

Zastosowanie uczenia maszynowego do obrazowania stanu zawilgocenia murów z wykorzystaniem tomografii impedancyjnej

Grzegorz Kłosowski



**Zastosowanie uczenia
maszynowego do
obrazowania stanu
zawilgocenia murów
z wykorzystaniem
tomografii impedancyjnej**

Rada Naukowa Wydawnictwa Politechniki Lubelskiej

Przewodnicząca:

Agnieszka Rzepka

Dyrektor CINT:

Katarzyna Weinper

Przedstawiciele Dyscyplin Naukowych Politechniki Lubelskiej:

Marzenna Dudzińska

Małgorzata Franus

Arkadiusz Gola

Beata Kowalska

Grzegorz Komarzyniec

Jarosław Latański

Tomasz Lipecki

Zbigniew Łagodowski

Lucjan Pawłowski

Natalia Przesmycka

Halina Rarot

Magdalena Rzemieniak

Arkadiusz Syta

Wydawnictwo Politechniki Lubelskiej:

Magdalena Chołojczyk

Karolina Famulska-Ciesielska

Katarzyna Pełka-Smętek

Zastosowanie uczenia maszynowego do obrazowania stanu zawilgocenia murów z wykorzystaniem tomografii impedancyjnej

Grzegorz Kłosowski



WYDAWNICTWO
POLITECHNIKI
LUBELSKIEJ

Lublin 2025

RECENZENCI:

dr hab. inż. **Mariusz Rząsa**, prof. OP (Politechnika Opolska)

dr hab. inż. **Radosław Wajman**, prof. PŁ (Politechnika Łódzka)

AUTOR:

dr inż. **Grzegorz Kłosowski**, ORCID: 0000-0001-7927-3674

Politechnika Lubelska – ROR: <https://ror.org/024zjzd49>

Redaktor prowadzący: **Magdalena Chołojczyk**

Korekta językowa: **Natalia Witek-Dąbrowska**

Skład i łamanie: **Łukasz Maj**

Projekt graficzny serii: **Łukasz Maj**

Zdjęcie na okładce i stronie przedtytułowej pochodzi ze strony internetowej www.freepik.com.

Jeśli nie wskazano źródła ilustracji, stanowi ona opracowanie własne autora.

Publikacja wydana za zgodą **Rektora Politechniki Lubelskiej**

ISBN: 978-83-7947-627-5 (wersja drukowana)

ISBN: 978-83-7947-628-2 (wersja elektroniczna)

DOI: 10.35784/9788379476282

Wydawca: Wydawnictwo Politechniki Lubelskiej
www.wpl.pollub.pl
ul. Nadbystrzycka 36C, 20-618 Lublin
tel. (81) 538-46-59



WYDAWNICTWO
POLITECHNIKI
LUBELSKIEJ

Książka udostępniona jest na licencji Creative Commons Uznanie autorstwa – na tych samych warunkach 4.0 Międzynarodowe (CC BY-SA 4.0)

Nakład: 50 egz.

Spis treści

Wykaz ważniejszych skrótów i symboli	9
1. Wstęp	11
1.1. Metody tomograficzne	13
1.2. Pomiary zawilgocenia murów	14
1.3. Cel i zakres pracy	20
2. Tomografia elektryczna w obrazowaniu wilgoci	23
2.1. ETI na tle innych typów tomografii	23
2.2. Matematyczne podstawy elektrycznej tomografii impedancyjnej	26
2.3. Problem prosty vs. problem odwrotny	27
2.4. Elektryczna tomografia impedancyjna	34
3. Wybrane metody modelowania problemu odwrotnego	43
3.1. Metoda Gaussa–Newtona	44
3.2. Regularyzacja Tikhonova	45
3.3. Metoda Total Variation	46
3.4. Maszyna wektorów nośnych (SVM)	47
3.5. Lasso i <i>elastic net</i>	49
3.6. Regresja liniowa i regresja logistyczna	50
4. Wykorzystanie sztucznych sieci neuronowych do rozwiązania problemu odwrotnego	53
4.1. Perceptron wielowarstwowy	55
4.2. Konwolucyjne sieci neuronowe	57
4.3. Rekurencyjne sieci LSTM	59
4.4. Wielokrotne sztuczne sieci neuronowe	63
5. Laboratoryjne badania wilgotności muru ceglanego	65
5.1. Mur ceglany jako obiekt badań	66
5.2. Tomograf hybrydowy	69
5.3. Elektrody ETI	77
5.4. Modelowanie fragmentu muru metodą elementów skończonych	81
5.5. Protokół pomiarowy	86
5.6. Generowanie syntetycznych danych uczących	87
5.7. Preprocessing – przygotowanie danych do trenowania, walidacji i testowania	91
5.7.1. Normalizacja danych	91
5.7.2. Zaszumianie danych pomiarowych	93
5.7.3. Odszumianie pomiarów rzeczywistych z wykorzystaniem autoenkoderów	94
5.7.4. Redukcja wzajemnie skorelowanych zmiennych wejściowych	96
5.7.5. Analiza wpływu zmiennych wejściowych na wyniki modelu	98

5.8. Warianty architektury sieci neuronowej	100
5.8.1. Sieć neuronowa z warstwą konwolucyjną	100
5.8.2. Sieć neuronowa z warstwą LSTM	106
5.8.3. Sieć neuronowa o strukturze wielogałęzistej	110
5.8.4. Wielokrotna sztuczna sieć neuronowa	118
5.9. Dobór metody uczenia maszynowego	128
5.10. Rekonstrukcje obrazów uzyskane dzięki danym symulacyjnym	133
5.11. Rekonstrukcje rozkładu zawilgoceń obiektu rzeczywistego	157
6. Badania wilgotności murów Złotej Bramy w Gdańsku	173
6.1. Modelowanie wielogałęzistej sieci neuronowej LSTM+CNN	175
6.2. Pomiary wilgotności zrealizowane na stanowisku nr 1	185
6.3. Pomiary wilgotności zrealizowane na stanowisku nr 2	192
6.4. Pomiary wilgotności zrealizowane na stanowisku nr 3	197
7. Uwagi końcowe i wnioski	203
7.1. Badania laboratoryjne muru ceglanego	204
7.2. Badania terenowe obiektu Złota Brama w Gdańsku	205
7.3. Kierunki dalszych badań	206
Literatura	209

Zastosowanie uczenia maszynowego do obrazowania stanu zawilgocenia murów z wykorzystaniem tomografii impedancyjnej

Przedmiotem rozważań zawartych w niniejszym opracowaniu jest porównanie i weryfikacja skuteczności wybranych metod transformacji pomiarów tomograficznych na obrazy. Badania koncentrują się na elektrycznej tomografii impedancyjnej (ETI) wykorzystanej jako metoda obrazowania rozkładów wilgoci wewnątrz ścian budynków. Zastosowano w nich zarówno metody deterministyczne, jak również nowoczesne metody oparte na uczeniu maszynowym. Badania prowadzone były w warunkach laboratoryjnych oraz w obiekcie historycznym Złota Brama w Gdańsku. Opracowano model hybrydowej, wielogłęziowej sieci neuronowej, za której pomocą dokonano transformacji pomiarów wilgotności zrealizowanych na trzech stanowiskach badawczych. Wykazano, że zastosowanie modelu wielogłęziowej sieci neuronowej LSTM+CNN w połączeniu z techniką tomografii ETI cechuje wysoka skuteczność. Pomiary walidacyjne potwierdziły dokładność rekonstrukcji tomograficznych, co jest dowodem efektywności i potencjału utylitarnej opisywanej metody.

Słowa kluczowe: badanie zawilgocenia, kontrola nieniszcząca, uczenie maszynowe, elektryczna tomografia impedancyjna, sieci neuronowe

Application of machine learning to masonry moisture condition imaging using impedance tomography

The subject of the considerations contained in this study is the comparison and verification of the effectiveness of selected methods of transforming tomographic measurements into images. The research centers on the application of electrical impedance tomography (ETI) as a technique for imaging moisture distributions within building walls. Both deterministic methods and modern methods based on machine learning were used in the research. The research was conducted in laboratory conditions and in the historical building of the Golden Gate in Gdańsk. A hybrid, multi-branch neural network model was developed, which was used to transform moisture measurements taken at three research stations. The research showed that the use of the multi-branch LSTM+CNN neural network model in combination with the ETI tomography technique is characterized by high effectiveness. Validation measurements confirmed the high accuracy of tomographic reconstructions, which is proof of the effectiveness and utilitarian potential of the described method.

Keywords: moisture testing, non-destructive inspection, machine learning, electrical impedance tomography, neural networks

Wykaz ważniejszych skrótów i symboli

CNN	– konwolucyjna sieć neuronowa (ang. <i>convolutional neural network</i>)
ETI	– elektryczna tomografia impedancyjna
ETP	– elektryczna tomografia pojemnościowa
FEM	– siatka elementów skończonych (ang. <i>finite element mesh</i>)
GN	– metoda Gaussa–Newtona
LARS	– ang. <i>least angle regression</i>
Lasso	– ang. <i>least absolute shrinkage and selection operator</i>
LSTM	– sieć LSTM (ang. <i>long short-term memory</i>)
MES	– metoda elementów skończonych
MSE	– błąd średniokwadratowy (ang. <i>mean squared error</i>)
PSNR	– stosunek maksymalnej mocy sygnału do mocy szumu zakłócającego ten sygnał (ang. <i>peak signal-to-noise ratio</i>)
RMSE	– pierwiastek błędu średniokwadratowego (ang. <i>root mean squared error</i>)
SSIM	– wskaźnik podobieństwa strukturalnego (ang. <i>structural similarity index</i>)
SSN	– sztuczna sieć neuronowa
SVM	– maszyna wektorów nośnych (ang. <i>support vector machine</i>)
TV	– całkowita regularyzacja wariacyjna (ang. <i>total variation</i>)
UST	– tomografia ultrasonograficzna (ang. <i>ultrasound tomography</i>)
b	– obciążenie, czyli tzw. bias
ε	– szerokość pasma „bez kary” wokół funkcji regresji
λ, C	– parametry regularyzacji
$\mathbf{h}^{(e)}$	– wartości elementów skończonych macierzy przewodnictwa
$L1$	– regularyzacja Lasso
$L2$	– regularyzacja grzbietowa
γ	– rozkład przewodności
μ	– średnia wartość danej cechy w zbiorze danych
$R_{T\hat{y}}$	– wskaźnik korelacji Pearsona
σ_{rec}	– wektor zrekonstruowanych wartości przewodności elektrycznej
σ	– przewodność elektryczna [S/m]
T_i	– rzeczywista (wzorcowa) wartość i -tego elementu skończonego
\mathbf{T}	– operator transformacji wektora lub macierzy
\mathbf{U}	– pomiarowy wektor napięcia [V]
ψ	– rozkład potencjału elektrycznego [V]
\hat{y}_i	– zrekonstruowana wartość i -tego elementu skończonego
ω	– częstotliwość kątowna [rad/s]
Ω	– region

1. Wstęp

Zawilgocenia murów to poważny problem, który jest związany z eksploatacją budynków i budowli. Jednocześnie diagnostyka stanu zawilgocenia murów od wielu lat stanowi wyzwanie dla naukowców i inżynierów [50]. Wilgoć obecna wewnątrz ścian może być powodem wielu niekorzystnych zjawisk o charakterze techniczno-konstrukcyjnym, ekonomicznym i społecznym [74]. Zawarta w ścianach woda w temperaturach ujemnych zamarza, co powoduje przyspieszoną erozję murów i osłabia parametry wytrzymałościowe konstrukcji budynku [127]. Taka sytuacja przyczynia się do skrócenia okresów eksploatacji budynków między remontami, a w skrajnym przypadku może być powodem katastrofy budowlanej. Innym negatywnym skutkiem zawilgocenia budynków jest przyspieszony rozwój pleśni, drobnoustrojów i roztoczy, które mogą być przyczyną dyskomfortu, alergii, infekcji i innych chorób układu oddechowego u osób przebywających wewnątrz pomieszczeń [67, 126]. Wilgoć pogarsza termoizolacyjność budynków, co negatywnie wpływa na energooszczędność.

Problem wilgoci gromadzącej się w ścianach budynków istnieje od czasów, gdy zaczęły powstawać budynki mieszkalne i gospodarcze [30]. Jednak potrzeba skutecznego zarządzania problemem wody penetrującej mury budynków wyraźnie zyskała na znaczeniu dopiero w ostatnich dekadach [30]. Powstało wiele norm i kodów budowlanych mających na celu wspieranie projektowania i procesu realizacji robót budowlanych w taki sposób, aby zminimalizować potencjalne problemy związane z wilgocią [7].

Monitoring murów jest nieodłącznym elementem diagnostyki budynków, gdyż dostarcza aktualnych danych na temat stanu zawilgocenia konstrukcji [51]. Stały nadzór nad tym parametrem umożliwia skuteczną interwencję w przypadku wykrycia wilgoci, co jest kluczowe dla utrzymania integralności i trwałości struktury [42, 54].

Metody badania wilgotności murów można podzielić na niszczące i nieniszczące. Do metod niszczących zalicza się między innymi próbki rdzeniowe i chemiczne analizy materiału. Choć są one dokładne, ich główną wadą jest konieczność uszkodzenia badanej struktury. Metody nieniszczące obejmują termografię, pomiar wilgotności za pomocą czujników dielektrycznych, mikrofalowych i innych, oraz metody akustyczne [15, 60, 146]. Wśród metod wykorzystujących czujniki wyróżnia się tomografia elektryczna jako nowoczesna, nieniszcząca metoda diagnostyczna, umożliwiająca obrazowanie dużych fragmentów murów, a nie pojedynczych punktów. Ta technika polega na pomiarze potencjału elektrycznego na powierzchni muru i rekonstrukcji obrazu wnętrza struktury, co pozwala na identyfikację obszarów zawilgocenia [139].

W tomografii kluczowe jest rozwiązanie problemu odwrotnego, polegającego na transformacji pomiarów na obrazy. Powyższy problem można rozwiązać matematycznymi metodami deterministycznymi, jednak w ostatnich latach są one coraz częściej wypierane przez modele oparte na uczeniu maszynowym [93, 98]. Sztuczne sieci neuronowe, jako pewna kategoria modeli opartych na sztucznej inteligencji, posiadają duży potencjał w zakresie skutecznego przetwarzania danych tomograficznych [52]. Dzięki zdolnościom modelowania złożonych zależności modele neuronowe są w stanie efektywnie radzić sobie z problemami źle postawionymi (ang. *ill-posed problems*), które są charakterystyczne dla problemów odwrotnych, pełniących kluczową rolę w tomografii [6, 34].

Biorąc pod uwagę wpływ czasu i stale rosnącą liczbę murowanych obiektów dziedzictwa kulturowego w Europie i na świecie, problem diagnozowania wilgotności murów jest ważnym i koniecznym elementem procesu ratowania zabytków. W odniesieniu do budynków i budowli niebędących obiektami zabytkowymi zbadanie stopnia zawilgocenia i rozkładu wilgoci w murach umożliwia prawidłowy dobór metody usunięcia zawilgoceń, co w konsekwencji zapewnia efektywność ekonomiczną procesów konserwacyjnych, remontowych i modernizacyjnych, a także zapobiega zbędnym wydatkom podczas przyszłej eksploatacji. Zastosowanie nowoczesnych technik tomograficznych w połączeniu z zaawansowanymi algorytmami uczenia maszynowego może znacząco zwiększyć efektywność i dokładność diagnostyki murów, co jest niezbędne dla efektywnego zarządzania i utrzymania

infrastruktury budowlanej w dobrej kondycji, ze szczególnym uwzględnieniem budynków historycznych [24, 53].

1.1. Metody tomograficzne

Słowo „tomografia” pochodzi od greckich słów *tomos* (cięcie, przekrój) i *graphia* (opis, obraz). Tomografia jest techniką badań obrazowych, która rewolucjonizuje zarówno medycynę, jak i wiele innych dziedzin – od przemysłu po ochronę środowiska [14, 71].

Tomografia umożliwia szczegółową analizę wnętrza badanych obiektów bez konieczności ingerencji w ich fizyczną strukturę. Tym samym pomiary tomograficzne nie zakłócają przebiegu procesów produkcyjnych. Jest to możliwe dzięki zastosowaniu różnorodnych technik, które pozwalają na rekonstrukcję obrazu i wewnętrznych szczegółów badanego obiektu, bazując na zewnętrznych pomiarach jego właściwości fizycznych. Metody tomograficzne wykorzystują zaawansowane algorytmy matematyczne do tworzenia obrazów przekrojów poprzecznych lub trójwymiarowych modeli, które odwzorowują strukturę wewnętrzną i stan badanego obiektu.

Tomografia znajduje zastosowanie w wielu sektorach przemysłu: chemicznym, farmaceutycznym, spożywczym, rafineryjnym, a także w geologii, archeologii i innych obszarach [124]. W medycynie pozwala na dokładną diagnozę i monitorowanie różnych stanów organizmu oraz chorób – od wczesnego wykrywania ciąży po badanie aktywności kory mózgowej [90]. W przemyśle tomografia znajduje zastosowanie w kontroli jakości produktów, monitorowaniu procesów produkcyjnych, a także w detekcji uszkodzeń infrastruktury. W ochronie środowiska pozwala na ocenę stanu zbiorników wodnych, analizę struktury wałów przeciwpowodziowych i zapór wodnych, kontrolę zanieczyszczeń gruntów czy planowanie bezpiecznych tras gazociągów.

W kontekście rosnących wymagań dotyczących monitorowania i kontroli procesów przemysłowych szczególnie istotne staje się wykorzystanie elektrycznej tomografii pojemnościowej (ETP, ang. ECT – *electrical capacitance tomography*), która może być stosowana do monitorowania przemian zachodzących we wnętrzu reaktorów przemysłowych oraz rurociągów [160]. Tomografia elektryczna, zarówno impedancyjna, jak pojemnościowa, jako technika nieinwazyjna umożliwia dwu- lub trójwymiarową wizualizację rozkładu parametrów elektrycznych badanego medium bez konieczności ingerencji w badany obiekt czy proces [113, 148]. Otwiera to nowe możliwości w badaniach

przepływu i koncentracji cieczy w materiale porowatym oraz rozkładu właściwości elektrycznych, szczególnie w sytuacjach, gdzie inne metody – jak tomografia optyczna, radiowa, ultradźwiękowa czy rentgenowska – okazują się niewystarczające [115, 141, 149, 151, 152].


1.2. Pomiary zawilgocenia murów

Wszystkie budynki i budowle są poddawane działaniu różnych czynników, które powodują ich erozję. Woda jest jedną z głównych przyczyn degradacji materiałów wchodzących w skład konstrukcji budowlanych. Mokre ściany i zawilgocone fundamenty są przyczyną nadmiernego rozwoju pleśni i grzybów. Zawilgocenia wpływają negatywnie na estetykę budynków. Przykładami są przebarwienia na ścianach i elewacjach, odpadające tynki oraz łuszczące się powłoki malarskie. Dotyczy to zwłaszcza konstrukcji budowanych według przestarzałych zasad. Jedną z głównych przyczyn zawilgocenia jest brak izolacji przeciwwodnej fundamentów, anachroniczna technologia i zły jakości materiały stosowane w budownictwie. Wilgoć w ścianach obniża ich trwałość [26, 167]. Zawilgocenie cegieł i zaprawy murarskiej znacznie obniża parametry wytrzymałościowe [32]. Jest to szczególnie istotne w przypadku zaprawy wapiennej, która na skutek wymywania węglanu wapnia przez wodę kruszy się i rozpada [32, 159]. W efekcie pogarszają się zarówno warunki eksploatacji, jak i bezpieczeństwo konstrukcyjne budynku [137, 164]. Innym istotnym problemem związanym z zawilgoceniem ścian jest negatywny wpływ na zdrowie mieszkańców [76]. Mikroklimat, który tworzy się w pomieszczeniach o dużej wilgotności, często prowadzi do rozwoju grzybów pleśniowych, które mogą powodować zaburzenia oddychania, alergie i zatrucia [2, 104].

W połączeniu z dziennymi wahaniami temperatury wilgoć ma największy wpływ na ogólną wytrzymałość i trwałość konstrukcji budowlanych [35]. Woda przenikająca z otoczenia do murów może mieć różne stany skupienia: stan stały (lód, śnieg), stan ciekły (deszcz, wilgoć kapilarna) lub stan gazowy (para wodna) [112]. Podsiąkanie kapilarne to zjawisko, w którym wilgoć wnika w głąb materiału poprzez małe kanaliki zwane kapilarami [8]. Powyższe zjawisko jest wykorzystywane przez rośliny do pobierania wody z gleby, ale może również determinować problemy zawilgocenia w budynkach lub infrastrukturze takiej jak mosty lub fundamenty. Większość wad konstrukcyjnych powstałych pod wpływem wilgoci, do których należą nieregularności w ułożeniu cegieł lub pęknięcia, nasila się z upływem czasu.

Badania wilgotności budynków mają na celu zmniejszenia zagrożeń związanych z wodą zalegającą wewnątrz murów. Badania tego rodzaju mogą pomóc w określeniu wpływu opadów atmosferycznych i wód gruntowych, wycieków i wilgoci pochodzącej z sieci wodociągowych i kanalizacyjnych oraz kondensacji pary wodnej.

Materiały budowlane – zarówno naturalne, jak i sztuczne (np. cegła lub beton) – są porowate, co zwiększa ich podatność na wchłanianie wody. Hydrofilowość materiałów porowatych przyczynia się do rozprzestrzeniania wody w ich wnętrzu. Migracja wilgoci często występuje w wyniku przenikania wody w ścianach i fundamentach obiektów zabytkowych, które mają bezpośredni kontakt z gruntem. Powodem jest brak poziomej lub pionowej przegrody oddzielającej ściany od wody w gruncie. Skutkuje to przemieszczaniem się soli rozpuszczonych w wodzie, które są przyczyną wielu problemów budowlanych. Na rysunku 1.1 przedstawiono najczęstsze źródła powstawania wilgoci wewnątrz ścian murowanych i ceglanych.



Rys. 1.1. Typowe źródła powstawania wilgoci w murach budynków

Opracowanie własne na podstawie koester.pl

Problem wilgoci w murach jest zagadnieniem złożonym, które wymaga rozpatrzenia wielu różnorodnych przyczyn powstawania tego zjawiska oraz skutków, jakie ono wywołuje. Wilgoć w murach może pochodzić zarówno ze źródeł zewnętrznych, jak i wewnętrznych, co znacząco komplikuje proces diagnostyki.

