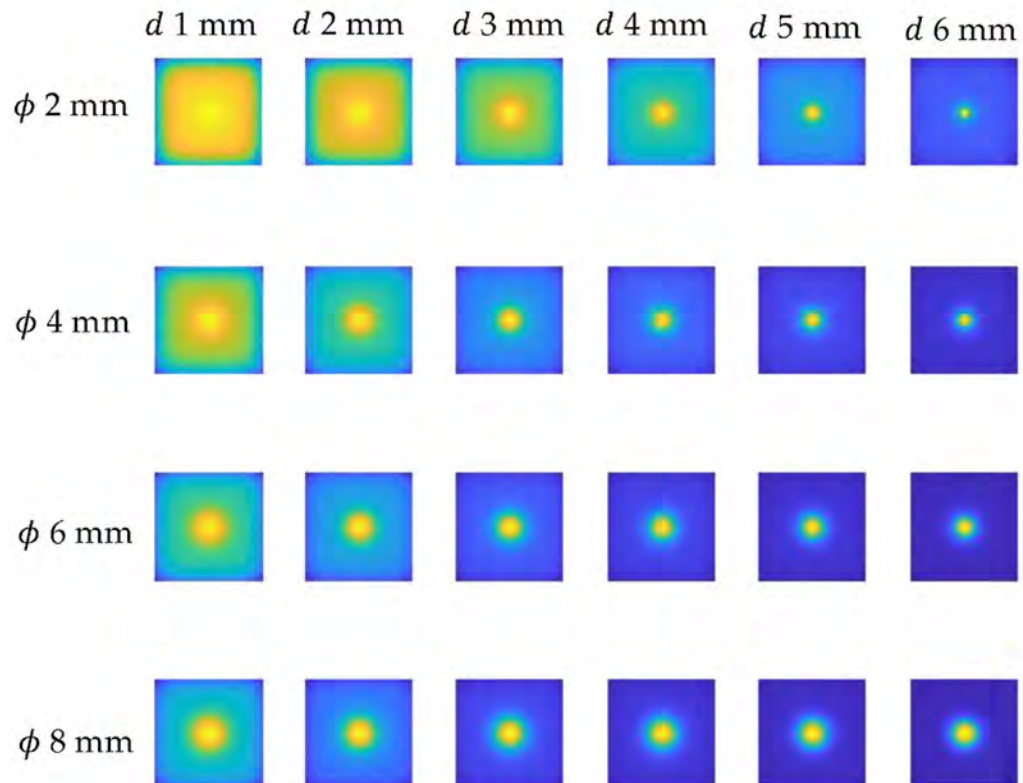
Technika IRT –
podejście nr 2
Przykładowe wyniki
eksperymentalne i
numeryczne




(a)




(b)



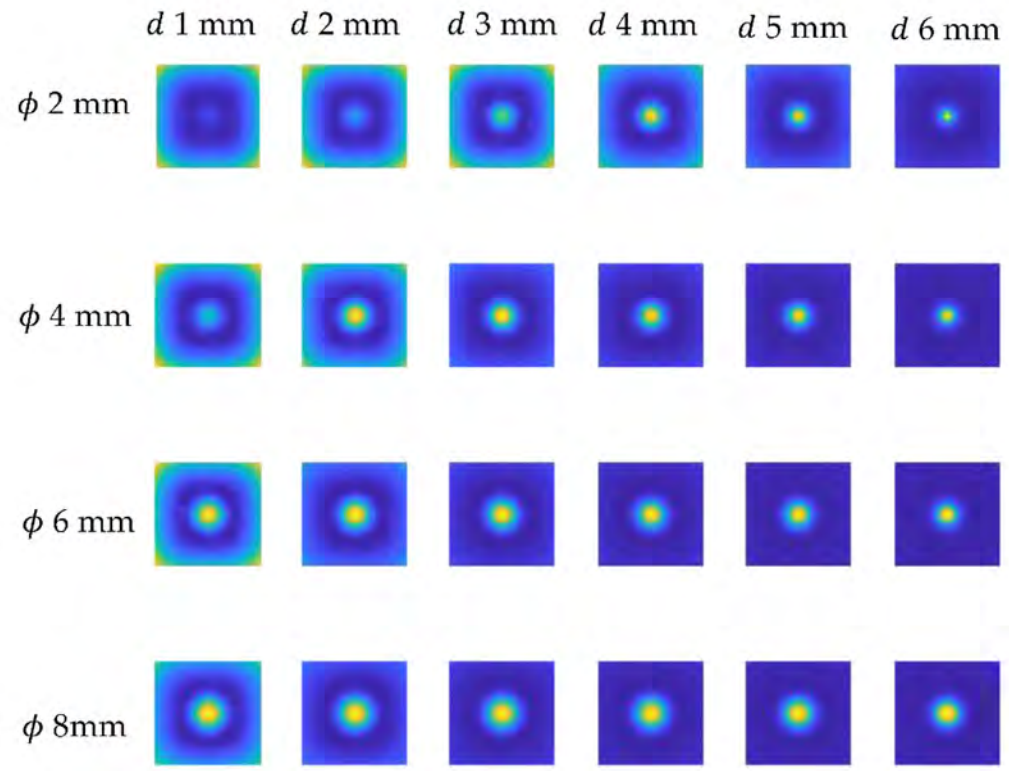
Technika IRT –
podejście nr 2
Przykładowe wyniki
eksperymentalne i
numeryczne