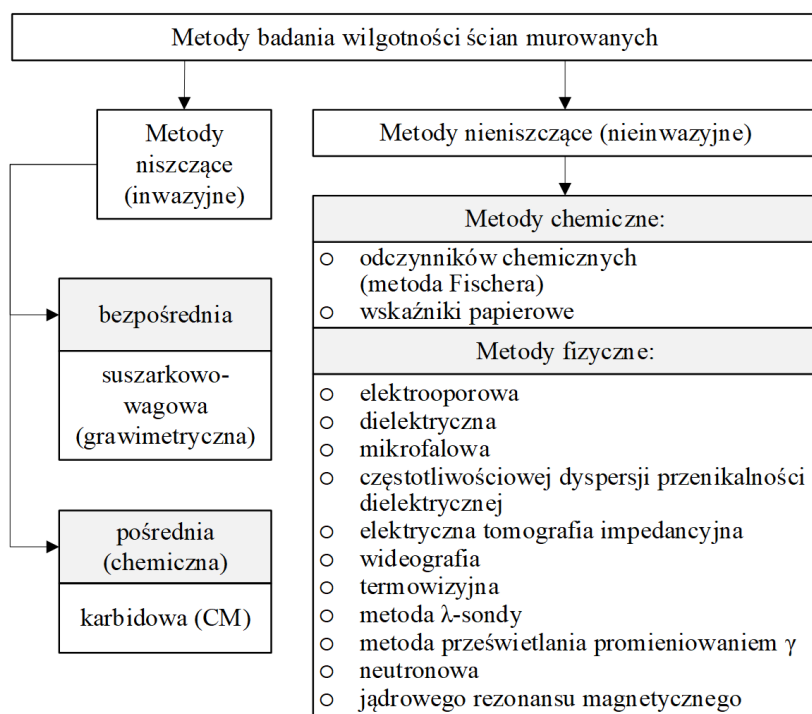
Wśród źródeł zewnętrznych dominujące miejsce zajmuje woda opadowa, która wpływa na powierzchnię muru poprzez bezpośrednie oddziaływanie deszczu. Woda może wnikać do murów przez nieszczelności w dachach. Może być efektem nasiąkliwości materiałów budowlanych, nieprawidłowego orynnowania oraz błędów przy realizacji obróbek blacharskich. Kolejnym źródłem zewnętrznym jest woda rozbryzgowa. Spadające krople, uderzając o powierzchnię ziemi w pobliżu budynku, mogą prowadzić do zawilgocenia dolnych partii ścian. Nie można także pominąć wilgoci pochodzącej z gruntu, która jest szczególnie problematyczna w przypadku wysokiego poziomu wód gruntowych lub gdy izolacja przeciwwilgociowa budynku jest uszkodzona. Woda przesiąkająca przez fundamenty i ściany piwnic z nieodpowiednio drenowanych terenów oraz wody gruntowe wywierające ciśnienie hydrostatyczne na konstrukcje budowlane stanowią kolejne przykłady zewnętrznych źródeł zawilgocenia.

Wewnętrznym źródłem wilgoci w murach jest przede wszystkim kondensacja wilgoci gromadzącej się na powierzchniach ścian pomieszczeń. Jest to zjawisko powstające w wyniku ochładzania powietrza do temperatury poniżej punktu rosy, co powoduje skraplanie wody zawartej w powietrzu. Kondensacją wilgoci szczególnie zagrożone są miejsca o zwiększonej wilgotności powietrza oraz pomieszczenia słabo wentylowane, takie jak łazienki, kuchnie lub piwnice.

Szczególne uwagę należy zwrócić na kondensację wody w kapilarach, która odnosi się do zjawiska kondensacji pary wodnej wewnątrz mikroskopijnych porów materiału budowlanego. Kondensacja kapilarna może zachodzić, gdy para wodna z powietrza wnika do mikroporów materiału, a następnie kondensuje się w wyniku różnic temperatur. To zjawisko może przyczynić się do zwiększenia zawartości wody w murze, co prowadzi do degradacji struktury oraz rozwoju szkodliwych mikroorganizmów.

Skuteczna ochrona przed wilgocią wymaga zastosowania kompleksowych rozwiązań, które uwzględniają zarówno izolacje przeciwwilgociowe i przeciwwodne, jak i systemy wentylacyjne zapobiegające kondensacji. Rozwiązania te powinny być dostosowane do specyfiki danego obiektu, z uwzględnieniem lokalnych warunków klimatycznych i hydrologicznych oraz charakterystyki zastosowanych materiałów budowlanych. Warunkiem skutecznego usunięcia wilgoci ze ścian jest jej właściwa identyfikacja. Badanie wilgotności murów jest więc kluczowym elementem diagnostyki stanu budynków, mającym na celu identyfikację obecności oraz rozkładu wilgoci w strukturach konstrukcji budowlanych. Istnieje wiele metod wykrywania i oceny stanu zawilgocenia, które najogólniej można podzielić na dwie kategorie. Pierwszą kategorią są metody niszczące, zwane inaczej destrukcyjnymi lub inwazyjnymi. Do drugiej

kategorii zaliczamy metody nieniszczące, czyli nieinwazyjne. Z uwagi na większą wartość aplikacyjną w praktyce preferowane są metody nieniszczące. Nieinwazyjność zyskuje na znaczeniu zwłaszcza w odniesieniu do budynków i budowli o wartości historycznej [65]. Badania wymagające wykonywania wierceń, które w oczywisty sposób naruszają obiekt badań, wymagają uzyskania formalnej zgody konserwatora zabytków lub innej osoby odpowiedzialnej. Również z tego powodu preferowane są takie metody badania wilgoci, które nie degradują obiektu badań. Zważywszy na fakt, że problem zawilgoceń w większości przypadków dotyczy budynków historycznych, będących pod ochroną konserwatora zabytków, wszelkie metody charakteryzujące się inwazyjnością są niedopuszczalne z przyczyn formalno-prawnych. Biorąc pod uwagę czynniki ekonomiczne, istnieje wyraźna potrzeba rozwoju metod w zakresie optymalizacji nieniszczących technik pomiarów i identyfikacji wilgoci w murach [47, 49]. Celem jest minimalizacja kosztów i skrócenie czasu wykonywania pomiarów przy jednoczesnym dążeniu do maksymalizacji skuteczności procesu pomiarowego. Na rysunku 1.2 przedstawiono klasyfikację metod wykorzystywanych w badaniach zawartości wilgoci w murach z podziałem na metody niszczące i nieniszczące [128].



Rys. 1.2. Podstawowe metody pomiaru wilgotności murów

Aby dokładnie określić procentową zawartość wody w badanej próbce muru, należy użyć inwazyjnej metody suszarkowo-wagowej. Metoda ta polega na pomiarze różnicy masy próbki muru przed odparowaniem i po odparowaniu wody z użyciem specjalnej suszarki. Pobraną próbkę należy zważyć na wadze laboratoryjnej o dużej dokładności. Następnie próbka jest umieszczana w specjalnej suszarce, która realizuje proces suszenia z zadaną temperaturą i określonym czasem suszenia. Suszenie polega na usunięciu wilgoci z próbki poprzez podgrzewanie powietrza. Po zakończeniu procesu suszenia próbka jest ponownie ważona na wadze laboratoryjnej. Różnica masy próbki przed wysuszeniem i po wysuszeniu jest równa masie wody zawartej wewnątrz próbki. Aby obliczyć wilgotność, można zastosować następującą formułę:

$$\text{wilgotność} = (\text{masa wilgoci}/\text{masa próbki}) \times 100\% \quad (1.1)$$

Poważną wadą tej metody, prócz jej inwazyjności, jest punktowy charakter pomiaru [66, 86]. Dokładną, określoną w procentach wilgotność można określić jedynie w pobranej próbce, która w istocie i tak nie jest już elementem badanego muru. Jedynie przez domniemanie można założyć, że w niewielkiej odległości od pobranej próbki wilgotność muru będzie do niej zbliżona. Chcąc określić wilgotność większego fragmentu ściany, należy dokonać wielu odwiertów, co jest w zasadzie niemożliwe w przypadku obiektów o historycznym znaczeniu kulturowym [48, 50].

Drugą metodą destrukcyjną jest metoda karbidowa (ang. *carbide mess*). Jest to tzw. metoda pośrednia, która wykorzystuje reakcję chemiczną karbidu wapnia z wilgocią zawartą w materiale w zamkniętej komorze. Za pomocą manometru dokonywany jest pomiar ciśnienia wydzielającego się acetylenu. Na tej podstawie obliczana jest wilgotność masowa badanego materiału budowlanego [86].

Wśród metod nieinwazyjnych wyróżniamy jeszcze metodę odczynników chemicznych (metoda Fischera), która należy do metod chemicznych, oraz metodę wskaźników papierowych zmieniających kolor w reakcji z wilgocią. Obie metody są łatwe w użyciu, ale podobnie jak inne metody, z wyjątkiem tomografii, mogą dostarczać jedynie informacji o lokalnej (punktowej) obecności wilgoci.

Wśród metod fizycznych znajdują się metody elektrooporowe, mierzące zmianę oporu elektrycznego materiału w zależności od ilości zawartej w nim wody, oraz dielektryczne, opierające się na pomiarze pojemności elektrycznej materiału, który zmienia się wraz ze zmianą zawartości wilgoci. Elektryczna

tomografia impedancyjna (ETI, ang. EIT – *electrical impedance tomography*) jest metodą wykorzystującą zależność opisaną prawem Ohma, czyli korelacją między napięciem i rezystancją prądu elektrycznego [4, 97, 121, 166]. Wzrost wilgotności materiału przewodzącego prąd powoduje wzrost jego konduktywności [3, 103].

Metoda mikrofalowa bazuje na absorpcji fal elektromagnetycznych przez wodę obecną w materiale, co umożliwia określenie wilgotności poprzez analizę zmiennych charakterystyk fal odbitych lub przenikających przez mur.

Częstotliwościowa dyspersja przenikalności dielektrycznej jest metodą opartą na pomiarze przenikalności dielektrycznej materiału przy różnych częstotliwościach. Powyższa metoda umożliwia określenie zawartości wilgoci oraz związanej z nią porowatości materiału, jednak z uwagi na prawdopodobne zasolenie zalegającej wody wymaga kalibracji przed każdym pomiarem *in situ*.

Wideoografia pozwala na obserwację migracji wilgoci w materiale w czasie rzeczywistym, podczas gdy termowizja wykorzystuje kamery termowizyjne do wykrywania różnic temperatur, które mogą wskazywać na obecność wilgoci. Metoda sondy λ (lambda), znana również jako pomiar przewodzenia ciepła, wykorzystuje fakt, że wilgotne materiały mają inne właściwości termiczne niż suche. Metoda prześwietlania promieniowaniem i neutronowa opierają się na absorpcji promieniowania przez wodę zawartą w badanym materiale, co pozwala na identyfikację obszarów zawilgoconych. W przypadku metody magnetycznego rezonansu jądrowego (ang. *nuclear magnetic resonance*) wykorzystuje się zdolność jąder atomowych w wodzie do absorpcji i reemisji energii elektromagnetycznej w polu magnetycznym, co pozwala na określenie rozkładu wilgoci wewnątrz materiału.

Każda z wymienionych metod ma swoje specyficzne zastosowania, zalety i ograniczenia. Wybór odpowiedniej metody badawczej zależy od wielu czynników, w tym od celu badania, rodzaju i stanu materiału, a także od dostępności sprzętu i warunków zastanych w miejscu dokonywania pomiarów. Metody nieinwazyjne są preferowane z powodu szybkości zastosowania i braku konieczności ingerencji w strukturę badanego obiektu. Ich wadą jest niska dokładność i punktowy charakter pomiarów. Natomiast metody destrukcyjne, mimo swojej inwazyjności i punktowości, dostarczają pewnych i dokładnych informacji o zawartości wilgoci, co jest niezbędne do wykonania precyzyjnej diagnostyki badanego obiektu. Warto zauważyć, że spośród wyżej wymienionych metod jedynie tomografia elektryczna umożliwia obrazowanie przekroju ściany 2-D lub przestrzennego fragmentu muru 3-D. Wszystkie pozostałe metody mają charakter jedynie punktowy.

1.3. Cel i zakres pracy

Podstawowym celem badań opisanych w niniejszym opracowaniu jest porównanie i weryfikacja wybranych metod transformacji pomiarów na obrazy tomograficzne [12]. Badania koncentrują się na elektrycznej tomografii impedancyjnej (ETI) wykorzystanej jako metoda obrazowania rozkładów wilgoci wewnątrz ścian budynków [19, 95]. W kontekście utylitarnym metodyka badań jest ukierunkowana na opracowanie metody algorytmicznej umożliwiającej zwiększenie dokładności i efektywności diagnostyki stanu zawilgocenia murów, co ma istotne znaczenie zarówno w obszarze ochrony zabytków, jak i codziennej eksploatacji budynków [16, 99].

Składająca się z siedmiu rozdziałów praca rozpoczyna się wstępem, który stanowi wprowadzenie w tematykę zawilgocenia murów. Omówiono w nim negatywne skutki tego zjawiska oraz znaczenie diagnostyki wilgotności dla utrzymania integralności konstrukcji budowlanych. W tej części opracowania przedstawiono również metody pomiarowe, podkreślając rosnące znaczenie nieniszczących technik diagnostycznych, do których zalicza się ETI.

Rozdział drugi poświęcono problematyce zastosowania elektrycznej tomografii impedancyjnej w obrazowaniu wilgoci. Opisano w nim podstawy teoretyczne ETI, umiejscawiając tę metodę na tle innych technik tomograficznych. Wskazano na unikalne zalety ETI w kontekście obrazowania wilgotności, omówiono matematyczne podstawy tej metody oraz zdefiniowano problemy prosty i odwrotny, które są kluczowe dla procesu rekonstrukcji obrazów tomograficznych [28, 110].

W rozdziale trzecim opisano sposób działania najbardziej popularnych metod rozwiązywania problemu odwrotnego w tomografii elektrycznej, z wyjątkiem sztucznych sieci neuronowych. Zaprezentowano zarówno podejścia matematyczne, jak również algorytmiczne, w szczególności takie jak metoda Gaussa–Newtona, regularyzacja Tikhonova, metoda Total Variation, maszyna wektorów nośnych (SVM), Lasso i elastic net, oraz regresja liniowa i logistyczna. Omówiono ich zastosowanie i przydatność w kontekście rozwiązywania problemów odwrotnych w ETI.

Rozdział czwarty opisuje wykorzystanie sztucznych sieci neuronowych do rozwiązania problemu odwrotnego w ETI. Przedstawiono tutaj różne architektury sieci neuronowych, takie jak perceptrony wielowarstwowe, konwolucyjne sieci neuronowe (CNN) oraz rekurencyjne sieci LSTM. Omówiono także sposób ich zastosowania w rekonstrukcji obrazów tomograficznych.

Rozdział piąty ma znaczenie szczególne, ponieważ opisuje laboratoryjne badania wilgotności muru ceglanego sztucznie zawilgoconego w warunkach laboratoryjnych. W badaniach wykorzystano prototypowy tomograf hybrydowy opracowany w Centrum Badawczo-Rozwojowym Netrix S.A. oraz specjalnie zaprojektowany do badań wilgotności murów, opatentowany zestaw 32 elektrod ETI. Omówiono proces modelowania fragmentu muru metodą elementów skończonych, zastosowany w badaniach protokół pomiarowy, generowanie syntetycznych danych uczących oraz przygotowanie danych do trenowania, walidacji i testowania. Szczególną uwagę poświęcono normalizacji danych pomiarowych, zaszumianiu i odszumianiu pomiarów rzeczywistych oraz analizie wpływu zmiennych wejściowych na wyniki modelu. Przedstawiono również różne architektury sieci neuronowych oraz dobór metody uczenia maszynowego. Wyniki rekonstrukcji obrazów uzyskane na podstawie danych symulacyjnych i rzeczywistych wykazały skuteczność proponowanej metody w diagnostyce zawilgocenia murów.

Rozdział szósty opisuje badania *in situ* w obiekcie historycznym Złota Brama w Gdańsku. W tym celu opracowano model hybrydowej, wielogłęziowej sieci neuronowej LSTM+CNN, za której pomocą dokonano transformacji pomiarów wilgotności zrealizowanych na trzech stanowiskach badawczych zlokalizowanych na terenie Złotej Bramy. Opisano znaczenie pomiarów walidacyjnych, które są kluczowe dla potwierdzenia dokładności i wiarygodności rekonstrukcji obrazów wilgotności przeprowadzonych w warunkach rzeczywistych. Pomiar walidacyjny pozwoliły na ocenę skuteczności proponowanych algorytmów w praktyce, co jest istotnym krokiem w kierunku ich wdrożenia w obszarze diagnostyki wilgotnościowej obiektów zabytkowych.

Opracowanie kończy rozdział siódmy, zawierający uwagi końcowe, w których podsumowano realizację badań oraz wskazano kierunki dalszych prac badawczych, podkreślając potencjał zastosowania zaawansowanych technik tomograficznych i algorytmów bazujących na uczeniu maszynowym w tomograficznej diagnostyce i konserwacji budynków.

2. Tomografia elektryczna w obrazowaniu wilgoci

W niniejszym rozdziale przedstawione zostaną najważniejsze aspekty elektrycznej tomografii impedancyjnej w kontekście obrazowania wilgoci. Część pierwsza umiejscawia ETI na tle innych technik tomograficznych, co pozwala na lepsze zrozumienie unikalnych zalet i ograniczeń tej techniki. Następnie omawiane są matematyczne podstawy tej metody, w tym między innymi takie pojęcia jak: przewodność, przenikalność i potencjał elektryczny oraz różnice między odmianami tomografii elektrycznej. Kolejnym krokiem jest szczegółowe omówienie problemów prostego i odwrotnego, które stanowią rdzeń procesu rekonstrukcji obrazów w ETI. Na koniec zaprezentowano praktyczne zastosowania elektrycznej tomografii impedancyjnej, podkreślając jej znaczenie w obrazowaniu wilgoci. Przedstawiono zależności między zawilgoceniem i rezystywnością, omówiono protokoły pomiarowe ETI oraz zaprezentowano graficzną interpretację problemu prostego i odwrotnego.

2.1. ETI na tle innych typów tomografii

Elektryczna tomografia impedancyjna (ETI) jest metodą o szczególnym potencjale w kontekście obrazowania rozkładów wilgotności murów [136]. Istnieje kilka powodów, które czynią tę metodę wyjątkowo przydatną w kontekście analizy materiałów budowlanych i diagnozowania problemów

związanych z wilgocią. Przewaga ETI wynika z ograniczenia elektrycznej tomografii pojemnościowej (ETP) związanego z niskim kontrastem dielektrycznym, który występuje w przypadku niewielkich różnic wilgotności. Może to skutkować mniejszą dokładnością w lokalizacji i kwantyfikacji obszarów zawilgoconych [159]. ETP opiera się na rekonstrukcji rozkładu przenikalności elektrycznej materiałów na podstawie pomiarów pojemności elektrycznej [140]. Ten rodzaj tomografii sprawdza się szczególnie w badaniach przemysłowych, zwłaszcza podczas monitorowania przepływów wielofazowych. ETI, wyznaczając konduktywność elektryczną na podstawie pomiarów napięcia, jest bardziej czuła na zmiany wilgotności, ponieważ woda znacząco wpływa na przewodnictwo elektryczne materiału. Inną przewagą ETI jest możliwość przeprowadzenia pomiarów nawet w przypadku, kiedy dostępna jest tylko jedna strona badanego obiektu. Innymi słowy: elektrody mogą być umieszczone z jednej strony ściany, co jest niemożliwe w przypadku tomografii pojemnościowej. ETP wymaga rozmieszczenia elektrosensorów naprzeciw siebie, co oznacza, że obiekt badań musi być dostępny co najmniej z dwóch stron. Stanowi to poważne ograniczenie, ponieważ w warunkach terenowych, podczas badania zawilgocenia zewnętrznych ścian budynków i piwnic, pomiary są możliwe jedynie od strony pomieszczeń.

Prawdopodobnie najbardziej popularną odmianą tomografii jest tomografia rentgenowska, znana także jako tomografia komputerowa. Ten rodzaj tomografii wykorzystuje promienie X jako czynnik penetrujący wnętrze badanego obiektu. Niewątpliwie tomografia promieni X swoją popularność zawdzięcza zastosowaniom medycznym, jednak ta technika znajduje zastosowanie również w sferze przemysłowej [163]. Jednocześnie ten rodzaj tomografii nie nadaje się do wykorzystania w zakresie detekcji rozkładów zawilgocenia w murach. Istnieją ku temu istotne powody, do których należą przede wszystkim: szkodliwość dla zdrowia, słaba zdolność promieniowania X do różnicowania poziomu wilgoci w materiałach budowlanych, wysoki koszt pomiarów oraz duże gabaryty systemu tomograficznego, co utrudnia lub uniemożliwia badania terenowe z powodu braku dostępu do miejsc wymagających pomiarów. Bardzo podobne powody sprawiają, że tomografia promieni γ (gamma), choć stosowana także w przemyśle, nie jest metodą wykorzystywaną w obrazowaniu wilgoci ścian budynków. Dodatkowym problemem są bardzo restrykcyjne regulacje prawne dotyczące wykorzystania źródeł promieniowania gamma. Powyższe wymogi oraz opisane wcześniej ograniczenia sprawiają, że stosowanie tomografii gamma w praktyce budowlanej jest nieefektywne i mało użyteczne [27].

Tomografia ultradźwiękowa (ang. UST – *ultrasound tomography*) jest skuteczna w wykrywaniu nieciągłości w strukturach, takich jak pęknięcia czy pustki [73]. Zasada działania tej metody jest oparta na fizycznych właściwościach fal dźwiękowych. W przypadku wilgotności murów metoda ta może być mniej efektywna, ponieważ rozprzestrzenianie się ultradźwięków nie jest bezpośrednio związane z obecnością wody w strukturze materiału. Ponadto UST wymaga bezpośredniego i bardzo dobrego kontaktu przetwornika dźwiękowego z badaną powierzchnią, co może być utrudnione w przypadku nierównych, porowatych powierzchni budynków.

Zasada działania tomografii indukcji magnetycznej (TIM, ang. *magnetic induction tomography*) opiera się na zmianach w polu magnetycznym spowodowanych zmianami przewodności materiału wewnątrz badanego obiektu [61]. Wilgoć wpływa głównie na właściwości elektryczne, takie jak przewodność i przenikalność materiałów budowlanych, a TIM nie jest tak czuła na te zmiany jak choćby ETI, która bezpośrednio mierzy bardziej skorelowane z poziomem wilgoci napięcie elektryczne.

Kolejną odmianą tomografii jest tomografia optyczna (ang. OT – *optical tomography*). Ten rodzaj tomografii opiera się na pomiarze absorpcji światła w badanym materiale, co może być skutecznie realizowane w powierzchniowych badaniach tkanek biologicznych. Penetracja światła w obrębie gęstych materiałów budowlanych jest jednak znacznie ograniczona, co obniża przydatność tej metody w diagnozowaniu wilgotności murów.