(a)




(b)



Technika IRT –
podejście nr 2
Przygotowanie bazy
danych



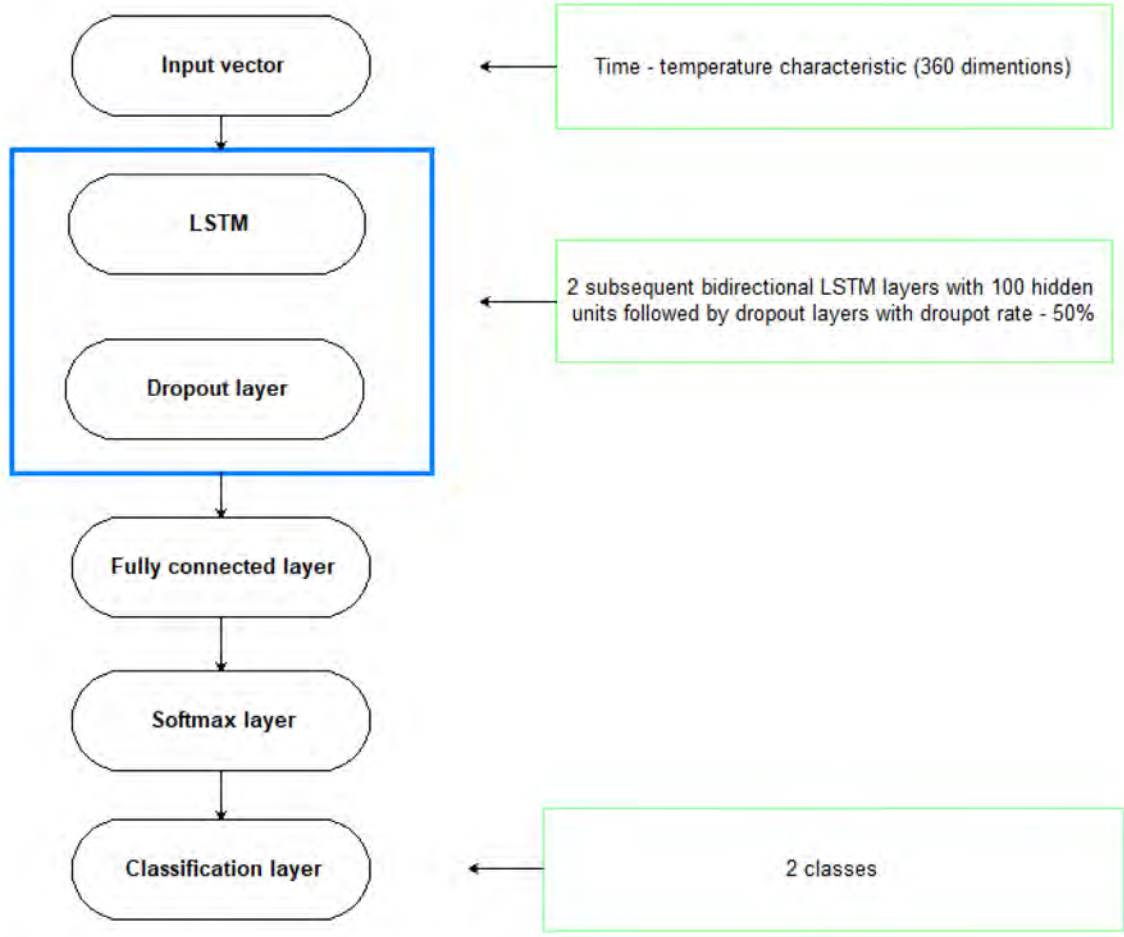
(a)