W świetle powyższych informacji elektryczna tomografia impedancyjna (ETI) okazuje się być najbardziej odpowiednią metodą do badania wilgotności murów. Głównym powodem jest jej wysoka czułość na obecność wody w badanym materiale. Woda, będąc dobrym przewodnikiem elektrycznym, znacząco wpływa na zmiany konduktywności, co pozwala na precyzyjne wykrywanie i kwantyfikowanie obszarów zawilgoconych. Jak już wcześniej wspomniano, ETI umożliwia uzyskanie przestrzennego obrazu rozkładu wilgotności w strukturze muru bez konieczności ingerencji w jego fizyczną formę. Jest to cecha kluczowa, zwłaszcza w przypadku budowli zabytkowych. Nieinwazyjność tej metody umożliwia przeprowadzanie wielokrotnych pomiarów bez ryzyka uszkodzenia badanego obiektu, a także pozwala na monitorowanie zmian wilgotności w czasie. W porównaniu z innymi technikami tomograficznymi, ETI zapewnia optymalny kompromis między dokładnością, bezpieczeństwem użytkowania oraz kosztami, co czyni ją metodą pierwszego wyboru spośród tomograficznych metod badania wilgotności murów.

2.2. Matematyczne podstawy elektrycznej tomografii impedancyjnej

Tomografia elektryczna stanowi metodę wizualizacji, która opiera się na wykorzystaniu różnic w elektrycznych właściwościach poszczególnych materiałów. W ramach tej techniki do badanego obiektu przyłączane jest źródło prądu, co prowadzi do stworzenia specyficznego rozkładu napięcia na jego powierzchni, a także stymuluje natężenie pola elektrycznego we wnętrzu obiektu. Dane zebrane w ten sposób poddawane są przekształceniu przez specjalistyczny algorytm, którego zadaniem jest rekonstrukcja obrazu wnętrza badanej struktury. Jednym z wyzwań związanych z tomografią elektryczną jest relatywnie niska rozdzielczość przestrzenna tworzonych obrazów [5]. Problemy z osiągnięciem lepszej rozdzielczości wynikają przede wszystkim z ograniczonej ilości dostępnych danych pomiarowych, nieliniowej natury przepływu prądu przez niejednorodny materiał oraz z niedostatecznej czułości urządzeń pomiarowych na zmiany przewodności w badanym obszarze [138]. Ponadto proces rekonstrukcji obrazu jest szczególnie podatny na różnorodne błędy modelowania, które często są efektem niedoskonałego odwzorowania lub nieprecyzyjnego określenia dodatkowych zmiennych modelu pomiarowego. W praktyce nawet niewielkie nieścisłości w zakresie odwzorowania kształtu badanego obiektu mogą prowadzić do znaczących błędów w rekonstruowanym obrazie, co dodatkowo komplikuje wykorzystanie tej techniki.

Tomografia elektryczna ma swoje teoretyczne podstawy w teorii Maxwella. Równania Maxwella stanowią fundament, na którym oparta jest konstrukcja projektowanych urządzeń wykorzystywanych w różnych odmianach tomografii elektrycznej. W tym kontekście wprowadza się pojęcie zespolonej admitancji, znanej również jako przewodność zespolona, którą można definiować wzorem:

$$\gamma = \sigma + i\omega\epsilon \quad (2.1)$$

gdzie σ oznacza przewodnictwo elektryczne, czyli konduktancję, ω jest częstotliwością kątową, a ϵ – przenikalnością elektryczną. Model matematyczny, będący odwrotnością problemu przewodnictwa elektrycznego wprowadzonego przez Calderona, ma następującą postać:

$$\nabla \cdot ((\sigma + i\omega\epsilon)\nabla\psi) = 0 \quad (2.2)$$

gdzie ψ reprezentuje potencjał elektryczny. W zależności od tego, czy dominuje składnik pojemnościowy, czy oporowy, co wyraża stosunek $\frac{\omega\epsilon}{\sigma}$, równanie (2.2)

może zostać uproszczone. Jeżeli przeważa składnik oporowy, to znaczy, kiedy $\frac{\omega\epsilon}{\sigma} \ll 1$, równanie (2.2) przyjmuje postać:

$$\nabla \cdot |\sigma \nabla \psi| = 0 \text{ (dla ETR)} \quad (2.3)$$

Natomiast gdy dominuje składnik pojemnościowy, czyli $\frac{\omega\epsilon}{\sigma} \gg 1$, równanie (2.2) sprowadza się do:

$$\nabla \cdot (\epsilon \nabla \psi) = 0 \text{ (dla ETP)} \quad (2.4)$$

W kontekście tomografii elektrycznej tomografia rezystancyjna (ETR) wykorzystuje składnik oporowy, podczas gdy elektryczna tomografia pojemnościowa (ETP) bazuje na składniku pojemnościowym. Elektryczna tomografia impedancyjna (ETI) łączy w sobie obie powyższe składowe – oporową i pojemnościową. Zatem ETI stanowi sposób na uwzględnienie zarówno oporu elektrycznego, jak i pojemności elektrycznej badanego obiektu, co pozwala na uzyskanie bardziej kompleksowego obrazu jego właściwości elektrycznych. W związku z powyższym, utożsamianie ETR z ETI jest podejściem błędnym, choć spotykanym w niektórych publikacjach.

2.3. Problem prosty vs. problem odwrotny

Zadaniem elektrycznej tomografii impedancyjnej jest stworzenie obrazu dystrybucji potencjału elektrycznego wewnątrz analizowanego obiektu, z uwzględnieniem specyficznych warunków granicznych oraz właściwości materiału, z którego składa się struktura badanego fragmentu. Ten proces może być skutecznie zrealizowany przez zastosowanie metody elementów skończonych (MES), stanowiącej podstawę wielu algorytmów deterministycznych wykorzystywanych do rozwiązania problemu prostego i odwrotnego w tomografii ETI. W omawianym przypadku kluczową rolę odgrywa równanie:

$$\nabla^2 \psi = 0 \quad (2.5)$$

z uwzględnieniem warunków granicznych Dirichleta i Neumanna, tj. $\psi = \psi_b$ oraz $\frac{\partial \psi}{\partial n} = 0$ [64]. Przez podstawienie do równania (2.5) wartości $\psi = \sigma \mathbf{E}$ oraz w dalszej części $\mathbf{E} = -\nabla \psi$ uzyskuje się zależność pomiędzy dystrybucją potencjału w polu elektrycznym \mathbf{E} analizowanego obiektu a przewodnością σ . Powyższą zależność wyraża formuła (2.6)

$$(\sigma + i\omega\epsilon)\nabla^2\psi + \nabla(\sigma + i\omega\epsilon) \cdot \nabla\psi = 0, \quad (2.6)$$

w której $\nabla^2\psi$ jest dywergencją gradientu $\nabla \cdot \nabla\psi = \frac{\partial^2\psi}{\partial x^2} + \frac{\partial^2\psi}{\partial y^2} + \frac{\partial^2\psi}{\partial z^2} = \nabla^2\psi$, czyli tzw. operatorem Laplace'a ψ . Wyrażenie $\nabla(\sigma + i\omega\epsilon)$ jest gradientem impedancji $\sigma + i\omega\epsilon$ punktu o współrzędnych (x, y, z) w przestrzeni. Tak sformułowane równanie, razem z warunkami granicznymi, definiuje elektrodynamiczny problem prosty. Zależność (2.6) łączy charakterystyki przewodzenia σ oraz przenikalności dielektrycznej ϵ badanego medium z potencjałem elektrycznym ψ , biorąc przy tym pod uwagę także wpływ częstotliwości prądu elektrycznego ω . σ odnosi się tutaj do przewodności elektrycznej materiału. Składnik $i\omega\epsilon$ reprezentuje część urojoną równania, związaną z przenikalnością dielektryczną ϵ oraz pulsacją prądu $\omega = 2\pi f$ mierzoną w radianach na sekundę, gdzie jest częstotliwością oscylacji mierzoną w hercach [Hz], a i jest jednostką urojoną. Sugeruje to, typowe dla elementów reaktancyjnych, przesunięcie fazowe między prądem a napięciem. Rozwinięta postać formuły (2.6) opisuje sposób, w jaki zespolona impedancja ośrodka wpływa na rozkład pola potencjalnego ψ . Pierwszy składnik, $(\sigma + i\omega\epsilon)\nabla^2\psi$, odnosi się do efektu samej zespolonej impedancji na Laplasjan potencjału. Drugi składnik, $\nabla(\sigma + i\omega\epsilon) \cdot \nabla\psi$, opisuje wpływ gradientu impedancji na gradient potencjału. W kontekście fizycznym powyższe równanie może być używane do opisu propagacji zmieniających się w przestrzeni fal elektromagnetycznych w ośrodkach, które mają zarówno przewodność, jak i przenikalność elektryczną. Zespolona impedancja determinuje zarówno sposób tłumienia fal, jak również zmianę ich fazy podczas przechodzenia przez różne materiały.

Warto zauważyć, że w tej sytuacji zarówno przewodnictwo σ , jak i spadki napięcia między elektrodami są zależne od częstotliwości. Gradient potencjału elektrycznego $\nabla\psi$ wskazuje na zmiany potencjału w przestrzeni, ukazując kierunek i wielkość największej zmiany, co pozwala na ustalenie charakterystyki pola elektrycznego [158]. Równanie (2.6) odgrywa ważną rolę w zrozumieniu sposobu, w jaki impedancja (obejmująca przewodność i przenikalność dielektryczną) wpływa na propagację pola elektrycznego w analizowanym ośrodku. W elektrycznej tomografii impedancyjnej (ETI) równanie (2.6) opisuje sposób, w jaki pole elektryczne penetruje badany obiekt, umożliwiając rekonstrukcję jego wewnętrznej struktury na podstawie zmierzonego rozkładu potencjału na powierzchni badanego obiektu. Rozwiązanie powyższego równania pozwala na ustalenie rozkładu funkcji stanu w badanym obszarze. Warto zauważyć, że równanie (2.6) można przekształcić do postaci zależności (2.2) γ .

Przypuśćmy, że wektor ψ reprezentuje zbiór potencjałów zarejestrowanych na zewnętrznej granicy analizowanego obiektu, natomiast γ symbolizuje zbiór parametrów charakteryzujących wewnętrzną strukturę obiektu, czyli jego rozkład przewodności. Powyższe dwa zbiory danych można ze sobą powiązać za pomocą pewnej nieliniowej funkcji transformacji \mathbf{T} . Macierz generowana przez tę transformację określa rozwiązania równania Laplace'a, które można przedstawić w formie $\psi_m = \mathbf{T}(\gamma)$.

W tym kontekście celem elektrycznej tomografii impedancyjnej (ETI) jest ustalenie takiej funkcji odwrotnej do \mathbf{T} , która umożliwiłaby przekształcenie wartości wektora ψ z powrotem na wektor γ :

$$\gamma = \mathbf{T}^{-1}\psi_m \quad (2.7)$$

Równanie (2.7) jest określane mianem problemu odwrotnego pola elektrycznego. Zazwyczaj rozmiar wektora ψ_m jest mniejszy niż rozmiar wektora γ , stąd uzyskanie jednoznacznego rozwiązania tego problemu nie jest możliwe.

Analiza pola elektrycznego w kontekście ETI wymaga rozwiązania określonego równania charakteryzującego to pole w danej przestrzeni. Problem prosty odnosi się do wyznaczenia rozwiązań równania Laplace'a dla zadanych granic i warunków brzegowych, co jest równoważne z odnalezieniem minimum funkcji:

$$I(\psi) = \int_{\Omega} \gamma (\nabla \psi)^2 d\Omega \quad (2.8)$$

Aby rozwiązać problem prosty metodą elementów skończonych, konieczne jest obliczenie wartości potencjałów w poszczególnych węzłach, co odpowiada punktowi stacjonarnemu funkcji $I(\psi)$. Punkt ten jest osiągany, gdy wartości węzłowe ψ doprowadzają do zerowania się wariacji funkcji, co można wyrazić jako

$$\delta I = \sum_{i=1}^n \frac{\partial I}{\partial \psi} \delta \psi_i = 0 \quad (2.9)$$

gdzie n to liczba węzłów siatki elementów skończonych. Równanie (2.9) jest prawdziwe pod warunkiem, że

$$\frac{\delta I}{\delta \psi_i} = 0, \quad i = 1, 2, \dots, n \quad (2.10)$$

Na skutek dyskretyzacji obszaru za pomocą metody elementów skończonych funkcję $I(\psi)$ można przedstawić jako sumę n osobnych funkcji, z których każda jest przypisana do jednego elementu skończonego:

$$I = \sum_{e=1}^n I^{(e)} \quad (2.11)$$

Równanie, które uwzględnia powyższą dyskretyzację w ramach MES, można zapisać jako

$$\delta I = \sum_{e=1}^{n_e} \delta I^{(e)} = 0 \quad (2.12)$$

gdzie $I^{(e)}$ zmienność zależy wyłącznie od wartości potencjałów w węzłach przypisanych do elementu e . Równanie (2.12) demonstruje, że pochodna funkcjonału I względem ψ_i dla każdego elementu równa się zero, czyli $\frac{\partial I^{(e)}}{\partial \psi_i} = 0$. Całość metody elementów skończonych przekłada się na zestawienie pochodnych funkcjonału $I(\psi)$ dla całej siatki elementów skończonych

$$\frac{\delta \mathbf{I}}{\delta \psi_i} = \sum_{j=1}^{n_e} \frac{\partial I^{(e)}}{\partial \psi_j} = 0 \quad (2.13)$$

co odpowiada równaniu

$$\frac{\partial \mathbf{I}}{\partial \psi} = \mathbf{0} \quad (2.14)$$

Jako wynik otrzymujemy układ równań, które łącznie opisują wartości węzłowych. W formie macierzowej, przy założeniu spełnienia warunków brzegowych, powyższy układ równań przyjmuje postać $\mathbf{Y}\psi = \mathbf{b}$, gdzie \mathbf{b} jest wektorem pomiarów.

Macierz \mathbf{b} , w większości przypadków, jest macierzą symetryczną, pasmową i rzadką. Wynika to z faktu, że tylko elementy będące w kontakcie z węzłem i będą miały swój udział w wyrażeniu $\frac{\partial I}{\partial \psi_j}$. Jeśli i -ty węzeł nie jest częścią e -tego elementu, wtedy wkład tego elementu w wyrażeniu $\frac{\partial I}{\partial \psi}$ jest równy zero. Zgodnie z powyższymi założeniami funkcja zdefiniowana dla dowolnego elementu ma postać

$$I^{(e)}(\psi^{(e)}) = \int_{\Omega^{(e)}} \gamma^{(e)} (\nabla \varphi^{(e)})^2 d\Omega^{(e)} \quad (2.15)$$

Po zróżniczkowaniu funkcji $I^{(e)}$ w stosunku do wartości funkcji ψ w węzłach elementu, otrzymuje się następujące wyrażenie:

$$\frac{\partial I^{(e)}}{\partial \psi_i} = \iint_{\Omega^{(e)}} \gamma^{(e)} \left[\frac{\partial \psi}{\partial x} \frac{\partial}{\partial \psi_i} \left(\frac{\partial \psi}{\partial x} \right) + \frac{\partial \psi}{\partial y} \frac{\partial}{\partial \psi_i} \left(\frac{\partial \psi}{\partial y} \right) \right] dx dy \quad (2.16)$$

Mając zależność

$$\frac{\partial \psi}{\partial x} = \left\{ \frac{\partial N_i}{\partial x}, \frac{\partial N_j}{\partial x}, \frac{\partial N_k}{\partial x} \right\} \{ \psi_i, \psi_j, \psi_k \} \quad (2.17)$$

oraz

$$\frac{\partial \psi}{\partial u_i} = N_i \quad (2.18)$$

$$\frac{\partial}{\partial \psi_i} \left(\frac{\partial \psi}{\partial x} \right) = \frac{\partial N_i}{\partial x} \quad (2.19)$$

i podstawiając (2.16) i (2.19) do równania (2.17), otrzymuje się następującą formułę:

$$\left\{ \frac{\partial I^{(e)}}{\partial \psi_i}, \frac{\partial I^{(e)}}{\partial \psi_j}, \frac{\partial I^{(e)}}{\partial \psi_k} \right\} = \left[\int_{\Omega^{(e)}} \gamma^{(e)} \left(\frac{\partial N_i}{\partial x}^2 + \frac{\partial N_i}{\partial y}^2 \right) d\Omega^{(e)}, \dots \right] \{ \psi_i, \psi_j, \psi_k \} \quad (2.20)$$

W formułach (2.17–2.20) reprezentuje funkcje kształtu w metodzie elementów skończonych (MES). W formule (2.20), N_i, N_j, N_k odnoszą się do funkcji kształtu dla poszczególnych węzłów elementu skończonego. Funkcje te są używane do interpolacji wartości pola wewnątrz elementu na podstawie wartości w jego węzłach. Oznaczając

$$h_{ij} = \int_{\Omega^{(e)}} \gamma^{(e)} \left(\frac{\partial N_i}{\partial x}^2 + \frac{\partial N_i}{\partial y}^2 \right) d\Omega^{(e)} \quad (2.21)$$

otrzymujemy następującą zależność:

$$\left\{ \frac{\partial I^{(e)}}{\partial \psi_i}, \frac{\partial I^{(e)}}{\partial \psi_j}, \frac{\partial I^{(e)}}{\partial \psi_k} \right\} = [h_{ii}, h_{ij}, h_{ik}; h_{ji}, h_{jj}, h_{jk}; h_{ki}, h_{kj}, h_{kk}] \{\psi_i, \psi_j, \psi_k\} \quad (2.22)$$

Równanie (2.13) zapisane w ogólnej formie macierzowej ma postać

$$\frac{\partial I^{(e)}}{\partial \psi_i} = \mathbf{h}^{(e)} \boldsymbol{\psi}^{(e)} \quad (2.23)$$

gdzie $\mathbf{h}^{(e)}$ reprezentuje wartości elementów skończonych macierzy przewodnictwa. Dla płaskiego elementu trójkątnego i, j -ty element macierzy stanu można opisać wzorem

$$h_{ij}^{(e)} = \frac{1}{4\Delta^2} \int_{\Omega^{(e)}} \gamma^{(e)} (b_i b_j + c_i c_j) d\Omega = \frac{1}{4\Delta} \gamma^{(e)} (b_i b_j + c_i c_j) \quad (2.24)$$

gdzie b_i i b_j , a także c_i i c_j są współczynnikami związanymi z pochodnymi funkcji kształtu względem współrzędnych przestrzennych. Funkcje kształtu N_i służą do reprezentacji wartości rozwiązania w obrębie elementu na podstawie jego wartości węzłowych. Pochodne tych funkcji po współrzędnych x i y (dla 2-D) są kluczowe do obliczania gradientów i innych właściwości fizycznych elementów skończonych.

Dla przestrzennego elementu czworobocznego równanie (2.24) przyjmuje postać

$$h_{ij}^{(e)} = \frac{ab}{4} \int_{-1}^1 \int_{-1}^1 \left[\left(\frac{2}{a} \right)^2 \frac{\partial N_i}{\partial \xi} \frac{\partial N_j}{\partial \xi} + \left(\frac{2}{b} \right)^2 \frac{\partial N_i}{\partial \eta} \frac{\partial N_j}{\partial \eta} \right] d\xi d\eta \quad (2.25)$$

Ponieważ macierz stanu jest symetryczna względem głównej przekątnej, to dla całego obszaru stosuje się następujące równanie

$$\frac{\partial I}{\partial \psi_i} = \mathbf{H} \cdot \boldsymbol{\psi} = \{0\} \quad (2.26)$$

gdzie $H_{ij} = \sum_{e=1}^{n_e} h_{ij}$. Macierz \mathbf{H} odzwierciedla relacje między potencjałami elektrycznymi w węzłach a przewodnictwem elektrycznym badanego obszaru. Elementy macierzy \mathbf{H} są konstruowane na podstawie równań różniczkowych determinujących dystrybucję pola elektrycznego i zależą od geometrii obszaru, rodzaju materiału oraz warunków brzegowych. Wektor $\boldsymbol{\psi}$ reprezentuje zbiorcze wartości potencjału elektrycznego w węzłach sieci MES. W analizie ETI powyższe wartości potencjału są wielkościami szukanymi, które chcemy ostatecznie ustalić w celu uzyskania rekonstrukcji obrazu przewodnictwa wewnętrznego badanego obiektu.

Agregacja wszystkich elementów prowadzi do utworzenia macierzy wielu równań o rozmiarach $n \times n$. W rozpatrywanym problemie zaimplementowano warunki brzegowe Dirichleta oraz Neumanna. Implementacja warunków brzegowych Dirichleta wymaga usunięcia z układu równań $\mathbf{H} \cdot \boldsymbol{\psi} = 0$ tych wartości potencjałów w węzłach, które są już znane. Przy wprowadzeniu do układu równań (2.26) zmiennych węzłowych zdefiniowanych przez warunki brzegowe wartości znajdujące się na głównej przekątnej macierzy \mathbf{H} muszą zostać odpowiednio dostosowane. Elementy na głównej przekątnej macierzy \mathbf{H} , odpowiadające konkretnym węzłom na krawędzi, są skalowane dużą wartością, natomiast odpowiedni składnik wektora współczynników \boldsymbol{b} jest zastępowany przez wartość zmiennej w węzle krawędziowym, skalowaną tym samym współczynnikiem o dużej wartości oraz wartością na przekątnej. Procedura ta jest powtarzana dla każdego węzła położonego na krawędzi. W rezultacie elementy macierzy \mathbf{H} , które nie zostały zmodyfikowane, mają wartości znacząco mniejsze w porównaniu z tymi, które przeszły modyfikację. Taka modyfikacja macierzy \mathbf{H} utrzymuje jej pierwotne charakterystyki, tj. strukturę pasmową, rzadkość i symetrię, jednak wpływa negatywnie na jej uwarunkowanie.

Warunki Dirichleta polegają na ustaleniu wartości funkcji (np. potencjału elektrycznego) na brzegu analizowanego obszaru. Oznacza to, że dla określonych punktów położonych na granicy domeny wartość poszukiwanego rozwiązania (np. potencjału elektrycznego) jest znana. W kontekście fizycznym może to odpowiadać sytuacji, w której wartość potencjału na brzegach przewodnika jest znana, a obliczenia dotyczą rozkładu potencjału wewnątrz badanego obiektu. Przykładami mogą być sytuacje, w których badany obiekt jest podłączony do źródła o stałym napięciu na określonej parze elektrod.

Warunki Neumanna dotyczą ustalenia wartości pochodnej funkcji normalnej do granicy obszaru, czyli odpowiadają określeniu strumienia fizycznej wielkości (np. przepływu prądu elektrycznego) przez granicę obiektu. W tym przypadku wartości funkcji bezpośrednio na brzegu nie jest znana. Znany jest natomiast gradient (pochodna) tej funkcji względem normalnej do powierzchni. Przykładowo, w elektryczności warunki Neumanna mogą oznaczać, że znamy gęstość prądu przepływającego przez krawędź obszaru, ale nie znamy wartości potencjału elektrycznego na tej krawędzi.