(b)

- Dla każdego z 885 modeli do dalszej analizy wzięto sekwencje czasowe złożone z 360 obrazów termicznych;
- Z każdego modelu do bazy dołączono po 300 charakterystyk czasowo-temperaturowych dla losowo wybranych pikseli z obszaru wady i 300 charakterystyk z obszaru bez wady;
- W rezultacie otrzymano bazę złożoną z 256 500 charakterystyk dla obszaru wady i 256 500 charakterystyk z obszaru bez wady;
- Bazę podzielono na zbiór uczący, walidacyjny i testowy w proporcjach 0.7:0.15:0.15.

Technika IRT –
podejście nr 2
Sieć LSTM



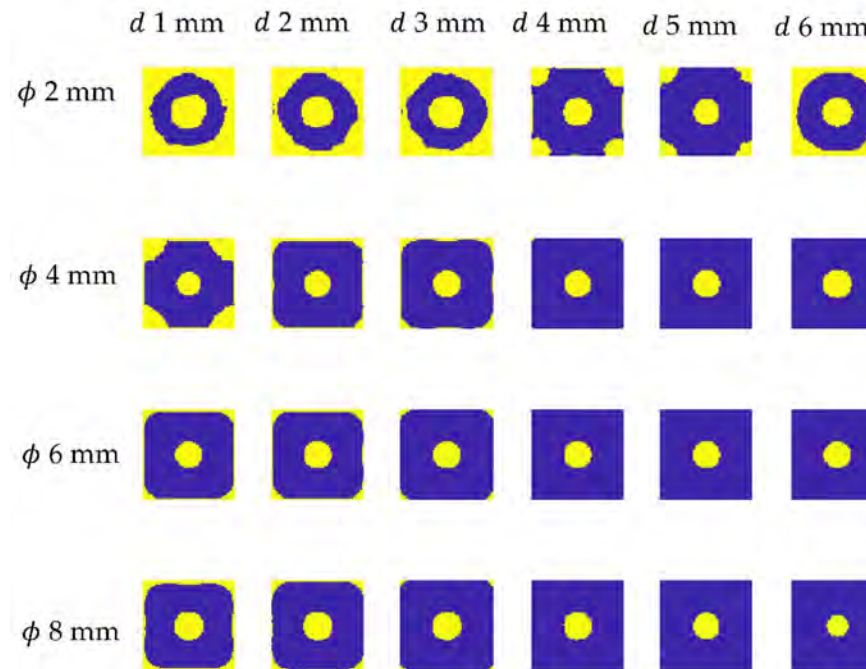
Confusion matrix

		Predicted Class	
		Non-defect	Defect
Actual class	Non-defect	49.37%	0.63%
	Defect	0.08%	49.92%

Technika IRT –
podejście nr 2
Wyniki dla danych
numerycznych

Wyniki dla przykładowych parametrów

Accuracy	Recall	Selectivity	Precision
99.30%	99.84%	98.75%	98.76%



Confusion matrix dla obu próbek

Technika IRT –
podejście nr 2
Walidacja sieci na
danych
eksperymentalnych

		Predicted Class	
		Non-defect	Defect
Actual class	Non-defect	88.50%	7.31%
	Defect	1.21%	2.98%

100%


Wyniki dla przykładowych parametrów

Accuracy	Recall	Selectivity	Precision
91.48%	71.07%	92.37%	28.93%

		Predicted Class	
		Non-defect	Defect
Actual class	Non-defect	84.25%	11.36%
	Defect	1.20%	3.18%

30%


Accuracy	Recall	Selectivity	Precision
87.43%	72.57%	88.12%	21.88%



(a)