Obecnie modele matematyczne umożliwiające precyzyjne rozwiązanie problemu prostego w tomografii impedancyjnej są wykorzystywane do symulacyjnego generowania przypadków pomiarowych składających się z pomiarów i odpowiadających im obrazów (tomogramów). Tomogramy powstają dzięki przypisaniu kolorów do wartości konduktywności poszczególnych elementów skończonych. Dzięki pomiarom syntetycznym można w krótkim czasie uzyskać wiele przypadków uczących potrzebnych do trenowania modeli algorytmicznych opartych na uczeniu maszynowym. Zadaniem tych modeli jest rozwiązanie tomograficznego problemu odwrotnego, czyli transformacja pomiarów elektrycznych na obrazy rekonstruujące wnętrza badanych obiektów.


Istnieją metody klasyczne, które umożliwiają rozwiązanie problemu odwrotnego w sposób matematyczny, jednak dają one gorsze rezultaty w porównaniu z metodami algorytmicznymi wykorzystującymi uczenie nadzorowane.

2.4. Elektryczna tomografia impedancyjna

Prowadzone wcześniej badania wykazały, że oporność elektryczną można wykorzystać do określenia wilgotności ścian betonowych i murowanych. W badaniach potwierdzono istnienie korelacji między różnymi poziomami wilgoci zalegającej wewnątrz porowatych materiałów budowlanych a wartością wskaźnika określającego rezystancję. Ściana wykonana z cegły i ściana z lekkiego bloczka betonowego mają podobne własności elektryczne. W takich materiałach wraz ze spadkiem poziomu wilgoci spada również opór elektryczny. Niewielka zmiana rezystancji może być skutkiem zmiany poziomu zawilgocenia wewnątrz badanego obiektu. Istniejące metody wykrywania wilgoci w ścianach betonowych i ceglanych są obarczone wadami. Jak już wcześniej wspomniano, podstawową wadą jest punktowy charakter pomiarów. Kolejną niedogodnością jest konieczność uszkodzenia muru w celu pobrania próbek (metody niszczące). Metody nieniszczące mają również charakter punktowy

i nie są w stanie sondować głębiej niż na kilka centymetrów w głąb muru. Skuteczny zasięg elektrycznej tomografii impedancyjnej jest wielokrotnie większy. Choć trudno jest to jednoznacznie określić, może on wynosić nawet 50 cm. Na rysunku 2.1 przedstawiono zależności między rezystywnością elektryczną a procentowym zawilgoceniem czterech próbek betonu. Próbki różniły się składem mieszanki betonowej wykorzystanej do ich wykonania, a w szczególności stosunkiem wody do cementu wyrażonym współczynnikiem w/c . Jak widać, we wszystkich czterech przypadkach istnieje wyraźna zależność między zawilgoceniem a rezystywnością. Prócz tego można zauważyć, że wraz ze wzrostem współczynnika w/c rezystywność betonu maleje.

Zasada działania tomografu wiąże się nierozdzielnie z koniecznością rozwiązania problemu odwrotnego. W przypadku tomografii elektrycznej powyższy problem jest opisany funkcją pola elektrycznego. Mówiąc precyzyjniej, pole, o którym mowa, dotyczy problemu odwrotnego identyfikacji, optymalizacji lub syntezy, w którym parametry opisujące pole elektryczne są ustalane na podstawie posiadania pewnych informacji specyficznych dla tego pola. Problemy odwrotne charakteryzują się trudnością i niepewnością, ponieważ z reguły nie posiadają jednoznacznych rozwiązań i są źle uwarunkowane (inaczej – źle postawione). Przyczyną jest zazwyczaj niedostateczna ilość informacji wejściowych (zmiennych niezależnych, argumentów funkcji), które dodatkowo mogą być wzajemnie sprzeczne lub liniowo zależne (skorelowane).



Rys. 2.1. Zależności między rodzajem betonu, jego zawilgoceniem i rezystywnością [33]

Jeżeli ilość danych wejściowych jest niewystarczająca do uzyskania jednoznacznego rozwiązania problemu odwrotnego, mówi się o zadaniach nieokreślonych, natomiast w przypadku nadmiaru informacji – o zadaniach nadokreślonych. Z problemem odwrotnym mamy do czynienia w sytuacji, gdy brakuje pewnych informacji dotyczących rozpatrywanego obszaru, np. gdy nieznane są warunki brzegowe. Deficyt informacji uniemożliwia zastosowanie modelu matematycznego rozwiązującego problem prosty. Aby uzyskać jednoznaczne rozwiązanie, tym samym rozwiązać problem prosty, potrzebna jest dodatkowa informacja, np. dotycząca rozkładu potencjału pola elektrycznego. Rodzaj brakujących informacji często wykorzystuje się jako kryterium podziału problemów odwrotnych. Podział ten uwzględnia fizyczne parametry badanego obiektu. Przykładowy problem odwrotny może być tak nazwany z uwagi na brak następujących składowych modelu: warunków brzegowych, funkcji źródłowej, geometrii obszaru lub czynników materiałowych. Przedstawiona systematyka wskazuje na złożoność i wielowymiarowość problemów odwrotnych w kontekście pola elektromagnetycznego, ujawniając szerokie spektrum aspektów, które należy wziąć pod uwagę przy ich rozwiązywaniu.

W analizie numerycznej tomograficznego problemu odwrotnego zazwyczaj wykorzystuje się metodę elementów skończonych (MES) lub metodę elementów brzegowych (MEB) [143]. W języku angielskim metoda elementów skończonych określana jest skrótem FEM (*finite element method*). Tym samym skrótem określa się także siatkę elementów skończonych (ang. FEM – *finite element mesh*).

Choć obie metody mają za zadanie przekształcenie danych pomiarowych na obrazy przedstawiające rozkład konduktywności wewnątrz obiektu badań, różnią się one zasadniczo zarówno pod względem teoretycznym, jak i praktycznym. Metoda elementów skończonych (MES) polega na dyskretyzacji całego obszaru badanego obiektu na mniejsze, łatwiejsze do analizy elementy – piksele lub woksele. Ta metoda wymaga określenia tzw. parametru materiałowego dla każdego z tych elementów, co pozwala na szczegółową analizę rozkładu pola elektrycznego wewnątrz całego obszaru badanego. MES jest szczególnie użyteczna w przypadkach, gdy heterogeniczność właściwości elektrycznych badanego obiektu jest znacząca i gdzie zmiany w tych właściwościach są rozłożone w całej jego objętości.

Z kolei metoda elementów brzegowych (MEB) skupia się na dyskretyzacji jedynie powierzchni badanego obiektu. W przypadku analizy przestrzennej takie podejście umożliwia zredukowanie problemu trójwymiarowego do dwóch wymiarów. W MEB obliczenia są przeprowadzane tylko na zewnętrznej

powierzchni obiektu, co znacząco redukuje liczbę wymaganych obliczeń w porównaniu z MES. Metoda ta jest efektywna, gdy rozkład impedancji wewnątrz obiektu jest relatywnie jednorodny, a zainteresowanie badacza koncentruje się na zmianach zachodzących na jego obrzeżach.

Różnice między MES a MEB mają zasadnicze znaczenie dla aplikacji tych metod w ETI. MES, ze względu na swoją zdolność do modelowania złożonych heterogeniczności wewnątrz obiektu, jest preferowana w aplikacjach wymagających wysokiej rozdzielczości i dokładności w całej objętości, jak na przykład w zastosowaniach medycznych do monitorowania funkcji płuc czy też diagnozowania nowotworów, a także w zastosowaniach ETI obejmujących obrazowanie wilgoci wewnątrz murów. Z kolei MEB znajduje zastosowanie w sytuacjach, gdzie obliczenia muszą być przeprowadzane szybko i gdy zainteresowanie koncentruje się na zmianach powierzchniowych, niesięgających głęboko do wnętrza obiektu.

Z uwagi na dynamiczny rozwój technologii informatycznych obniżających koszt operacji obliczeniowych MES jest obecnie jednym z najbardziej wszechstronnych narzędzi w analizie numerycznej i inżynierii. W kontekście elektrycznej tomografii impedancyjnej MES odgrywa kluczową rolę zarówno w rozwiązywaniu problemów prostych, jak i odwrotnych. Problem prosty w ETI dotyczy obliczenia rozkładu potencjału elektrycznego wewnątrz obiektu na podstawie znanych wartości przewodności i określonego rozkładu prądów na jego powierzchni. Natomiast problem odwrotny polega na odtworzeniu rozkładu przewodności wewnętrznej obiektu na podstawie pomiarów potencjału na jego powierzchni.

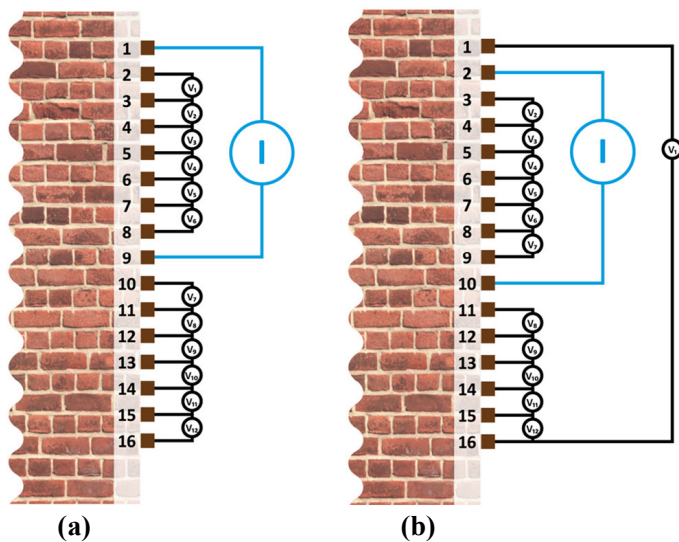
Model FEM w połączeniu z ETI umożliwia bardzo dokładne symulowanie rzeczywistych pomiarów napięcia z urządzeń ETI, biorąc pod uwagę efekty elektrod [18]. Matematyczny model symulacyjny uwzględnia efektywną impedancję kontaktową między elektrodami a ścianą budynku. Kluczowym elementem jest uwzględnienie zarówno warunków brzegowych, jak i prawa Kirchhoffa dotyczącego przepływu prądu. W praktyce oznacza to, że wykorzystując siatkę elementów skończonych, można precyzyjnie symulować sposób, w jaki prąd wprowadzany przez parę elektrod rozprzestrzenia się w badanym obiekcie, a następnie, na podstawie rozkładu przewodności wewnętrznej, obliczać spodziewane napięcia na pozostałych elektrodach.

FEM pozwala na dyskretyzację przekroju 2-D lub fragmentu 3-D badanego obiektu na bardzo małe elementy. W przypadku obrazów 2-D elementy siatki mają kształt trójkątów równobocznych, natomiast dla fragmentów 3-D są to czworokąty. Każdy z elementów skończonych ma przypisaną lokalną

wartość przewodności. Następnie, rozwiązując sformułowany w ten sposób problem wariacyjny, możliwe jest uzyskanie przybliżonego rozkładu potencjału w całym obszarze elementów skończonych objętych siatką. Takie podejście jest szczególnie użyteczne w kontekście ETI, gdzie rozkład przewodności wewnątrz obiektu jest nieznanym i musi być odtworzony na podstawie pomiarów zewnętrznych.

Wykorzystanie FEM w ETI umożliwia opracowanie metod umożliwiających odtwarzanie rozkładu przewodności wewnątrz obiektu na podstawie zewnętrznych pomiarów napięcia[38]. Problem odwrotny ETI jest skomplikowany i źle postawiony. Niewielkie zmiany w danych wejściowych mogą prowadzić do dużych różnic w wynikach. Pomimo tego FEM umożliwia stosowanie różnych strategii regularyzacji, metod deterministycznych i modeli uczenia maszynowego w celu stabilizacji rozwiązania.

Na rysunku 2.2 przedstawiono protokół pomiarowy wykorzystany w niniejszym opracowaniu. Dla 16 elektrod ($n = 16$) można uzyskać 12 niezależnych pomiarów napięcia (V). Istnieje 16 możliwości podłączenia źródła zasilania, ale ze względu na symetrię systemu akceptuje się tylko połowę z nich ($n/2 = 8$).



Rys. 2.2. Protokół pomiarowy ETI dla 16 elektrod: (a) poprzedni krok pomiarowy w cyklu, (b) następny krok pomiarowy w cyklu [21, 129]

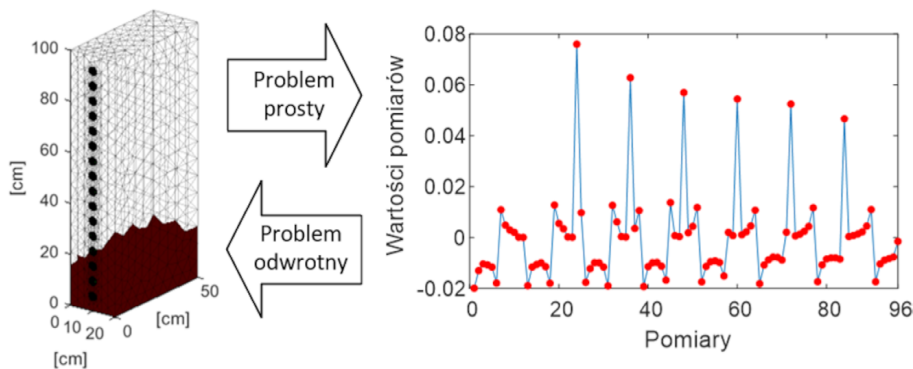
Danymi wejściowymi do algorytmu rekonstrukcji obrazu są pomiary napięcia zmierzone między sąsiadującymi parami elektrod. Pomija się przy tym

pomiary wykonane przy użyciu elektrod z przyłączonym źródłem zasilania z powodu nieznanymi wartości spadków napięcia między tymi elektrodami a badanym obiektem. Dla systemu $n = 16$ z elektrodami i dowolnym protokołem pomiarowym można uzyskać $n - 4 = 12$ niezależnych pomiarów. Tym samym pełna liczba mierzalnych napięć między sąsiadującymi elektrodami napięciowymi przy $n/2 = 8$ parach elektrod wynosi $(n - 4) \cdot (n/2) = 12 \cdot 8 = 96$. Metoda pomiaru napięć międzyelektrodowych przedstawiona na rysunku 2.1 odpowiada pierwszemu i drugiemu pomiarowi w cyklu 96 pomiarów. Dla kolejnych kroków pomiarowych następuje sekwencyjne przełączanie obwodu zasilającego i pomiarowego na sąsiadujące elektrody.

Dla systemu z $n = 32$ elektrodami można uzyskać $n - 4 = 28$ niezależnych pomiarów. Stąd pełna liczba możliwych do uzyskania niezależnych pomiarów napięć między sąsiadującymi elektrodami napięciowymi przy $n/2 = 16$ parach elektrod wynosi $(n - 4) \cdot (n/2) = 28 \cdot 16 = 448$.

Rozwiązanie problemu prostego umożliwia dokładne obliczenie wartości pomiarów zarejestrowanych na poszczególnych parach elektrod. Dzięki temu, rozwiązując problem prosty, można stosunkowo szybko wygenerować duże zbiory danych uczących dla modeli predykcyjnych, które mogą być następnie trenowane w celu rozwiązania problemu odwrotnego. Dane uczące składają się więc z wejść i wyjść dla modelu predykcyjnego. Zarówno wejścia, jak i wyjścia są wektorami liczb. Wejścia są pomiarami, stąd zwykle są to liczby rzeczywiste lub zespolone. Wyjścia są wartościami przewodnictwa elektrycznego poszczególnych elementów skończonych siatki FEM (ang. *finite element mesh*). W zależności od potrzeb wartości wektora wyjściowego mogą być binarne lub liczbowe – naturalne, rzeczywiste lub zespolone.

Rysunek 2.3 przedstawia graficzną interpretację problemu prostego i odwrotnego dla przykładowego pomiaru symulacyjnego. Siatka elementów skończonych obejmuje fragment muru o wymiarach $50 \times 20 \times 100$ cm (długość \times szerokość \times wysokość). Przedstawiona na rysunku siatka składa się z 5102 elementów skończonych. Ponieważ jest to siatka przestrzenna, elementami są czworościany, które określa się także mianem wokseli. Dobór elektrod, do których przyłożone jest źródło prądu, i ich kolejność podczas realizacji cyklu pomiarowego określa się mianem protokołu pomiarowego. Po lewej stronie widzimy fragment muru wpisany w siatkę FEM. Woksele przezroczyste odzwierciedlają obszary suche, natomiast woksele ciemne – obszary mokre. Do czoła ściany przyłożono 16 elektrod, które wykorzystano do zgromadzenia 96 pomiarów napięcia (sekwencja pomiarowa).



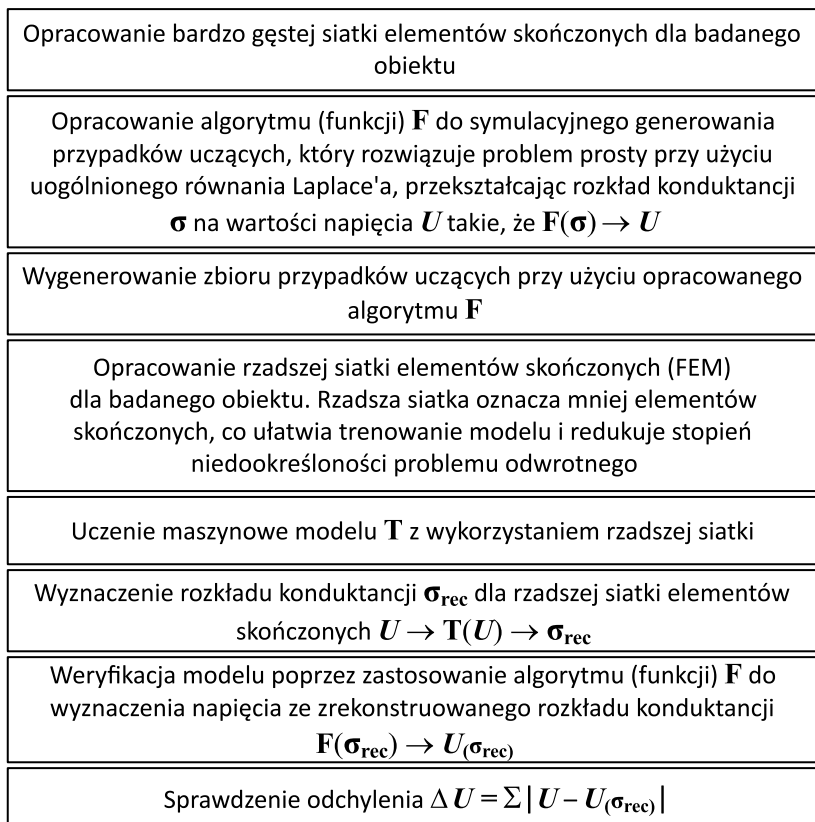
Rys. 2.3. Graficzna interpretacja problemu prostego i odwrotnego w ETI

Tak więc według rysunku 2.3 problem prosty jest transformacją $f(\mathbf{y}) \rightarrow \mathbf{U}$, gdzie \mathbf{y} jest wektorem 5102 wartości konduktywności poszczególnych wokseli FEM, natomiast \mathbf{U} jest 96 elementowym wektorem pomiarów napięć. Problem odwrotny jest zatem transformacją $f_{inv}(\mathbf{U}) \xrightarrow{\sim} \hat{\mathbf{y}}$, podczas której na podstawie pomiarów elektrycznych \mathbf{U} generowany jest zrekonstruowany wektor konduktywności $\hat{\mathbf{y}}$. Miarą jakości odwzorowania f_{inv} może być sumaryczne odchylenie $\Delta y = \sum_i |\mathbf{y} - \hat{\mathbf{y}}|$, gdzie jest licznikiem wokseli w siatce FEM. Wartości konduktywności można powiązać z odpowiednią paletą kolorów, co po nałożeniu na siatkę FEM skutkuje uzyskaniem obrazu rozkładu wilgoci wewnątrz analizowanego fragmentu muru.

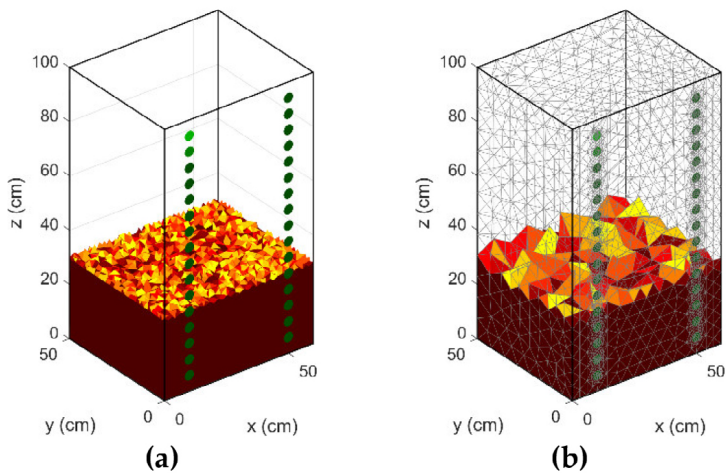
Rysunek 2.4 przedstawia proces generowania syntetycznych danych uczących wraz z ich weryfikacją. W tym celu można zastosować dwie siatki FEM – gęstą dla problemu prostego i rzadszą dla problemu odwrotnego.

Problem prosty można rozwiązać z dużą dokładnością, dlatego zwiększenie ilości argumentów funkcji $\mathbf{F}(\boldsymbol{\sigma}) \rightarrow \mathbf{U}$ nie zmniejsza jakości wyników. Przeciwnie, podział obiektu badań, którym jest fragment muru, na większą liczbę elementów skończonych umożliwia dokładniejsze oszacowanie pomiarów napięcia na elektrodach. Z kolei zastosowanie rzadszej siatki FEM w celu wygenerowania rozkładu konduktywności jako rezultatu rozwiązania problemu odwrotnego $\mathbf{U} \rightarrow \mathbf{T}(\mathbf{U}) \rightarrow \boldsymbol{\sigma}_{rec}$ zmniejsza poziom złożoności i niedookreśloności, a także ułatwia wytrenowanie sieci neuronowej [31]. Ostatecznie zalecane jest, aby ponownie wykorzystać algorytm generujący pomiary syntetyczne, podstawiając na jego wejściu zrekonstruowane rozkłady konduktancji $\mathbf{F}(\boldsymbol{\sigma}_{rec}) \rightarrow \mathbf{U}_{(\boldsymbol{\sigma}_{rec})}$. W ten sposób, obliczając różnicę między pomiarami uzyskanymi pierwotnie a pomiarami uzyskanymi na podstawie

rekonstrukcji $\Delta U = \sum_i |U - U_{(\sigma_{rec})}|$, można obiektywnie zweryfikować zarówno wytrenowany model, jak i deterministyczny algorytm generujący pomiary syntetyczne. Rysunek 2.5. przedstawia porównanie gęstej i rzadszej siatki FEM tego samego fragmentu muru [127].