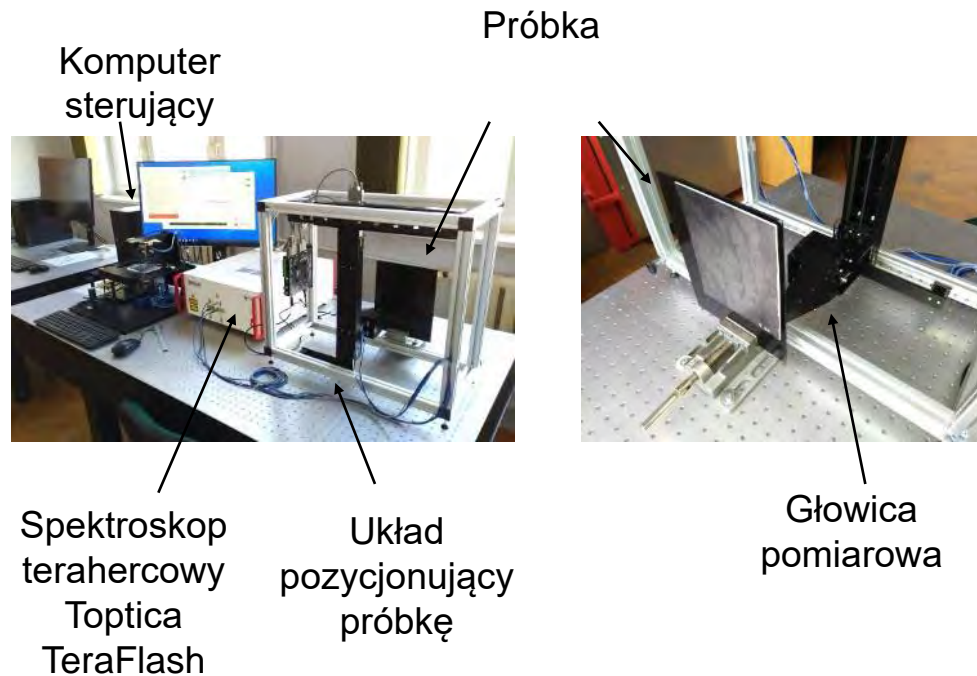


(b)


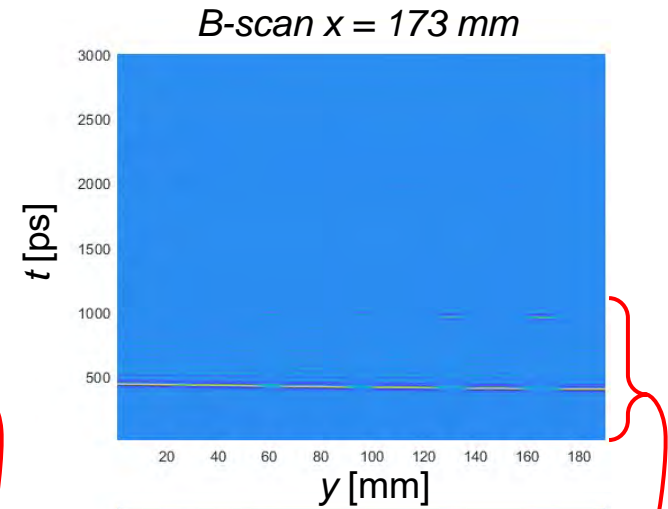





(c)