Rys. 2.4. Proces generowania syntetycznych danych uczących umożliwiający jednoczesną weryfikację algorytmów problemu prostego i odwrotnego



Rys. 2.5. Przykładowe siatki FEM dla tego samego obiektu badań:
 (a) siatka o dużej gęstości elementów skończonych, odpowiednia do problemu prostego,
 (b) siatka o mniejszej gęstości, odpowiednia do problemu odwrotnego [127]

Pomimo wyzwań, dzięki swojej zdolności do nieinwazyjnego sondowania wnętrza obiektów na podstawie ich elektrycznych właściwości, tomografia elektryczna oferuje unikalną perspektywę do badań różnorodnych materiałów, otwierając nowe możliwości zarówno w diagnostyce przemysłowej, jak i w obszarze badań naukowych.

3. Wybrane metody modelowania problemu odwrotnego

Jak już wcześniej wspomniano, rozwiązanie problemu odwrotnego jest głównym wyzwaniem w procesie tomograficznej rekonstrukcji obrazu. Ogół metod umożliwiających rozwiązanie problemu odwrotnego można podzielić na cztery podstawowe grupy: metody deterministyczne, stochastyczne, topologiczne i metody oparte na uczeniu maszynowym. Należy zaznaczyć, że jest to podział ogólny i nie w pełni obiektywny. Pomimo tego może być uznany za uprawniony, ponieważ systematyzuje znane metody wg zrozumiałego klucza, a w literaturze nie ma jednoznacznie ustalonych kryteriów, które są uznawane za kanon obowiązujący. W tabeli 3.1 przedstawiono zestawienie metod umożliwiających rozwiązanie tomograficznego problemu odwrotnego z podziałem na grupy.

Tab. 3.1. Systematyka metod używanych w tomografii do rozwiązania problemu odwrotnego [25, 119]

Grupa metod	Przykłady metod
Metody deterministyczne	<ul style="list-style-type: none">• metoda Gaussa–Newtona [55, 58, 59]• regularyzacja Tikhonova [10, 62, 156]• regularyzacja Total Variation [147]• liniowa projekcja wsteczna (ang. <i>linear back projection</i>) [36]• metoda D-bar [107]• metoda perturbacyjna [113]• metoda warstwowa [29]• algorytm Kaczmarza [92]• algorytm Wexlera [150]• gradientowe metody optymalizacyjne [158]

Tab. 3.1. Systematyka metod używanych w tomografii do rozwiązania problemu odwrotnego [25, 119]

Grupa metod	Przykłady metod
Metody stochastyczne	<ul style="list-style-type: none"> • algorytmy ewolucyjne [170] • algorytmy rojowe [171] • algorytmy mrówkowe [45] • optymalizacja wielokryterialna [108]
Metody topologiczne	<ul style="list-style-type: none"> • metoda zbiorów poziomicowych (ang. <i>level set method</i>) [93] • pochodna materiałowa [155] • pochodna kształtu [138] • pochodna topologiczna [118]
Metody oparte na uczeniu maszynowym	<ul style="list-style-type: none"> • sztuczne sieci neuronowe, w tym: <ul style="list-style-type: none"> ◦ perceptron wielowarstwowy [120] ◦ sieci głębokiego uczenia (ang. <i>deep learning</i>) [11, 41, 70] ◦ sieci konwolucyjne (ang. <i>convolutional neural networks</i>) [153] ◦ sieci rekurencyjne, np. LSTM (ang. <i>long short-term memory</i>) [69, 169] ◦ autoenkodery [37] ◦ uczenie transferowe (ang. <i>transfer learning</i>) [68]
	<ul style="list-style-type: none"> • metody statystyczne, w tym: <ul style="list-style-type: none"> ◦ <i>k</i>-najbliższych sąsiadów (ang. <i>k-nearest neighbors</i>) [81] ◦ maszyna wektorów nośnych (SVM, ang. <i>support vector machine</i>) [56] ◦ Lasso (ang. <i>least absolute shrinkage and selection operator</i>) [154] ◦ elastic net [122] ◦ LARS (ang. <i>least angle regression</i>) [20, 133] ◦ regresja liniowa [57] ◦ regresja logistyczna [83, 84]

W dalszej części tego rozdziału opisano wybrane metody, które następnie zostały wykorzystane w badaniach stanowiących przedmiot niniejszego opracowania.

3.1. Metoda Gaussa–Newtona

W tomografii impedancyjnej do rekonstrukcji obrazu można stosować deterministyczną metodę Gaussa–Newtona, która wykorzystuje uogólnioną regularyzację Tikhonova [109]. W literaturze przedmiotu metoda ta znana jest również jako algorytm Gaussa–Newtona w formie uogólnionej. Podczas przeprowadzania analiz ilościowych można założyć, że badany obiekt jest polaryzowany prądem o niskiej częstotliwości. Wówczas właściwości elektryczne materiału można opisać za pomocą funkcji o wartościach rzeczywistych. W przypadku uogólnionego równania Laplace’a, składowa proporcjonalna do częstotliwości jest pomijana, a wspomniana funkcja może być utożsamiana z rzeczywistym przypadkiem admitancji izotropowej.

Rekonstrukcja wewnętrznego obrazu badanego obiektu wiąże się z określeniem globalnego minimum funkcji celu, które w rozpatrywanym przypadku definiowane jest następująco:

$$F(\sigma) = \frac{1}{2} \left\{ \|\mathbf{L}_1(\mathbf{U}_m - \mathbf{U}_s(\sigma))\|^2 + \lambda^2 \|\mathbf{L}_2(\sigma - \sigma^*)\|^2 \right\} \quad (3.1)$$

gdzie: σ jest wektorem przewodności, σ^* jest przyjętym a priori wektorem przewodnictwa reprezentującym znane właściwości elektryczne obiektu, \mathbf{U}_m jest wektorem napięć uzyskanych podczas pomiarów, $\mathbf{U}_s(\sigma)$ jest wektorem napięć otrzymanych za pomocą obliczeń numerycznych przy użyciu MES, \mathbf{L}_1 jest macierzą kwadratową, \mathbf{L}_2 jest macierzą regularyzacji, zwykle jednostkową, której zadaniem jest dyskretne przybliżenie wybranego operatora różniczkowego, a λ jest parametrem regularyzacji, przy czym $\lambda > 0$.

3.2. Regularyzacja Tikhonova

Wynikiem równania $\mathbf{u} = \mathbf{A}\mathbf{f} + \varepsilon$ poddanego regularyzacji za pomocą deterministycznej metody Tikhonova jest wektor transformacji $T_\alpha(\mathbf{u}) \in \mathbb{R}^n$, który minimalizuje wyrażenie (3.2) [106]

$$\|AT_\lambda(\mathbf{u}) - \mathbf{u}\|_2^2 + \lambda^2 \|T_\lambda(\mathbf{u})\|_2^2 \quad \lambda > 0 \quad (3.2)$$

w którym A jest macierzą, która przekształca model $T_\lambda(\mathbf{u})$ na rekonstruowane wyniki, \mathbf{u} jest wektorem danych pomiarowych (napięć), $T_\lambda(\mathbf{u})$ jest estymowanym rozwiązaniem problemu odwrotnego (wektor konduktywności), λ jest parametrem regularyzacji, a $\|\cdot\|_2$ oznacza normę euklidesową (L_2 -normę). Regularyzacja Tikhonova może być rozumiana jako kompromis między dwoma postulatami. Postulat pierwszy dotyczy minimalizacji wyrażenia $AT_\lambda(\mathbf{u}) - \mathbf{u}$. Postulat drugi określa potrzebę minimalizacji normy L_2 dla $T_\lambda(\mathbf{u})$.

Zastosowanie regularyzacji Tikhonova do rozwiązania problemu odwrotnego w ETI łagodzi typowe mankamenty związane z tego rodzaju problemami, a mianowicie niestabilność rozwiązań oraz złe postawienie problemu w sensie matematycznym. Regularyzacja Tikhonova pozwala na uzyskanie bardziej stabilnego i „wygładzonego” rozwiązania, co jest możliwe dzięki wprowadzeniu dodatkowego terminu kary, który penalizuje rozwiązania o dużej normie.

Rozważmy model liniowy, w którym określamy zależność między wektorem wejściowym \mathbf{X} a wektorem wyjściowym \mathbf{Y} za pomocą macierzy

transformacji \mathbf{A} . W problemach odwrotnych często jest więcej parametrów do estymacji niż dostępnych obserwacji, co może prowadzić do niestabilności rozwiązań. Aby temu zaradzić, stosuje się regularyzację Tikhonova.

Dla danych wejściowych \mathbf{X} , które są macierzą projektowania systemu zawierającą przykładowe prądy generowane przez elektrody i dla wektora napięć zmierzonych na powierzchni badanego obiektu \mathbf{Y} , macierz transformacji \mathbf{A} jest szacowana z wykorzystaniem regularyzacji Tikhonova w następujący sposób:

$$\mathbf{A}_{est} = \arg \min_{\mathbf{A}} \left\{ \|\mathbf{A}\mathbf{X} - \mathbf{Y}\|_2^2 + \lambda^2 \|\mathbf{A}\|_2^2 \right\} \quad (3.3)$$

gdzie λ jest parametrem regularyzacji określającym wpływ kary. W kontekście problemu odwrotnego ETI oznacza to konieczność poszukiwania takiej macierzy przekształcenia \mathbf{A} , która najlepiej przybliży dane wejściowe do wyjściowych poprzez minimalizację pewnej funkcji kosztu. Po dalszym przekształceniu otrzymujemy funkcję

$$\mathbf{A}_{est} = (\mathbf{X}^T \mathbf{X} + \lambda^2 \mathbf{I})^{-1} \mathbf{X}^T \mathbf{Y} \quad (3.4)$$

gdzie $\mathbf{X}^T \mathbf{X}$ jest macierzą kowariancji wejść, \mathbf{I} jest macierzą jednostkową odpowiedniej wielkości, a $\mathbf{X}^T \mathbf{Y}$ jest macierzą kowariancji między wejściem a wyjściem. W równaniu (3.4), parametr λ^2 jest mnożony przez macierz jednostkową \mathbf{I} , co dodaje dodatkową wartość na głównej przekątnej macierzy $\mathbf{X}^T \mathbf{X}$. Dzięki temu macierz $\mathbf{X}^T \mathbf{X} + \lambda^2 \mathbf{I}$ staje się lepiej uwarunkowana, co ułatwia jej odwracanie i pomaga uzyskać bardziej stabilne rozwiązania.

3.3. Metoda Total Variation

Załóżmy, że analizowany obiekt można podzielić na ograniczoną liczbę podobszarów o stałej przewodności, a każdy z tych obszarów jest zdefiniowany przez pewną funkcję. Total Variation jest deterministyczną techniką regularyzacji wykorzystywaną do rekonstrukcji obrazu wewnętrznego obiektu, który jest podzielony na skończoną liczbę niewielkich obszarów o stałej przewodności za pomocą metody elementów skończonych [23]. Standardowe metody, takie jak regularyzacja Tikhonova, często prowadzą do powstania rozmytego obrazu, który nie pozwala na dokładne określenie granic pomiędzy obszarami o różnych przewodnościach. Zastosowanie regularyzacji z wykorzystaniem metody Total Variation może skutecznie zapobiec temu

efektowi. Funkcję celu dla tak przedstawionego problemu można zdefiniować w następujący sposób:

$$F(\boldsymbol{\sigma}) = \frac{1}{2} \|\mathbf{U}_s(\boldsymbol{\sigma}) - \mathbf{U}_m\|^2 + \lambda \sum_{i=1}^N |\mathbf{R}_i \boldsymbol{\sigma}| \quad (3.5)$$

gdzie: $\boldsymbol{\sigma}$ jest wektorem przewodności elektrycznej ($M + 1$), $\mathbf{U}_s(\boldsymbol{\sigma})$ jest obliczonym numerycznie wektorem napięć ($P + 1$), \mathbf{U}_m jest wektorem napięć uzyskanym za pomocą tomografu ($P + 1$), N jest liczbą krawędzi siatki elementów skończonych (bez granic krawędzi), M jest liczbą elementów skończonych, P jest liczbą elementów w tabeli testowych napięć \mathbf{U}_m , \mathbf{R}_i jest wektorem liniowym w i -tej iteracji reprezentującym dyskretną aproksymację operatora gradientu. Gdy dana krawędź należy do dwóch różnych elementów skończonych, wektor \mathbf{R}_i jest określony wzorem:

$$\mathbf{R}_i = d_i [0, \dots, 0, 1, 0, \dots, 0, -1, 0, \dots, 0] \quad (3.6)$$

gdzie d_i jest długością i -tej krawędzi. Wektor \mathbf{R}_i składa się z M elementów, z których tylko dwie składowe przyjmują wartości różne od zera. Należy zauważyć, że termin regularyzacji zdefiniowany w ten sposób nie jest różniczkowalny w punktach, gdzie wyrażenie pod wartością bezwzględną wynosi zero.

W rozważanym przypadku idea rekonstrukcji obrazu opiera się na zastosowaniu metody pierwotno-wtórnej punktu wewnętrznego. Problem pierwotny definiowany jest jako:

$$\min_{\boldsymbol{\sigma}} \left(\frac{1}{2} \|\mathbf{U}_s(\boldsymbol{\sigma}) - \mathbf{U}_m\|^2 + \lambda \sum_{k=1}^N \|\mathbf{L}_i \boldsymbol{\sigma}\| \right) \quad (3.7)$$

gdzie macierz \mathbf{L}_i jest typu $N \times M$ i zawiera elementy niezerowe tylko w i -tym wierszu, natomiast $[\mathbf{L}_i]_{ab} = \delta_{ai} [\mathbf{R}_i]_b$, gdzie δ_{ai} jest symbolem (delta) Kroneckera.

3.4. Maszyna wektorów nośnych (SVM)

Maszyna wektorów nośnych (ang. SVM – *support vector machine*) należy do grupy statystycznych metod uczenia maszynowego. SVM używa funkcji jądra, aby przekształcić dane wejściowe w przestrzeń o wyższym wymiarze, co ułatwia ich linearną separację. Algorytm SVM zaimplementowany w Matlabie

(funkcja „fritsvm”) umożliwia wybór spośród trzech popularnych funkcji jądra: liniowej, wielomianowej i radialnej funkcji bazowej (ang. RBF – *radial basis function*). Funkcja jądra liniowego opisana jest wzorem

$$K(x, y) = x^T y \quad (3.8)$$

gdzie x i y są wektorami danych. Funkcja jądra wielomianowego opisana jest jako

$$K(x, y) = (x^T y + c)^d \quad (3.9)$$

gdzie c to stała, a d jest stopniem wielomianu. Funkcja RBF opisana jest wzorem

$$K(x, y) = \exp(-\gamma \|x - y\|^2) \quad (3.10)$$

w którym γ jest parametrem skalującym. Problem optymalizacji w SVM polega na minimalizacji funkcji straty (ang. *loss*),

$$L = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (3.11)$$

gdzie \mathbf{w} – wektor wag, ξ i ξ^* – zmienne pomocnicze, C – parametr regularyzacji, a n jest liczbą próbek. Model SVM po optymalizacji reprezentowany jest przez funkcję

$$f(x) = \mathbf{w}^T \phi(x) + b \quad (3.12)$$

gdzie \mathbf{w}^T – transponowany wektor wag, $\phi(x)$ jest funkcją mapującą cechy, a b symbolizuje obciążenie, czyli stałą (ang. *bias*). Dla kolejnego pomiaru x' , predykcja modelu SVM jest określona zależnością

$$y' = f(x') = \sum_{i=1}^n \alpha_i K(x_i, x') + b \quad (3.13)$$

w której α to mnożnik Lagrange’a, a K jest funkcja jądra. W implementacji oprogramowania Matlab dopasowanie parametrów modelu SVM wykorzystuje kilka kluczowych parametrów, takich jak *BoxConstraint*, *KernelScale* i *Epsilon* ϵ . Celem SVM jest skonstruowanie takiej funkcji $f(x)$, która jak najdokładniej przewidywa rzeczywistą wartość y dla wejścia x , minimalizując błąd predykcji i pozwalając na odchylenia mniejsze niż ϵ . *Epsilon* określa szerokość

pasma „bez kary” wokół funkcji regresji, w którym błędy nie są penalizowane. Parametr ten bezpośrednio wpływa na elastyczność modelu w kontekście dopasowywania danych treningowych. BoxConstraint C określa kompromis między utrzymaniem marginesu ε , a maksymalizacją marginesu między różnymi punktami danych. Wyższa wartość C skłania model do dokładniejszego dopasowania do danych uczących, co może jednak prowadzić do przeuczenia. Innymi słowy: C określa „twardość” marginesu błędu w modelu SVM. KernelScale (γ dla RBF) wpływa na funkcję jądra, umożliwiając modelowi obsługę nieliniowości. Dla jądra RBF, γ kontroluje „szerokość” dzwonu funkcji Gaussa, wpływając na złożoność modelu i jego zdolność do uchwycenia zależności w danych. SVM często wykorzystuje funkcje jądra do rzutowania danych wejściowych na przestrzeń o wyższym wymiarze, co ułatwia znalezienie liniowego separatora, którym dla regresji jest linia najlepszego dopasowania. Funkcja straty dla jądra RBF jest zdefiniowana jako

$$Loss(y, f(x)) = \max(0, |y - f(x)| - \varepsilon) \quad (3.14)$$

gdzie: y jest wyjściowym wektorem wartości referencyjnych, $f(x)$ jest wektorem wartości zrekonstruowanych, natomiast ε jest z góry określonym progmem tolerancji błędu.

3.5. Lasso i elastic net

Obie metody, *elastic net* i Lasso, należą do grupy metod statystycznych wykorzystujących uczenie maszynowe. *Elastic net* jest techniką regresji z regularyzacją, która łączy w sobie zalety dwóch innych metod: Lasso (ang. *least absolute shrinkage and selection operator*) oraz regresji grzbietowej (ang. *ridge regression*) [135, 168]. Metoda ta stosuje jednocześnie kary L_1 oraz L_2 , które są charakterystyczne odpowiednio dla Lasso i metody grzbietowej [89, 132]. Technika Lasso, będąca jedną z metod regularyzacji, umożliwia redukcję liczby predyktorów w modelu regresyjnym oraz wybór spośród predyktorów, które mogą być redundantne względem siebie [105]. W przypadku wybranej wartości parametru Lambda (λ), który jest parametrem nieujemnym, Lasso rozwiązuje problem opisany formułą

$$\min_{\beta_0, \beta} \left(\frac{1}{2N} \sum_{i=1}^N (y_i - \beta_0 - x_i^T \beta)^2 + \lambda \sum_{j=1}^p |\beta_j| \right) \quad (3.15)$$

gdzie: N – liczba obserwacji, y_i – odpowiedź na obserwację i , x_i – dane pomiarowe w postaci wektora wartości p przy obserwacji j , λ – dodatni parametr regularyzacji odpowiadający jednej wartości λ .

Parametry β_0 i β są odpowiednio skalarne i p -wektorowe. Dla α o wartości ściśle między 0 a 1 i dodatniego λ *elastic net* rozwiązuje problem regularyzacji określony zależnością

$$\min_{\beta_0, \beta} \left(\frac{1}{2N} \sum_{i=1}^N (y_i - \beta_0 - x_i^T \beta)^2 + \lambda P_\alpha(\beta) \right) \quad (3.16)$$

gdzie

$$P_\alpha(\beta) = \frac{(1 - \alpha)}{2} \|\beta\|_2^2 + \alpha \|\beta\|_1 = \sum_{j=1}^p \left(\frac{(1 - \alpha)}{2} \beta_j^2 + \alpha |\beta_j| \right) \quad (3.17)$$

Jeżeli $\alpha = 1$, metoda *elastic net* działa identycznie jak Lasso. Gdy α zbliża się do 0, metoda *elastic net* upodabnia się do regresji grzbietowej. Dla innych wartości α składnik kary $P_\alpha(\beta)$ interpoluje między normą L_1 parametru β a normą kwadratową L_2 parametru β .

3.6. Regresja liniowa i regresja logistyczna

Do grupy statystycznych metod uczenia maszynowego zaliczamy regresję liniową i regresję logistyczną. Zastosowany w niniejszym opracowaniu model regresji liniowej wykorzystany do rozwiązania problemu odwrotnego ETI można opisać zależnością

$$f(x) = x\beta + b \quad (3.18)$$

gdzie: β jest wektorem współczynników p , x jest wektorem wejściowym (zbiorem obserwacji) p , a b jest skalarnym odchyleniem modelu (czyli obciążeniem, ang. *bias*). Algorytm iteracyjny implementuje funkcję straty w postaci błędu średniokwadratowego (MSE, ang. *mean squared error*). Funkcja straty jest minimalizowana przy pomocy technik obliczeniowych takich jak np. stochastyczny spadek gradientu i jest określona zależnością

$$\ell[y, f(x)] = \frac{1}{2}[y - f(x)]^2 \quad \text{dla } y \in (-\infty, \infty) \quad (3.19)$$

gdzie: y reprezentuje wartość rzeczywistą, a $f(x) = x\beta + b$ jest prognozowaną wartością modelu.

Regresja logistyczna różni się od regresji liniowej głównie mechanizmem predykcji. Podczas gdy regresja liniowa modeluje bezpośrednio wartości ciągłe za pomocą liniowej kombinacji wejść, regresja logistyczna jest wykorzystywana do przewidywania prawdopodobieństwa przynależności do określonej kategorii (klasy), przez co jest odpowiednia dla problemów klasyfikacyjnych. Typową formułę matematyczną stosowaną w regresji logistycznej przedstawia wzór (3.20)

$$\sigma(x) = \frac{1}{1 + e^{-(x\beta + b)}} \quad (3.20)$$

w którym: $\sigma(x)$ jest funkcją logistyczną, β jest wektorem współczynników dla zmiennych predykcyjnych x , natomiast b oznacza wyraz wolny (ang. *bias*) [134]. W odróżnieniu od zależności liniowej $y = x\beta + b$, występującej w regresji liniowej, regresja logistyczna stosuje funkcję sigmoidalną σ , która ogranicza wynik do przedziału $(0,1)$, interpretowanego jako prawdopodobieństwo. Ponieważ regresja logistyczna, w odróżnieniu od liniowej, generuje na wyjściu klasyfikatory, w tomografii elektrycznej badającej zawilgocenie murów można za jej pomocą wyznaczać binarne wartości elementów skończonych siatki FEM [85]. Badania realizowane w ramach niniejszego opracowania wykazały, że lepsze rezultaty w ETI przynosi generowanie wartości elementów skończonych w postaci liczb rzeczywistych, co jest domeną problemów regresyjnych.