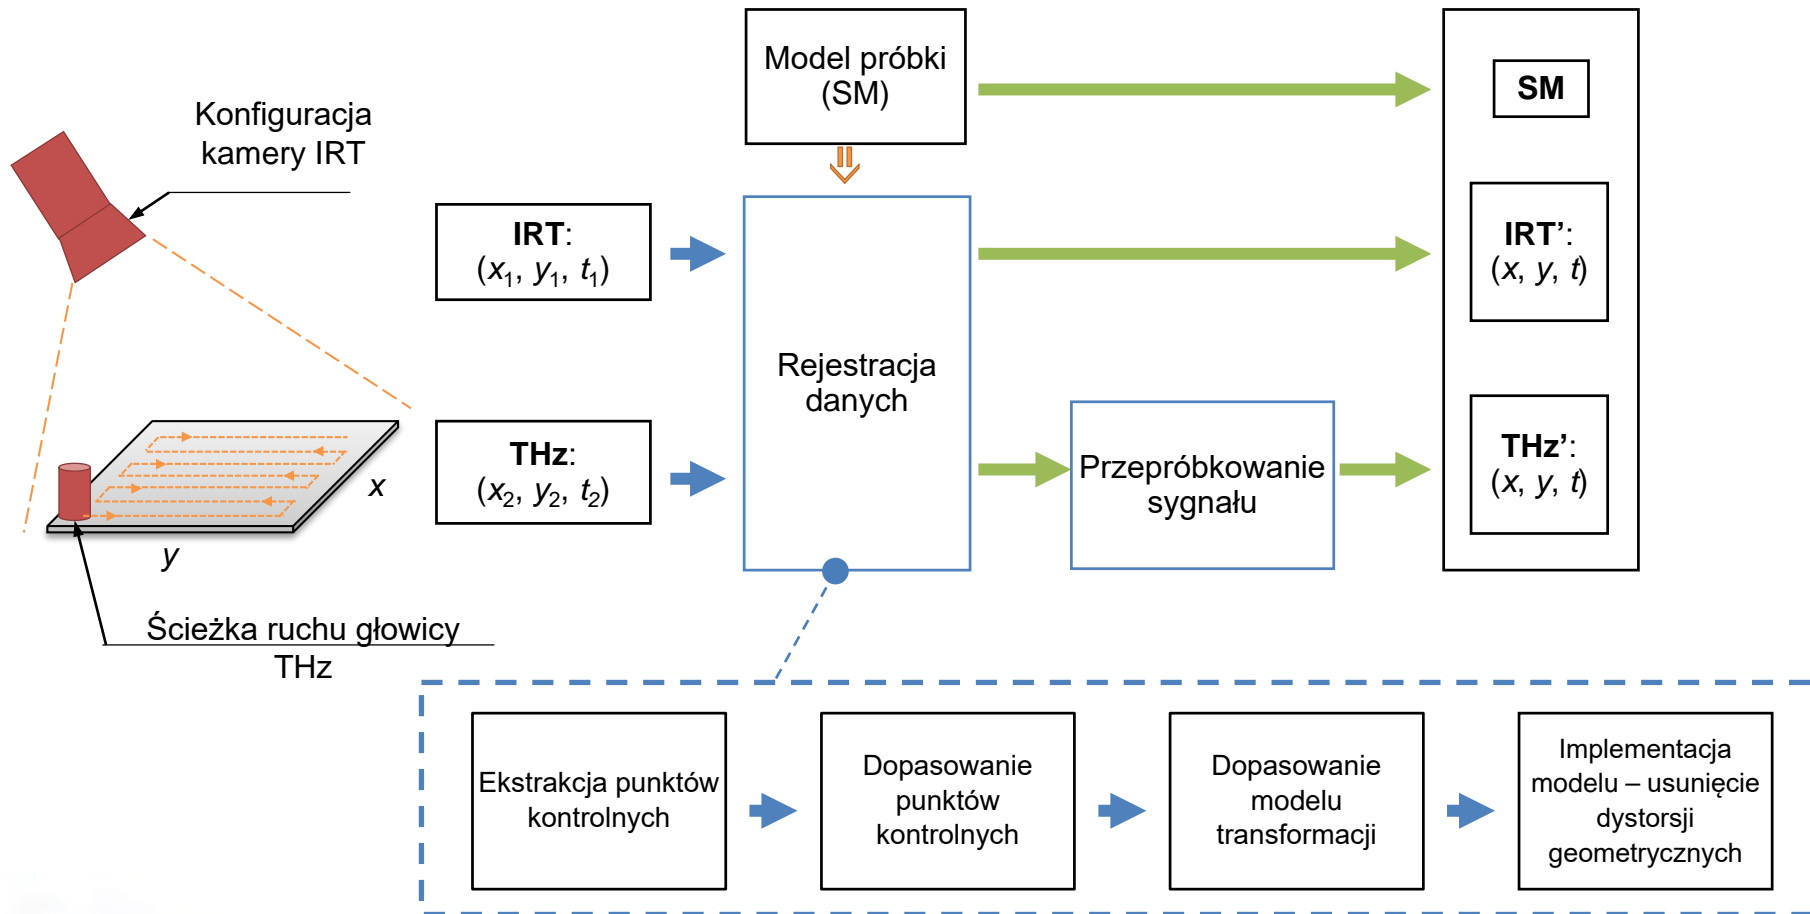
Połączone metody
THz i IRT
Laboratoryjny układ
obrazowania
terahercowego



Połączone metody
THz i IRT
Wyniki obrazowania
THz




Połączone metody THz i IRT Rejestracja danych




Przebiegi rejestrowanych sygnałów: sekwencje 360 kroków czasowych



Połączone metody
THz i IRT
Rezultaty rejestracji
danych




Indeks kroku




Indeks kroku



Rzeczywista mapa defektów




Wynik inspekcji IRT dla kroku czasowego nr 60




Wynik inspekcji THz dla kroku czasowego nr 60

Połączone metody
THz i IRT
Przygotowanie bazy
danych

Mapa defektów







Liczba wszystkich punktów pomiarowych:
 $198 \times 198 = 39204$
26 group:
1 – bez defektów
25 – defekty o różnych średnicach i głębokościach