4. Wykorzystanie sztucznych sieci neuronowych do rozwiązania problemu odwrotnego

Szczególną grupą metod zaliczaną do uczenia maszynowego są sztuczne sieci neuronowe (SSN) [123, 142]. Sieci neuronowe są strukturami, które modelują funkcjonowanie ludzkiego mózgu, umożliwiając rozwiązywanie złożonych problemów o różnym charakterze [131]. Zainteresowanie strukturą mózgu i procesami zachodzącymi w jego wnętrzu doprowadziło do rozwoju modeli obliczeniowych znanych jako SSN. Za ich pomocą można między innymi rozpoznawać wzorce, prognozować, dokonywać segmentacji danych i obrazów, klasyfikować elementy zbiorów, wspomagać decyzje, tworzyć reprezentacje zbiorów danych itp. [13, 87, 111, 144].

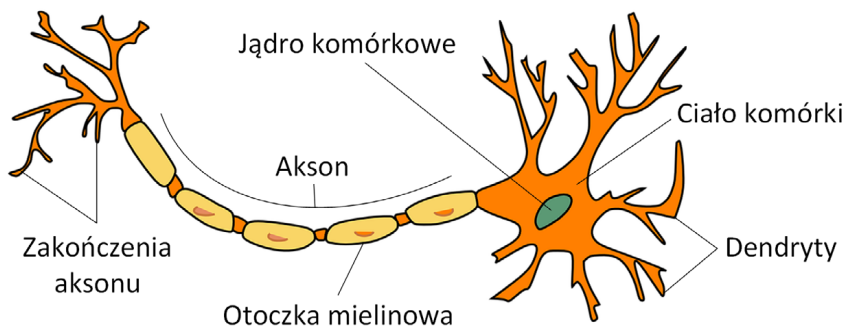
Wczesne prace nad sieciami neuronowymi sięgają lat 40. XX wieku. W tamtym czasie McCulloch i Pitts zbadali możliwości interkoneksji podstawowych komponentów modelu neuronu. W kolejnych latach naukowcy tacy jak Hebb zajmowali się badaniem praw adaptacji w systemach neuronowych. W 1958 roku amerykański psycholog Frank Rosenblatt wprowadził nazwę „perceptron” i opracował architekturę, która zyskała znaczną popularność. W roku 1960 Widrow i jego student Hoff przedstawili istotne uogólnienie algorytmu trenowania perceptronu znane jako metoda najmniejszych kwadratów (ang. *least mean square*).

W latach 70. XX wieku prace Grossberga, oparte na dowodach biologicznych i psychologicznych, przyczyniły się do wprowadzenia nowych architektur nieliniowych systemów dynamicznych. W roku 1982 John Hopfield zastosował

oryginalną, nieliniową strukturę dynamiczną ukierunkowaną na rozwiązywanie problemów optymalizacyjnych.

Badania nad SSN znacznie przyspieszyły w 1986 roku po opublikowaniu artykułu autorstwa Rumelharta, Hintona i Williama pt. *Learning Internal Representations by Error Propagation*, w którym opisano algorytm wstecznej propagacji błędów. Algorytm ten jest wciąż chętnie wykorzystywany do trenowania sieci neuronowych [116]. W tym samym okresie fiński profesor Teuvo Kohonen opisał architekturę SSN, która jest trenowana za pomocą nienadzorowanej procedury SOM (ang. *self-organizing map*). Algorytm SOM był szeroko stosowany w tzw. sieciach Kohonena, które zyskały popularność zarówno w zastosowaniach badawczych, jak i praktycznych. W późnych latach 80. zyskały popularność sieci radialne (ang. *radial basis function networks*). Sieci te, wraz z perceptronami wielowarstwowymi MLP (ang. multilayer perceptron – MLP), miały wpływ na pojawienie się maszyn wektorów nośnych (SVM).


Fascynacja morfologią i sposobem funkcjonowania ludzkiego mózgu doprowadziły do powstania modeli obliczeniowych określanych jako SSN. Szczególną rolę w powstaniu tych systemów odegrał sztuczny neuron, wzorowany na strukturze neuronu ludzkiego (rysunek 4.1).



Rys. 4.1. Model ludzkiego neuronu
Opracowanie własne na podstawie pixabay.com

4.1. Perceptron wielowarstwowy

Sztuczny neuron jest podstawową jednostką obliczeniową sztucznej sieci neuronowej w warstwowej strukturze klasycznego perceptronu wielowarstwowego. Rysunek 4.2 przedstawia budowę matematycznego modelu neuronu McCullocha–Pittsa, który jest podstawowym elementem SSN.




Rys. 4.2. Model sztucznego neuronu McCullocha–Pittsa [44]

Sztuczny neuron składa się z n wejść oznaczonych przez $\varphi_1, \varphi_2, \dots, \varphi_n$ które mają przypisane wagi w_1, w_2, \dots, w_n . Każde wejście φ_i jest mnożone przez odpowiadającą mu wagę w_i , a następnie wszystkie iloczyny są sumowane. Na koniec dodawana jest pewna stała b (tzw. obciążenie, ang. *bias*). W ten sposób powstaje wektor \mathbf{x} , będący sumą iloczynów wejść i wag oraz biasu. Uzyskana suma ważona jest przekształcana przez funkcję aktywacji $f(\mathbf{x})$, generując zbiór wyjściowy \mathbf{y} .

Bias b nie musi być indeksowany jak wagi w_1 , ponieważ jest on dodatkową stałą wartością, która przesuwca całą funkcję aktywacji w przestrzeni. W tradycyjnym modelu neuronu, który jest pokazany na rysunku 4.2, bias jest jednolity dla całego neuronu, niezależnie od liczby wejść.

Pojedyncze neurony mogą być ze sobą łączone, tworząc bardziej złożone struktury sieci neuronowych. Na rysunku 4.3 przedstawiono architekturę perceptronu wielowarstwowego złożonego z trzech warstw. Perceptron

wielowarstwowy jest jedną z podstawowych struktur jednokierunkowych sieci neuronowych. W tego rodzaju sieciach informacja przemieszcza się od wejść ku wyjściom.



Rys. 4.3. Struktura perceptronu wielowarstwowego

Warstwa wejściowa odróżnia się od pozostałych warstw, ponieważ nie zawiera neuronów, a jedynie neurony są zdolne przekształcać informacje, wykorzystując funkcje transferowe. Ostatnia warstwa (warstwa 3) jest warstwą wyjściową, zaś warstwy pomiędzy wejściami a warstwą wyjściową nazywane są warstwami ukrytymi. Sieci jednokierunkowe nie posiadają sprzężeń zwrotnych. Neurony w tej samej warstwie nie komunikują się między sobą, a każda z warstw ma własną funkcję aktywacji. Oprócz zastosowań badawczych SSN wykorzystywane są w wielu dziedzinach przemysłu i usług. W szczególności znajdują zastosowania w takich obszarach jak: modelowanie i sterowanie procesami, aproksymacja funkcji, rozpoznawanie wzorców i znaków, klasyfikacja i segmentacja obrazów, ocena kredytowa, kategoryzacja zbiorów, wykrywanie oszustw, ubezpieczenia, prognozowanie giełdowe, wspomaganie decyzji, predykcja kursów walut, przewidywanie awarii, rozpoznawanie twarzy itp.

Obecnie, w najnowszych strukturach sieci neuronowych, na wyjściu często stosuje się warstwę zawierającą neurony działające jak w perceptronie wielowarstwowym. Tego rodzaju warstwy są określane mianem gęstych, czyli *dense* (w języku Python) lub w pełni połączonych, czyli *fully connected* (w języku Matlab).

4.2. Konwolucyjne sieci neuronowe

Głównym zastosowaniem konwolucyjnych sieci neuronowych (CNN) jest klasyfikacja obrazów, gdzie ich zdolność do wydobywania i analizowania cech wizualnych sprawdza się w różnorodnych aplikacjach: od rozpoznawania twarzy, poprzez identyfikację usterek materiałowych, po analizę medycznych obrazów diagnostycznych [69, 72]. Jednak elastyczność tych sieci pozwala na dostosowanie ich architektury do specyficznych potrzeb, w tym do skutecznego rozwiązywania tomograficznych problemów regresyjnych [117]. Modyfikując architekturę sieci, na przykład przez implementację warstw jednowymiarowych (1-D) różnych rodzajów, takich jak konwolucyjne, poolingowe, czy w pełni połączone, możliwe jest dostosowanie procesu uczenia do specyfiki problemu regresyjnego. W ETI sieć neuronowa nie służy do klasyfikowania obrazów. Jej celem jest predykcja konduktancji dla poszczególnych elementów skończonych siatki FEM. Wartości te mogą być liczbami rzeczywistymi lub liczbami zespolonymi. Konwolucyjne modele regresyjne mogą być wykorzystywane do generowania obrazów rekonstrukcyjnych, co świadczy o wszechstronności i adaptacyjności CNN do zastosowań wykraczających poza tradycyjną klasyfikację obrazów.

CNN są szczególnym rodzajem głębokich sieci neuronowych, które wyróżniają się wykorzystaniem tzw. konwolucji (splotów) zamiast ogólnych operacji macierzowych w przynajmniej jednej z warstw [157]. W kontekście ETI konwolucja pozwala na efektywną analizę danych pomiarowych w kierunku poszukiwania ukrytych cech, co jest kluczowe dla dokładnej identyfikacji zmian konduktywności wewnątrz obiektu [22].

Rysunek 4.4 przedstawia przykładową architekturę sieci CNN przeznaczoną dla ETI. Pierwszą warstwą w omawianej architekturze CNN jest warstwa wejściowa, która przyjmuje wektor pomiarów napięć zmierzonych między elektrodami. Wektor wejściowy ma wymiar 96×1 . Zadaniem tej warstwy jest sprecyzowanie formatu danych wejściowych. Następnie dane przechodzą przez pierwszą warstwę konwolucyjną (Conv1D) z 32 filtrami o rozmiarze 3×1 każdy, której aktywacja dokonuje się za pomocą funkcji ReLU (ang. *rectified linear unit*). Funkcja ReLU, którą można zapisać jako $f(x) = (0, x)$, jest powszechnie stosowana ze względu na swoje właściwości pozwalające na efektywne uczenie się i redukcję problemu zanikającego gradientu. Jej zadaniem jest także wprowadzenie nieliniowości do modelu.

Po warstwie konwolucyjnej ma miejsce normalizacja wsadowa (ang. *batch normalization*), która stabilizuje i przyspiesza proces uczenia poprzez


normalizowanie wyjść z poprzedniej warstwy w taki sposób, aby wariancja była równa jeden, a średnia zero. Po warstwie normalizującej dane są przekazywane do warstwy MaxPooling1D, która z rozmiarem okna 2×1 redukuje wymiarowość danych, pozwalając na wychwycenie dominujących cech z wcześniejszych operacji konwolucji, tym samym zmniejszając ryzyko przeuczenia.

Kolejne warstwy Conv1D, zawierające odpowiednio 64 i 128 filtrów, również korzystają z funkcji aktywacji ReLU i są oddzielone warstwami normalizacji wsadowej. Te warstwy pozwalają na dalsze wydobywanie bardziej złożonych cech z danych, przygotowując grunt pod dokładniejszą rekonstrukcję konduktywności.

Po drugiej warstwie konwolucyjnej i kolejnej warstwie MaxPooling1D dane trafiają do warstw w pełni połączonych (Dense), gdzie pierwsza zawiera 1024 neurony, a druga 2048 neuronów. Obie wzmiankowane warstwy korzystają z funkcji aktywacji ReLU, normalizacji wsadowej oraz mechanizmu Dropout z prawdopodobieństwem 0,5.

Dropout jest techniką regularyzacyjną, która pomaga w zapobieganiu przeuczeniu przez losowe wyłączanie neuronów podczas treningu. Takie działanie utrudnia utrwalanie wzorców podczas uczenia. Ostatnia warstwa, zwana warstwą wyjściową, składa się z 3050 neuronów. Posiada ona liniową funkcję aktywacji. Warstwa wyjściowa ma za zadanie przekształcić wszystkie wyuczone cechy na ostateczny wektor wartości konduktywności, które następnie są interpretowane w kontekście rekonstrukcji obrazu za pomocą metody elementów skończonych (MES).

W złożonym, nieliniowym problemie odwrotnym ETI przedstawiona architektura CNN demonstruje sposób, w jaki tego rodzaju techniki przetwarzania informacji mogą być efektywnie wykorzystane do analizy i interpretacji danych pomiarowych. Dzięki takim strukturom możliwe jest osiągnięcie znacznych postępów w zakresie dokładności i rozdzielczości rekonstrukcji obrazów tomograficznych.



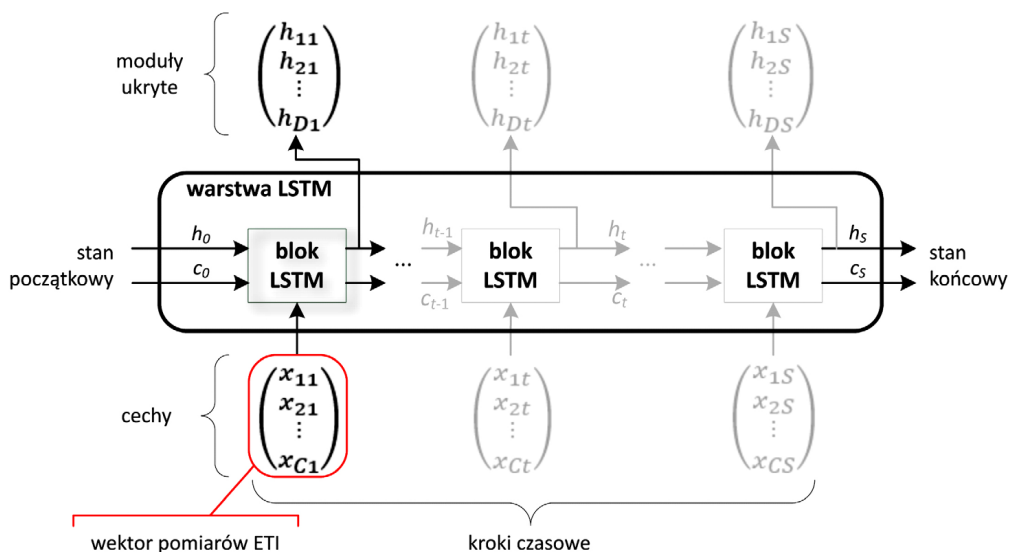
Rys. 4.4. Architektura przykładowej sieci CNN przeznaczonej do tomografii elektrycznej

4.3. Rekurencyjne sieci LSTM

Sieci LSTM (ang. *long-short term memory*) należą do nowszych struktur sieci neuronowych, jednak z uwagi na swój potencjał są szeroko opisywane w literaturze naukowej [39, 77, 96]. Jednym z kluczowych źródeł na ich temat jest praca Hochreitera i Schmidhubera z 1997 roku, która formalnie zainicjowała ten oryginalny model sieci neuronowych [46]. Wspomniana publikacja, zatytułowana *Long Short-Term Memory*, ukazała się w czasopiśmie „Neural Computation” i stanowi fundamentalne źródło na temat teoretycznych podstaw LSTM. Przez lata badania nad LSTM rozszerzyły ich zastosowania oraz pozwoliły na rozwój bardziej zaawansowanych technik, które kontynuują rozwój i optymalizację tego modelu, adaptując go do różnorodnych zastosowań i kontekstów badawczych.

Sieci LSTM są szczególnym rodzajem rekurencyjnych sieci neuronowych (RNN – ang. *recurrent neural networks*), które zostały zaprojektowane głównie z myślą o problemach uwzględniających zależności występujące w dłuższych sekwencjach danych niż tradycyjne RNN. Ponadto sieci LSTM są przystosowane do wejść składających się z wielu sekwencji. Sieci te są stosowane do zadań, w których konieczne jest modelowanie złożonych zależności czasowych i sekwencyjnych, takich jak przetwarzanie języka naturalnego, analiza szeregów czasowych, identyfikacja wzorców w sekwencjach danych czy generowanie muzyki. Z uwagi na charakter wektora pomiarowego ETI, uporządkowanego według protokołu pomiarowego i stanowiącego wejście tomografu elektrycznego, można założyć, że stanowi on sekwencję danych. Ten fakt powoduje, że wykorzystanie sieci LSTM w ETI jest w pełni uprawnione, co potwierdzają liczne badania [66, 67, 69, 77, 78, 86].

Rysunek 4.5 przedstawia architekturę warstwy sieciowej LSTM z wyróżnionym fragmentem wykorzystywanym w opisywanych badaniach dotyczących ETI.



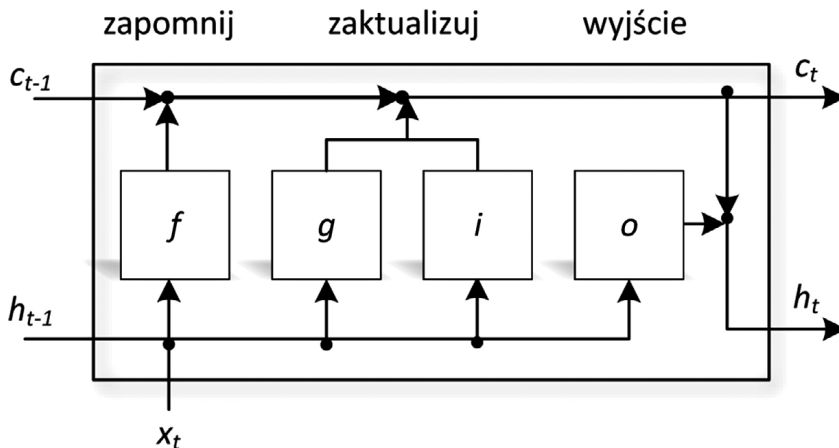
Rys. 4.5. Architektura przykładowej sieci LSTM przeznaczonej do tomografii elektrycznej [67]

Czerwona linia otacza sekcję LSTM, która została zaadaptowana jako pojedynczy (pierwszy i jedyny) krok czasowy. Szereg czasowy mający C cech (kanałów) o długości S jest oznaczony przez X . Dane binarne zawierające zarówno stan ukryty, jak i stan komórki w kroku czasowym t są oznaczone symbolami h_t i c_t . Cechy (x_1, x_2, \dots, x_C) w tym przypadku oznaczają wektor pomiarowy składający się z C pomiarów. Długość szeregu czasowego wynosi $S = 1$. W każdym bloku

warstwy LSTM znajduje się D jednostek ukrytych. Wektor pomiarowy może być uznany za sekwencję, czyli za uporządkowany zbiór wartości pojedynczych pomiarów napięcia między poszczególnymi parami elektrod, wykonywanych w regularnych odstępach czasu, według określonego protokołu pomiarowego [86]. W przypadku ETI D jest liczbą pixeli, czyli liczbą elementów skończonych siatki FEM, a ponieważ $S = 1$ to $h_s = h_{D1}$.

Stan ukryty (alternatywnie nazywany stanem wyjściowym) i stan komórki to dwa stany, które składają się na stan warstwy LSTM. Na przykład dane wyjściowe warstwy dla kroku czasowego t są ukryte. W każdym kroku czasowym stan komórki zawiera informacje zebrane z poprzednich kroków czasu ($t - 1$). Tak więc, w zależności od wektora wejściowego, warstwa dodaje lub odejmuje informacje od stanu komórki w każdym kroku czasowym. Warstwa LSTM jest odpowiedzialna za zarządzanie tymi zmianami za pośrednictwem bramek. Stanem komórki i stanem ukrytym warstwy zarządzają następujące bramki: bramka wejściowa (i) steruje poziomem aktualizacji stanu komórki, bramka zapominająca (f) steruje poziomem resetowania stanu komórki, kandydat na komórkę (g) dodaje informacje do stanu komórki, a bramka wyjściowa (o) steruje poziomem stanu komórki, który ma zostać dodany do stanu ukrytego.

Rysunek 4.6 przedstawia strukturę bloku LSTM, z której wynika sposób przetwarzania informacji realizowany dla danego kroku czasowego. Grafika ilustruje, w jaki sposób bramki zapamiętują, aktualizują i wyprowadzają stany komórek i stany ukryte, a także ich interakcje.



Rys. 4.6. Struktura bloku LSTM [77]

Dla sieci neuronowych nie opracowano jednoznacznych kryteriów doboru parametrów, które można stosować w zależności od typów problemów, do rozwiązywania których projektowana jest sieć LSTM. W rezultacie parametry struktury sieci, takie jak np. liczba warstw, liczba modułów ukrytych, liczba warstw normalizacyjnych, wartości wag początkowych lub rodzaje funkcji aktywacji, należy dobrać subiektywnie. Również hiperparametry określające proces uczenia, takie jak np. wielkość minipartii danych „minibatch”, rodzaj algorytmu optymalizacyjnego, sposób zatrzymania procesu uczenia, dobierane są empirycznie. Wzory (3.21) mogą być stosowane do obliczania wartości wektora wag \mathbf{W} , wag rekurencyjnych \mathbf{R} , a także obciążeń (biasów) \mathbf{b} [80].

$$\mathbf{W} = \begin{bmatrix} W_i \\ W_f \\ W_g \\ W_o \end{bmatrix}, \mathbf{R} = \begin{bmatrix} R_i \\ R_f \\ R_g \\ R_o \end{bmatrix}, \mathbf{b} = \begin{bmatrix} b_i \\ b_f \\ b_g \\ b_o \end{bmatrix} \quad (3.21)$$

Symbole i, f, o i g oznaczają odpowiednio bramki: wejściową, zapominającą, wyjściową oraz bramkę kandydata na komórkę. Stan komórki w określonym kroku czasowym t jest oznaczony jako $\mathbf{c}_t = f_t \odot \mathbf{c}_{t-1} + i_t \odot \mathbf{g}_t$, gdzie \odot oznacza mnożenie elementów wektorowych. W kroku czasowym t stan ukryty jest zdefiniowany jako $\mathbf{h}_t = o_t \odot \sigma_c(\mathbf{c}_t)$, gdzie σ_c jest funkcją aktywacji stanu. Równania (3.22) definiują składowe warstwy LSTM w kroku czasowym t :

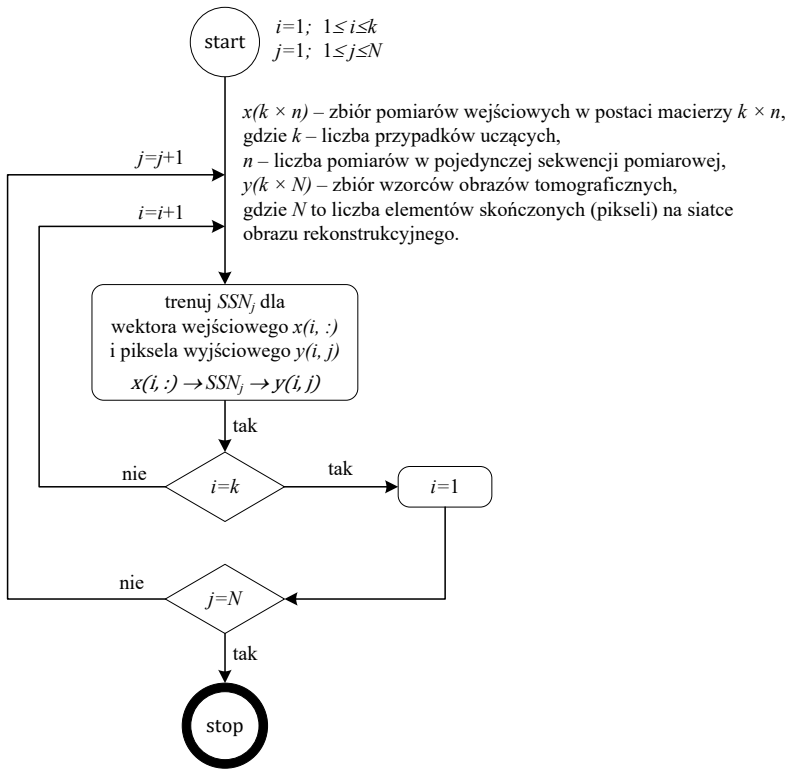
$$\begin{cases} i_t = \sigma_g(W_i \mathbf{x}_t + R_i \mathbf{h}_{t-1} + b_i) \\ f_t = \sigma_g(W_f \mathbf{x}_t + R_f \mathbf{h}_{t-1} + b_f) \\ g_t = \sigma_c(W_g \mathbf{x}_t + R_g \mathbf{h}_{t-1} + b_g) \\ o_t = \sigma_g(W_o \mathbf{x}_t + R_o \mathbf{h}_{t-1} + b_o) \end{cases} \quad (3.22)$$

gdzie σ_g oznacza funkcję aktywacji bramki. W problemach regresyjnych często stosowaną funkcją aktywacji warstwy sieci neuronowej jest funkcja sigmooidalna, która może być przedstawiona jako $\sigma(x) = (1 + e^{-x})^{-1}$.