0 – „bez defektu” (niebieska)
1 – „defekt” (żółta)

Wizualizacja lokalizacji punktów wybranych do uczenia sieci LSTM



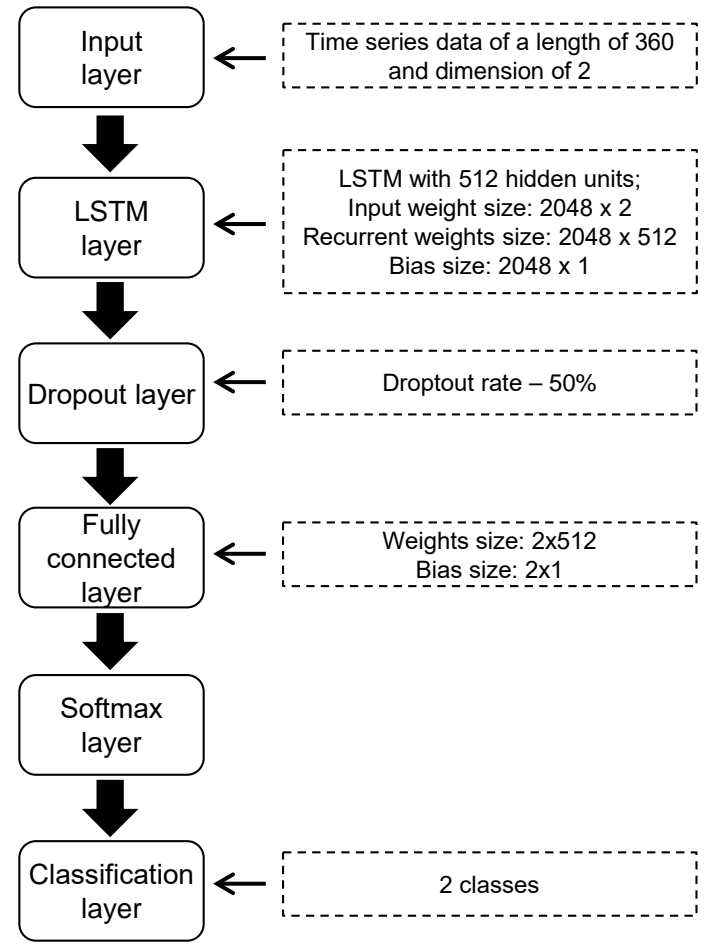
-  Dane uczące
-  Dane walidacyjne
-  Dane testujące

- Każdy punkt reprezentuje 2 cechy odpowiadające dwóm technikom pomiarowym
- Wybrano losowo 2260 przypadków ze wszystkich 39204, gdzie 1130 reprezentowało klasę 0 (bez defektu).
- Zbiór uczący (70%), walidacyjny (15%) i testujący (15%)


Połączone metody THz i IRT Struktura sieci LSTM

Confusion Matrix


Output Class	0	<p style="text-align: center;">166 48.1%</p>	<p style="text-align: center;">4 1.2%</p>	<p style="text-align: center;">97.6% 2.4%</p>
	1	<p style="text-align: center;">5 1.4%</p>	<p style="text-align: center;">170 49.3%</p>	<p style="text-align: center;">97.1% 2.9%</p>
		<p style="text-align: center;">97.1% 2.9%</p>	<p style="text-align: center;">97.7% 2.3%</p>	<p style="text-align: center;">97.4% 2.6%</p>
	0	1		Target Class



Połączone metody
THz i IRT
Weryfikacja dla
danych
eksperymentalnych



Mapa lokalizacji defektów



Klasyfikacja dokonana przez
sieć
Dokładność 93,75%

Wnioski

Wnioski i dalsze prace

- Uzyskane wyniki wskazują na duży potencjał zastosowania technik modelowania numerycznego do generowania baz danych, które można skutecznie wykorzystać do analizy rzeczywistych wyników pomiarowych.
- Proste dodanie szumu znacznie poprawia skuteczność wykrywania defektów w rzeczywistych termogramach uzyskanych z pomiarów.
- Wyniki z modelu uogólnionego użyte do uczenia sieci typu LSTM pozwalają na zwiększenie skuteczności i elastyczności metody.
- Połączenie IRT z innymi rodzajami inspekcji poprzez fuzję danych przy użyciu głębokich sieci neuronowych zapewnia znacznie lepsze wyniki niż przy użyciu jednej techniki.

Dziękuję za uwagę