4.4. Wielokrotne sztuczne sieci neuronowe

Wielokrotne sztuczne sieci neuronowe (WSSN) to oryginalna koncepcja opisana po raz pierwszy w roku 2018 [120, 130]. Idea ta opiera się na założeniu, że łatwiej jest wytrenować efektywne sieci neuronowe z jednym wyjściem niż z wieloma. Metoda WSSN, zwana także metodą trenowanie piksel po pikselu (ang. *pixel by pixel*), zakłada wytrenowanie nie jednej, lecz wielu SSN, z których każda ma za zadanie obsłużyć pojedynczego piksela obrazu wyjściowego. Warto zauważyć, że do wytrenowania różnych pikseli obrazu tomograficznego wykorzystywany jest ten sam zbiór uczący pomiarów (wejść). Z uwagi na fakt, że trenowanie SSN polega na dopasowaniu wag i biasów, nie ma w tym podejściu sprzeczności.

Rysunek 4.7 przedstawia algorytm procesu uczenia nie jednej, lecz wielu sieci neuronowych stanowiących system, mający na celu rekonstrukcję obrazu tomograficznego za pomocą WSSN. Algorytm rozpoczyna się od zainicjowania dwóch liczników i oraz j , gdzie i jest indeksem przechodzącym przez zbiór pomiarów wejściowych, a j przez zbiór wyjściowy odzwierciedlający wartości pikseli obrazu tomograficznego. Zbiór x o wymiarach k na n zawiera macierz pomiarów wejściowych, gdzie k to liczba przypadków uczących, a n to liczba pomiarów w pojedynczej sekwencji. Z kolei macierz y o wymiarach k na N to zbiór wzorców obrazów tomograficznych, gdzie N to liczba pikseli na siatce obrazu rekonstruowanego, równoznaczna z liczbą elementów skończonych siatki FEM. Dla każdego przypadku uczącego reprezentowanego przez i oraz dla każdego piksela obrazu wyjściowego reprezentowanego przez j algorytm przeprowadza trening sieci neuronowej SSN z wektorem wejściowym $x(i, :)$ oraz pikselem wyjściowym $y(i, j)$. Po uwzględnieniu wszystkich przypadków uczących i wytrenowaniu sieci dla danego piksela j algorytm sprawdza, czy zostały uwzględnione wszystkie piksele, testując warunek „czy $j = N$ ”. Jeśli warunek nie jest spełniony, algorytm zwiększa wartość j o jeden i kontynuuje trening kolejnej SSN_{j+1} przeznaczonej dla kolejnego piksela. Gdy wszystkim pikselom obrazu zostaną przypisane osobne sieci neuronowe, algorytm zostaje zatrzymany. W rezultacie uzyskujemy zmienną strukturalną zawierającą N wytrenowanych SNN .



Rys. 4.7. Algorytm trenowania wielokrotnych sieci neuronowych (WSSN)

5. Laboratoryjne badania wilgotności muru ceglanego

Niniejszy rozdział opisuje sposób badania wilgotności muru ceglanego w warunkach laboratoryjnych wykorzystujący zaawansowane techniki elektrycznej tomografii impedancyjnej (ETI). Omówiono fizyczny model zawilgoconego muru ceglanego, tradycyjnego i popularnego materiału budowlanego, stosowanego w budynkach historycznych. Charakterystyka obiektu obejmuje wymiary muru, strukturę wewnętrzną, materiały i sposób wymuszonego zawilgocenia. Kolejna część rozdziału poświęcona jest opisowi tomografu ETI – kluczowego urządzenia wykorzystywanego w badaniach. Tomograf umożliwia wykonanie pomiarów elektrycznych, na podstawie których generowane są obrazy wewnętrznej struktury badanego obiektu. Szczegółowo omówiono także elektrody, ich konstrukcję oraz rolę w procesie pomiarowym.

W dalszej części rozdziału przedstawiono algorytmy i metody obliczeniowe stosowane do rekonstrukcji obrazów, w tym metody deterministyczne, statystyczne oraz metody oparte na uczeniu maszynowym. Ostatnia część rozdziału zawiera analizę i porównanie wyników uzyskanych za pomocą różnych metod rekonstrukcyjnych, co umożliwia wyciągnięcie wniosków dotyczących efektywności i wiarygodności poszczególnych technik w kontekście badania wilgotności murów ceglanych. Celem jest znalezienie optymalnych rozwiązań algorytmicznych, które mogłyby być zastosowane w praktyce inżynierskiej i konserwatorskiej, przyczyniając się do lepszego poznania badanej problematyki i skuteczniejszej ochrony zabytkowej substancji murów ceglanych.

5.1. Mur ceglany jako obiekt badań


Obiektem badań był specjalnie zaprojektowany i wykonany w laboratorium Netrix S.A. mur ceglany widoczny na rysunku 5.1. Mur ustawiono w płytkiej wannie wykonanej z nieprzemakalnej folii otoczonej burtami, co umożliwiło zalanie dolnej części muru wodą. Woda, na skutek podsiąkania kapilarnego, przemieszczała się w górę muru poprzez porowate struktury cegieł i zaprawy murarskiej. Dodatkowo na szczycie muru dobudowano ceglaną nieckę o pojemności około 18 litrów (rysunek 5.1b). W ten sposób umożliwiono wnikanie wody w głąb muru także od góry.

Mur poddawany był działaniu wody przez 48 godzin. Po tym czasie stwierdzono, że rozkład zawilgocenia ustabilizował się, ponieważ dynamika wzrostu zawilgocenia została zrównoważona przez odparowywanie (wysychanie) muru. Można to było stwierdzić między innymi na podstawie obrazów termograficznych, a także organoleptycznie.



Rys. 5.1. Sztucznie zawilgocony mur ceglany w warunkach laboratoryjnych: (a) widok całego stanowiska badawczego, (b) górna część muru

Rysunek 5.2 przedstawia zdjęcie stanowiska badawczego, które obejmowało mur ceglany, elektrody, tomograf oraz komputer z oprogramowaniem umożliwiającym ustrukturyzowany zapis danych pomiarowych w odpowiednim formacie, a także uruchomienie algorytmu przetwarzającego pomiary na obrazy rekonstrukcyjne.




Rys. 5.2. Stanowisko badawcze

Rysunek 5.3 przedstawia obrazy uzyskane w podczerwieni, wykonane za pomocą kamery termowizyjnej FLIR-T540 (FLIR Systems, Inc., Wilsonville, OR, USA). Obrazy termowizyjne ilustrują dwa różne widoki sztucznie zawilgoczonego muru ceglanego. Rysunek 5.3a przedstawia mur z elektrodami umieszczonymi na jego powierzchni. Elektrody zostały wykorzystane do generowania i odbierania parametrów elektrycznych, które zostały użyte do mapowania rozkładu konduktywności w strukturze muru, co ma kluczowe znaczenie dla wizualizacji obszarów zawilgoczenia.

Rysunek 5.3b przedstawia ten sam mur, lecz bez elektrod. Na tym obrazie nie ma widocznych narzędzi pomiarowych, co pozwala na ocenę obrazu cieplnego muru bez wpływu obecności elektrod. Różnice w kolorach na obu obrazach odpowiadają różnicom temperatury powierzchni, co jest bezpośrednio związane z wilgotnością muru, zwłaszcza na jego powierzchni. Wilgotniejsze obszary charakteryzują się inną zdolnością do przewodzenia ciepła, przez co mają inny profil temperaturowy. Inna jest także ich konduktywność.

Analiza obrazów w podczerwieni, w ograniczonym zakresie, może być wykorzystana do weryfikacji skuteczności metody ETI w lokalizacji i kwantyfikacji zawilgoczenia w murach ceglanych. W szczególności porównanie rozkładu temperatury na obrazach z danymi uzyskanymi z ETI może dostarczyć informacji o zgodności i skuteczności tej techniki pomiarowej w diagnozowaniu stanu zawilgoczenia struktur budowlanych.



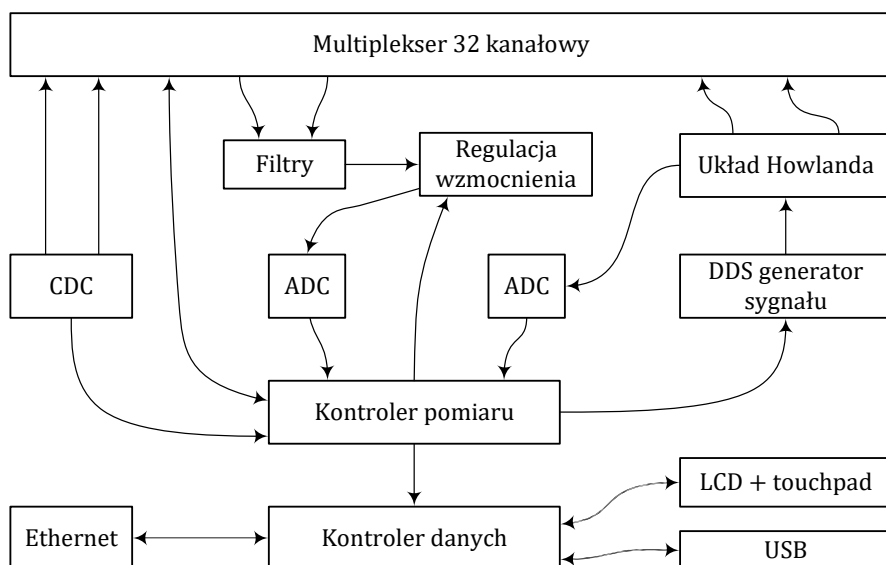
Rys. 5.3. Zdjęcia termowizyjne sztucznie zawilgoconego muru ceglanego:
 (a) widok z elektrodami, (b) widok bez elektrod

Źródło: materiały Netrix S.A.

Precyzyjne zweryfikowanie dokładności odwzorowania wilgoci na obrazie tomograficznym w przypadku obiektów rzeczywistych jest w zasadzie niemożliwe. Wynika to z braku bezpośredniego odniesienia do wzorca zawilgoconego wnętrza badanego fragmentu muru (ang. *ground truth*). Badanie zawilgoconego muru za pomocą elektrycznej tomografii impedancyjnej w kontrolowanych warunkach laboratoryjnych jest skuteczną metodą oceny jakości ETI w warunkach zbliżonych do rzeczywistych. Aby móc dokładnie ocenić jakość i precyzję obrazów rekonstrukcyjnych, często stosuje się różne wskaźniki ilościowe, takie jak błąd średniokwadratowy (MSE), wskaźnik korelacji Pearsona, strukturalny indeks podobieństwa (SSIM – ang. *structural similarity index measure*) oraz stosunek sygnału do szumu (PSNR – ang. *peak signal to noise ratio*). Jednak wykorzystanie tych wskaźników wymaga dostępności obrazu referencyjnego, który można uzyskać metodami symulacyjnymi. Jak już wspomniano, w warunkach rzeczywistych uzyskanie obrazów referencyjnych badanego fragmentu muru jest niemożliwe. Stanowi to zasadniczą przeszkodę utrudniającą weryfikację ETI jako skutecznej metody identyfikacji wilgoci. Pomimo tego klasyczne, punktowe metody badania zawilgoceń murów mogą w pewnym stopniu uzupełnić tę lukę.

5.2. Tomograf hybrydowy

W badaniach będących przedmiotem niniejszego opracowania wykorzystano prototypowy tomograf hybrydowy, zaprojektowany i wykonany w laboratoriach Netrix S.A. Jest to zaawansowane urządzenie pomiarowe, które wykorzystuje tomografię elektryczną do analizy obiektów dwoma metodami – elektrycznej tomografii impedancyjnej (ETI) oraz elektrycznej tomografii pojemnościowej (ETP) [17, 102]. Rysunek 5.4. przedstawia schemat blokowy tomografu hybrydowego ETI/ETP.



Rys. 5.4. Schemat blokowy tomografu hybrydowego ETI/ETP

Źródło: opracowanie własne na podstawie materiałów Netrix S.A.

Kluczową rolę w tomografii hybrydowym pełni układ Howlanda. Jego zadaniem jest generowanie stabilnego sygnału prądowego niezbędnego do precyzyjnych pomiarów metodą impedancyjną. Z punktu widzenia efektywności i dokładności systemu tomograficznego ma to znaczenie fundamentalne, szczególnie w aplikacjach medycznych i przemysłowych, w których niezawodność i stabilność sygnału są priorytetem. Centralnym elementem układu Howlanda jest moduł DDS (ang. *direct digital synthesis*). Moduł ten umożliwia precyzyjne modulowanie i stabilizowanie sygnału prądowego. Technologia DDS pozwala na szybkie i precyzyjne generowanie sygnałów

prądowych o zdefiniowanych parametrach. Do ww. parametrów zaliczamy częstotliwość, amplitudę i fazę, przy czym zmiana parametrów odbywa się w sposób elektroniczny. Cyfrowe podejście do syntezy sygnału znacznie zwiększa efektywność układu Howlanda, jednocześnie oferując dużą dokładność i powtarzalność wyników. Do zalet DDS należy łatwe, dynamiczne i automatyczne dostosowanie parametrów sygnału za pomocą oprogramowania. Pozwala to na elastyczne zarządzanie procesem pomiarowym i akomodację do specyficznych potrzeb użytkownika bez potrzeby fizycznej ingerencji w układ. Dodatkowo technologia DDS minimalizuje ryzyko powstawania szumów i zakłóceń. Zakłócenia mają negatywny wpływ na jakość sygnału, a co za tym idzie, także na dokładność pomiarów.

Zadaniem przetworników analogowo-cyfrowych (ADC) jest przekształcanie sygnałów analogowych pochodzących z różnych modułów urządzenia na dane cyfrowe. Tego rodzaju dane stanowią podstawę do dalszej analizy i rekonstrukcji obrazów. Zastosowane w tomografii moduły ADC charakteryzują się wysoką rozdzielczością, dzięki czemu urządzenie dokładnie odwzorowuje sygnały analogowe w ich cyfrowej formie. Wysoka, 16-bitowa rozdzielczość przetwornika jest szczególnie przydatna w aplikacjach medycznych i inżynierskich. Precyzja i szczegółowość pomiarów mają bezpośredni wpływ na jakość obrazowania.

Istotnym parametrem ADC jest również szybkość pomiaru. Krótki czas przetwarzania umożliwia szybką akwizycję danych, co jest szczególnie ważne w środowiskach dynamicznych, gdzie zmiany stanu badanego obiektu mogą następować w szybkim tempie. Dzięki krótkim czasom przetwarzania przetworników ADC tomograf może rejestrować dane w czasie rzeczywistym. Ta cecha jest istotna zwłaszcza podczas monitorowania przepływów cieczy, reakcji chemicznych czy funkcji fizjologicznych w badaniach biomedycznych. Szybkość przetworników w opisywanym tomografii wynosi 500 kSps¹ na kanał.

Kolejnym aspektem pracy ADC, oprócz rozdzielczości i szybkości, jest minimalizacja interferencji sygnału. Tomograf wykorzystuje zaawansowane techniki filtracji i tłumienia zakłóceń, aby zminimalizować wpływ szumów i innych zewnętrznych zakłóceń na sygnał. Redukcja zakłóceń ma duże znaczenie dla utrzymania wysokiego poziomu czystości sygnału. Ma to bezpośrednie przełożenie nie tylko na pomiary, lecz przede wszystkim wpływa na dokładność i wiarygodność wyników, dla których podstawą są pomiary.

Moduł regulacji wzmocnienia ma na celu zapewnienie optymalnej jakości sygnału przed jego digitalizacją realizowaną za pośrednictwem przetwornika

¹ kSps – ang. *kilosamples per second*, czyli tysiąc próbek na sekundę.

analogowo-cyfrowego (ADC). Regulacja wzmocnienia pozwala na dostosowanie amplitudy sygnału pomiarowego do różnych warunków operacyjnych. Jest to niezbędne w różnorodnych zastosowaniach, a zwłaszcza w sytuacjach, kiedy sygnały wykazują znaczne różnice w poziomie mocy. Funkcja regulacji wzmocnienia umożliwi precyzyjne dostosowanie poziomu sygnału wejściowego do zakresu pracy ADC. Ma to duże znaczenie dla utrzymania pełnej dynamiki sygnału i uniknięcia zniekształceń, takich jak przesterowanie lub zbyt niska rozdzielczość pomiaru. Opisujący moduł charakteryzuje się cyfrowym sterowaniem. To sprawia, że wszystkie ustawienia wzmocnienia mogą być realizowane za pośrednictwem oprogramowania sterującego urządzeniem. Oprogramowanie sterujące zawarte w układzie umożliwi dokonywanie szybkich zmian konfiguracji wzmocnienia w odpowiedzi na zmieniające się warunki pomiarowe, a także na specyficzne wymagania związane z realizowanym eksperymentem. Ponadto cyfrowe sterowanie wzmocnieniem umożliwi automatyzację procesów kalibracji i dostosowywanie parametrów operacyjnych. Dzięki temu tomograf uzyskuje większą efektywność i niezawodność w zróżnicowanych warunkach pracy.

Cyfrowo sterowane wzmocnienie sprawia, że tomograf można zaadaptować do szerokiej gamy scenariuszy pomiarowych, od sygnałów o niskiej amplitudzie, po sygnały o wysokiej mocy. Tego rodzaju elastyczność jest istotna w zastosowaniach badawczych i przemysłowych, w których warunki pomiarowe mogą się znacznie różnić.

Przetwornik ADC może generować surowe, bezpośrednie dane dla wartości pomiarów tomograficznych, ale w przypadku opisywanych badań ADC odpowiednio konwertuje wartości, tj. normalizuje je do efektywnej rozdzielczości 16-bitowej oraz dokonuje kwantyzacji analogowego sygnału wejściowego, dzieląc go na 65 536 możliwych poziomów. Cyfryzacja sygnału normalizuje dane wejściowe do ustalonego zakresu wartości, biorąc pod uwagę wartości wzmocnienia, upraszczając porównanie i analizę.

Charakter procesu akwizycji danych i późniejsze metody ich przetwarzania zastosowane w badaniach przyczyniły się do tego, aby wartości pomiarów były podawane w jednostkach umownych (ang. *arbitrary units*). Sposób wyrażania wartości pomiarów w jednostkach umownych, zamiast w woltach, wynika z kilku przesłanek. Powyższe przesłanki są rezultatem specyfiki metodologii ETI, jej zastosowań oraz kwantyfikacji i specyfiki procesu obrazowania wilgoci w ścianach. ETI polega na iniekcji prądu elektrycznego przez elektrody umieszczone na powierzchni badanego obiektu. Następnie dokonuje się pomiarów różnic potencjałów pomiędzy różnymi parami elektrod. W rezultacie uzyskane

wartości pomiarowe mogą się różnić w zależności od kalibracji urządzenia, normalizacji i zastosowanego algorytmu rekonstrukcji obrazu. Zmiany te wpływają na korelację względnych wartości potencjałów z bezwzględnymi jednostkami fizycznymi wyrażonymi w woltach. Zastosowanie jednostek umownych pozwala na bardziej uogólnioną reprezentację pomiarów, ułatwiając porównywanie uzyskanych rekonstrukcji w różnych konfiguracjach i eksperymentach bez konieczności powiązania kolorów z określoną skalą wyrażoną w woltach.

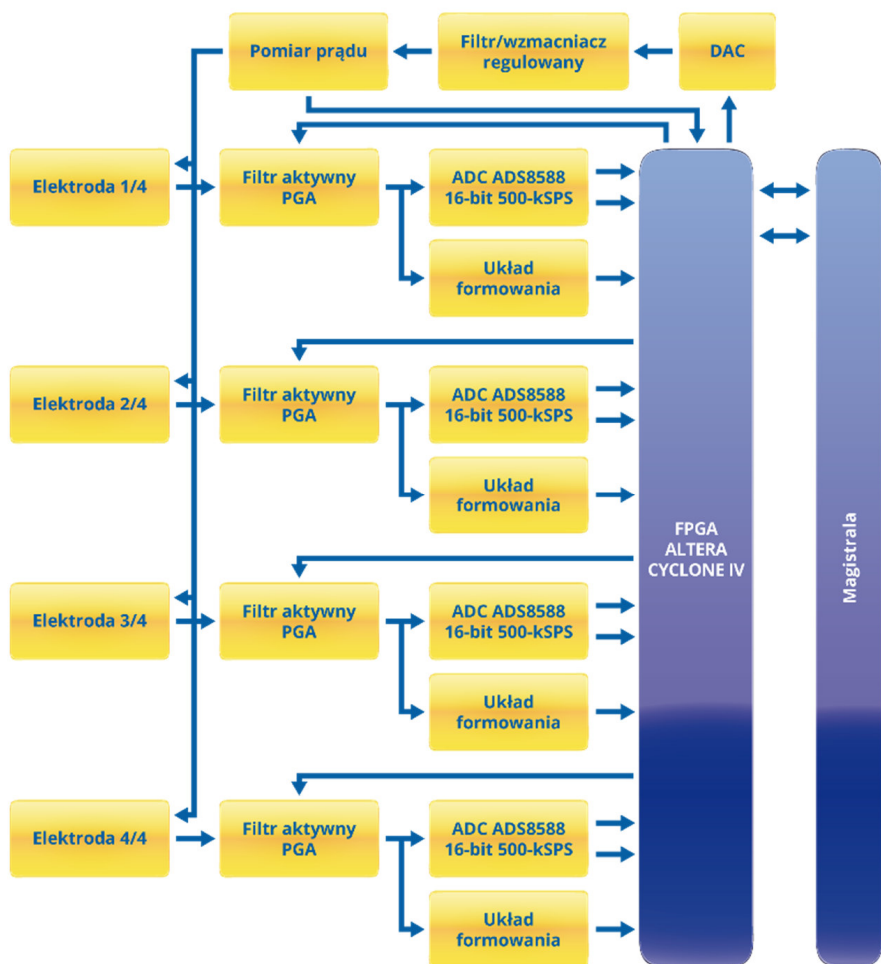
Innym argumentem przemawiającym za wprowadzeniem jednostek umownych jest proces kalibracji ETI. Kalibracja jest niezbędnym elementem procesu dostosowania pomiarów. Ma ona na celu uwzględnienie zmiennych specyficznych dla systemu, takich jak impedancja elektrody, charakterystyka wzmacniacza sygnału i inne czynniki, które mogą wpływać na pomiary. Ponieważ proces ten dostosowuje skalę wartości pomiarów, wynikowe dane mogą nie odpowiadać napięciom w sposób bezpośredni, co sprawia, że jednostki umowne są bardziej praktycznym wyborem.

Do zobrazowania wilgoci w ścianach za pomocą ETI wystarczy informacja na temat rozkładu względnych zmian konduktancji elektrycznej. Nie chodzi więc o uzyskanie bezwzględnych wartości konduktywności. Tego rodzaju podejście ułatwia interpretację obrazów tomograficznych, uwidoczniając rozkład wilgoci wewnątrz badanego obiektu, nie zaś dokładne wartości parametrów fizycznych. Zastosowanie jednostek umownych upraszcza porównywanie danych z różnych pomiarów, urządzeń i warunków eksperymentalnych. Ponieważ specyficzna konfiguracja i kalibracja systemu ETI może znacząco zmieniać wartości bezwzględne pomiarów elektrycznych, jednostki umowne oferują znormalizowaną skalę nadającą się do zastosowania w różnych badaniach, zwiększając w ten sposób porównywalność i powtarzalność wyników. W obrazowaniu wilgotności ścian głównym przedmiotem zainteresowania jest rozkład i względne zmiany zawartości wilgoci, a nie ilościowe określenie dokładnych właściwości elektrycznych badanej struktury. Jednostki umowne są odpowiednie do tego zadania, ponieważ pozwalają na skuteczną wizualizację i analizę wzorców zawilgoceń bez znajomości bezpośredniej korelacji z określonymi jednostkami fizycznymi.

Innym kluczowym komponentem, który odpowiada za koordynowanie procesu akwizycji danych jest kontroler pomiaru. Jego główne funkcje obejmują zarządzanie pracą przetworników analogowo-cyfrowych (ADC), sterowanie procesem zbierania danych oraz ich wstępne przetwarzanie. Kontroler pomiaru jest więc centralnym elementem systemu pomiarowego odpowiedzialnym za zapewnienie spójności i precyzji zbieranych danych.

Ma to fundamentalne znaczenie dla prowadzonych analiz i interpretacji wyników. Kontroler pomiaru zapewnia optymalny sposób rejestrowania zmieniających się sygnałów. Wspomniany moduł umożliwia szybką zmianę parametrów pomiarowych, takich jak częstotliwość próbkowania, zakres wzmocnienia sygnału czy parametry filtracji. Sterowanie ADC realizowane przez kontroler pomiaru obejmuje między innymi zarządzanie czasem próbkowania oraz precyzją, z jaką sygnały analogowe są konwertowane na format cyfrowy. Kontroler zapewnia, że każdy sygnał jest przetwarzany z odpowiednią dokładnością, co jest istotne dla zachowania integralności danych. Ma to szczególnie znaczenie w aplikacjach, gdzie nawet małe błędy pojawiające się w rejestrowanych danych mogą prowadzić do znacznych błędów w interpretacji wyników. Kontroler pomiaru posiada również funkcje wstępnego przetwarzania sygnałów. Należą do nich filtracja, wzmocnienie oraz ewentualna korekcja sygnałów przed ich cyfryzacją. Dzięki zaawansowanym algorytmom przetwarzania sygnałów, kontroler jest w stanie minimalizować wpływ zakłóceń oraz poprawiać jakość danych wejściowych.


Rysunek 5.5 przedstawia schemat karty pomiarowej, która jest integralną częścią modułu kontrolera pomiaru. Karta pomiarowa przetwarza sygnały otrzymane z wielu elektrod. Przetwarzanie obejmuje filtrację, regulację wzmocnienia oraz przekształcenie pomiarów analogowych na cyfrowe przy użyciu przetworników ADC.



Rys. 5.5. Schemat blokowy karty pomiarowej

Źródło: materiały Netrix S.A.

Na rysunku 5.6. przedstawiono kartę pomiarową konstrukcji Netrix S.A. Płytkę drukowaną zawiera wiele elementów elektronicznych, takich jak zintegrowane obwody (IC), rezystory, kondensatory i złącza. Cztery złącza koaksjalne typu SMA znajdujące się w górnej części układu świadczą o tym, że karta jest wykorzystywana do obsługi sygnałów wysokiej częstotliwości – nawet do 500 kHz. Na płycie umieszczono wiele drobnych komponentów pasywnych i aktywnych, które są integralnymi częściami obwodów elektronicznych wspierających funkcje karty. Karta realizuje takie zadania jak filtracja, wzmacnianie sygnałów, a także ich konwersja i przetwarzanie. Złącza widoczne na dolnej krawędzi karty pozwalają na jej połączenie z głównym systemem pomiarowym.



Rys. 5.6. Karta pomiarowa tomografu hybrydowego konstrukcji Netrix S.A.

Źródło: materiały Netrix S.A.

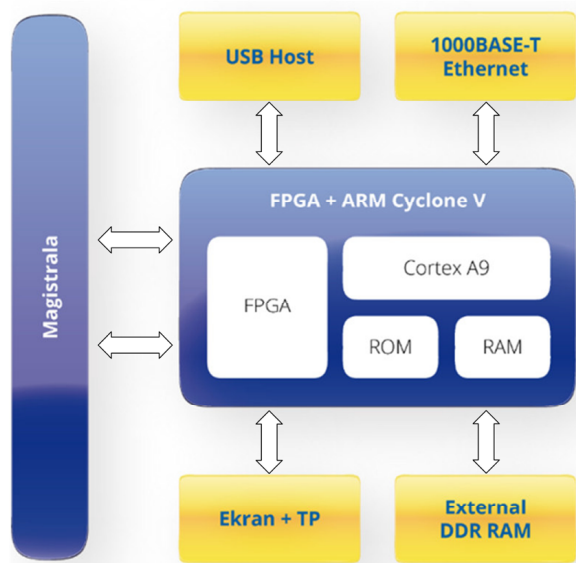
Innym istotnym elementem systemu tomograficznego są filtry aktywne. Ich rola polega na redukcji składowych sygnału o częstotliwości 50 Hz. Ta wartość częstotliwości jest typowa dla zakłóceń pochodzących z sieci elektrycznej. Filtry aktywne wykorzystują skomplikowane konfiguracje elektroniczne do selektywnego tłumienia określonych częstotliwości, jednocześnie zachowując integralność pożądaných części sygnału. Ich prawidłowe zaprojektowanie i implementacja są kluczowe dla efektywnej separacji użytecznych danych od szumów i zakłóceń. Korzyści wynikające z użycia filtrów aktywnych obejmują nie tylko eliminację zakłóceń o częstotliwości 50 Hz, ale również ogólną poprawę stosunku sygnału do szumu (PSNR). Zwiększa to zdolność systemu do wykrywania subtelnych kontrastów w badanych obiektach. Ma to szczególne znaczenie w sytuacji, kiedy niewielkie różnice w wartościach pomiarowych mogą powodować duże zmiany na wyjściu układu.

Zadania tomografu polegające na przetwarzaniu, analizie oraz zarządzaniu zebranymi danymi pomiarowymi realizuje kontroler danych. Pełni on priorytetową rolę w procesie transformacji surowych danych wejściowych na użyteczne informacje, które mogą być wykorzystane do dalszej analizy, diagnozy czy monitoringu. Kontroler danych przetwarza sygnały otrzymywane z modułu ADC. Do jego zadań należy filtracja, dekodowanie oraz przekształcanie sygnałów do odpowiednich formatów danych. Przetwarzanie, o którym mowa, obejmuje również algorytmy do identyfikacji anomalii, korekcji błędów oraz optymalizacji danych do dalszego wykorzystania. Zadaniem kontrolera danych jest także zarządzanie pamięcią. Wymaga to skutecznego gospodarowania przestrzenią pamięciową

zarówno wewnętrzną, jak i zewnętrzną. Celem jest zapewnienie odpowiedniej przepustowości i dostępności danych dla różnych procesów systemowych. Kontroler danych koordynuje zapis danych na lokalnych nośnikach oraz ich backup w celu zapewnienia bezpieczeństwa i integralności. Podlegający kontrolerowi danych interfejs użytkownika pozwala na interakcję systemu tomograficznego z operatorem. Z kontrolerem zintegrowane są takie elementy jak ekran dotykowy oraz graficzny panel kontrolny, który zarządza ich funkcjonalnością i wydajnością.

Kontroler danych posiada opcje zapisu i przesyłania danych. Możliwość zapisu danych na zewnętrznych nośnikach, takich jak dyski USB, jest konieczna w kontekście mobilności danych i ich archiwizacji. Ponadto kontroler zapewnia funkcje przesyłania danych poprzez interfejsy takie jak USB i Ethernet, co umożliwia wymianę danych pomiędzy tomografem a innymi systemami komputerowymi. Przyspiesza to procesy badawcze i diagnostyczne oraz umożliwia integrację systemu tomograficznego z większymi sieciami badawczymi, gdzie dane mogą być zdalnie analizowane i przetwarzane.

Rysunek 5.7 przedstawia schemat blokowy jednostki sterowania i przetwarzania danych, wykorzystujący zintegrowane układy FPGA oraz ARM Cyclone V. Centralnym elementem układu jest moduł zawierający FPGA oraz mikroprocesor ARM Cortex-A9 umożliwiający efektywne przetwarzanie danych oraz realizujący procesy zarządzania logiką operacyjną systemu.



Rys. 5.7. Schemat jednostki sterowania i przetwarzania danych

Źródło: materiały Netrix S.A.

W omawianej architekturze FPGA (ang. *field-programmable gate array*) służy do realizacji specyficznych funkcji związanych z przetwarzaniem sygnałów, logiką cyfrową czy operacjami na danych w czasie rzeczywistym. Możliwości konfiguracji FPGA pozwalają na elastyczne dostosowanie do zmiennych wymagań aplikacji. Mikroprocesor ARM Cortex-A9 zapewnia ogólną kontrolę nad systemem i obsługę tzw. zadań wyższego poziomu. W szczególności do jego zadań należy obsługa interfejsu użytkownika, zarządzanie siecią oraz komunikacja z urządzeniami zewnętrznymi. W opisywanym układzie znajdują się także bloki obsługujące pamięć ROM i RAM, które są wykorzystywane odpowiednio do przechowywania danych i oprogramowania tylko do odczytu (ROM – ang. *read-only memory*) oraz danych operacyjnych i tymczasowych (RAM – ang. *random-access memory*). Na schemacie widoczne są również interfejsy komunikacyjne, takie jak USB Host i 1000BASE-T Ethernet, które umożliwiają łączność z innymi urządzeniami i sieciami. Ponadto schemat uwzględnia zewnętrzną pamięć DDR RAM (DDR – ang. *double data rate*), która zapewnia dodatkową przestrzeń dla danych wymagających szybkiego dostępu i dużych zasobów, oraz moduł „Ekran + TP (Touchpad)”. Całość jest zintegrowana za pośrednictwem magistrali, która zapewnia komunikację i przesył danych między wszystkimi elementami systemu.

5.3. Elektrody ETI

Elektrody wykorzystane w badaniach wilgotności murów zostały zaprojektowane w laboratoriach Netrix S.A. Stanowią one odrębny system, który współpracuje z właściwym urządzeniem tomograficznym ETI/ETC. Podstawowym zadaniem elektrod jest umożliwienie przepływu prądu elektrycznego między obiektem badań a tomografem. W związku z powyższym elektrody mają kluczowy wpływ na jakość i dokładność rekonstrukcji obrazu. W przypadku obrazowania wilgotności murów powierzchnia styku z elektrodami może być nierówna. Ta okoliczność stanowi poważne wyzwanie techniczno-konstrukcyjne, ponieważ zapewnienie kontaktu elektrod ze ścianą budynku jest niezbędne do niezakłóconego przepływu prądu elektrycznego.


Z myślą o zapewnieniu efektywnego kontaktu z nierównymi powierzchniami, w laboratorium Netrix S.A. zaprojektowano i wykonano prototypy elektrod ETI wraz z systemem metalowych listew do ich mocowania. Elektrody zostały wykonane z elastycznych materiałów, które umożliwiają dostosowanie do nierówności badanej powierzchni. Ich głównym celem jest zapewnienie

stałego i niezawodnego kontaktu elektrycznego tomografu z obiektem badań. W elektrodach zastosowano innowacyjne rozwiązania konstrukcyjne, które zwiększają obszar kontaktu z nierówną powierzchnią.

Zarówno pojedyncze elektrody, jak również metalowe listwy, do których elektrody są przytwierdzone, chroni patent (PAT.239542). Uchwyt elektrody składa się z płyty montażowej z centralnym otworem, w którym umieszczony jest tulejowy korpus z kołnierzem. Konstrukcja ta ma na celu maksymalizację stopnia dopasowania do nierówności murów. Istotnym elementem zapewniającym prawidłowy styk każdej elektrody ETI z murem jest elastyczny pierścień gumowy. Wspomniane pierścienie zapewniają dodatkową amortyzację i pozwalają na zachowanie stałego nacisku, niezbędnego do utrzymania ciągłości pomiaru.

Elementy konstrukcyjne elektrod, w tym płyta montażowa i tulejowy korpus, zostały wytworzone przy użyciu technologii druku 3-D. Dzięki wykorzystaniu druku 3-D uzyskano wysoką precyzję, trwałość oraz dobre dopasowanie wszystkich części składowych. Syntetyczne materiały, które zostały użyte do wydrukowania elektrod, zapewniają wysoką trwałość i odporność na zmienne warunki środowiskowe mogące występować w warunkach rzeczywistych.

Na płycie laminowanej PCB znajduje się gniazdo połączeniowe SMB, co ułatwia podłączanie elektrod do systemu pomiarowego ETI. Dodatkowo pierścień z pianki poliuretanowej zabezpiecza złącze przed uszkodzeniami mechanicznymi i wpływem wilgoci. Innym zadaniem pierścienia jest zapewnienie równomiernego rozkładu nacisku na elektrodę. Dzięki powyższym rozwiązaniom techniczno-konstrukcyjnym elektrody ETI mogą być efektywnie wykorzystywane w różnorodnych aplikacjach – od monitoringu zawilgoceń w budynkach zabytkowych po zastosowania w badaniach przemysłowych. Badania ETI wymagają precyzji i niezawodności na każdym etapie procesu obrazowania, począwszy od pomiarów, poprzez transformację danych pomiarowych na dane wyjściowe, kalibrację kolorów i generowanie rekonstrukcji. Dlatego w technologii ETI nie powinno się dokonywać kompromisów, polegających na obniżeniu kosztów produkcji w zamian za obniżenie parametrów technicznych systemu tomograficznego. Rysunek 5.8 przedstawia półwidok – półprzekrój elektrody ETI.



Rys. 5.8. Półwidok – półprzekrój elektrody ETI


Źródło: materiały Netrix S.A.

Konstrukcja elektrody obejmuje kilka kluczowych elementów:

1. Korpus elektrody – element zapewniający sztywność konstrukcji, wykonany z tworzywa w technologii 3-D.
2. Płyta mocująca – element konstrukcyjny elektrody, w którego środkowej części znajduje się otwór o przekroju okrągłym. Przedmiotowa płyta jest wykonana w technologii druku 3-D, co pozwala na precyzyjne dopasowanie do specyfikacji technicznych.
3. Tuleja z kołnierzem – umieszczona w otworze płyty mocującej tuleja, przylega do wewnętrznej części korpusu elektrody, zapewniając stabilność i trwałość montażu. Kołnierz tulei pomaga w utrzymaniu elektrody w odpowiedniej pozycji względem powierzchni przylegania.
4. Elastyczny pierścień – znajdujący się pomiędzy płytą mocującą a korpusem elektrody, wykonany z gumy, zapewnia dodatkową amortyzację i elastyczność, umożliwiając dokładne dostosowanie do nierówności muru.
5. Płytkę z gniazdem przyłączeniowym – na powierzchni tej płytki znajduje się tuleja wykonana z gąbki, co dodatkowo zabezpiecza połączenie. Płytkę została wykonana z dwustronnego laminatu PCB z gniazdem przyłączeniowym SMB.

6. Powierzchnia stykająca się z murem – wykonana z gumy elektroprzewodzącej, zapewniająca skuteczny i stabilny kontakt. Wewnętrzna strona gumowej powierzchni jest pokryta galwaniczną warstwą miedzi, do której przytwierdzony jest spiralny drut. Drut ukryty jest pod gąbką. Jego zadaniem jest połączenie elektryczne powierzchni stykowej elektrody ze złączem na tylnej ścianie elektrody, do którego zamocowany jest przewód elektryczny.
7. Tuleja wykonana z gąbki – zapewnia elastyczność amortyzującą nierówności powierzchni badanej ściany.

Na rysunku 5.9 przedstawiono zdjęcia kompletnej elektrody ETI. Zdjęcia umożliwiają ogląd elektrody ze wszystkich stron. Wyraźnie widać zewnętrzną powierzchnię tulei wykonanej z gąbki (rysunek 5.9a), tylną ściankę z przytwierdzonym złączem (rysunek 5.9b) oraz powierzchnię styku wykonaną z gumy elektroprzewodzącej (rysunek 5.9c).



Rys. 5.9. Elektroda tomografu ETI:
(a) widok strony tylnej, (b) strona przednia, (c) widok z boku

Źródło: materiały Netrix S.A.

Rysunek 5.10 przedstawia elektrody ETI zamocowane na ścianie badanego obiektu. Elektrody są przymocowane do metalowych listew, z możliwością regulacji. Pozwala to na ich równomierne rozmieszczenie wzdłuż badanej powierzchni. Na rysunku 5.9a widoczne są obie listwy z elektrodami. Elektrody są rozmieszczone w równych odstępach, co jest kluczowe dla zapewnienia jednolitego pola pomiarowego i dokładności pomiarów. Każda elektroda posiada elastyczny przewód, który jest połączony z systemem akwizycji danych. Przewody są dobrze zorganizowane i zabezpieczone, co jest ważne dla utrzymania stabilności połączeń oraz ochrony przed mechanicznymi uszkodzeniami. Rysunek 5.9b prezentuje górną część lewej listwy, co pozwala na dokładniejszy ogląd sposobu montażu elektrod. Widać sposób, w jaki elektrody

są mocowane do listwy – co ma na celu zapewnienie zarówno stabilności, jak i niezbędnej elastyczności, umożliwiającej dobry kontakt elektrod z nierówną powierzchnią muru.



Rys. 5.10. Widok elektrod przyłożonych do powierzchni muru ceglanego: (a) widok obu listew z elektrodami, (b) widok górnej części lewej listwy

Źródło: materiały Netrix S.A.

5.4. Modelowanie fragmentu muru metodą elementów skończonych

Aby wykorzystać metodę elementów skończonych do modelowania rozkładu konduktywności wewnątrz murów, potrzebny jest model siatki. Tworzenie siatek FEM 3-D stanowi fundamentalny aspekt zaawansowanych aplikacji tomografii, w szczególności w dziedzinie tomografii impedancji elektrycznej i tomografii optycznej rozproszonej. Współpracujące z Matlabem oprogramowanie Eidors (ang. *electrical impedance and diffuse optical tomography reconstruction software*) jest popularnym narzędziem wykorzystywanym w badaniach tomograficznych, a odpowiednia siatka 3-D jest kluczowym składnikiem obrazowania tomograficznego [1]. Model FEM badanego obiektu można wykonać, korzystając z wbudowanych funkcji pakietu Eidors, jednak nie jest to jedyna

opcja. Dostępne są specjalistyczne programy komputerowe, które umożliwiają efektywne tworzenie siatek kompatybilnych z biblioteką Eidors. Ich wykorzystanie zapewnia elastyczność i precyzję w modelowaniu złożonych struktur 3-D. Jednym z uznanych i powszechnie stosowanych pakietów oprogramowania do tworzenia siatek jest Gmsh. Wzmiankowane oprogramowanie wyróżnia się intuicyjnym interfejsem użytkownika, który ułatwia proces tworzenia i edycji siatek FEM. Za jego pomocą można opracowywać siatki zarówno płaskie 2-D, jak również przestrzenne 3-D. Oprogramowanie Gmsh oferuje dość szeroki zakres funkcji. Należą do nich: automatyczne i ręczne tworzenie siatek, możliwość wyboru różnych kształtów elementów skończonych (trójkąty, czworokąty i heksagony) oraz możliwość definiowania złożonych geometrii. Jedną z kluczowych zalet Gmsh jest bezpośrednia kompatybilność z Eidors. Dzięki temu pliki zawierające sparametryzowane siatki FEM wygenerowane w Gmsh mogą być odczytane i wykorzystane w symulacjach realizowanych za pomocą Matlaba wyposażonego w pakiet narzędziowy Eidors.

Kolejny zaawansowany generator siatek FEM to Netgen. Wspomniany pakiet zyskał popularność wśród naukowców i inżynierów z uwagi na możliwość generowania plików w formacie CGNS (CFD General Notation System). CGNS jest szeroko stosowanym standardem w obliczeniach dynamiki płynów. Oprogramowanie jest kompatybilne z Eidors. Netgen umożliwia tworzenie siatek 3-D z różnymi typami elementów, koncentrując się na czworokątach i heksagonach.

Spośród pakietów oprogramowania umożliwiających tworzenie siatek FEM, na uwagę zasługuje TetGen. Jest to specjalistyczne narzędzie ukierunkowane na tworzenie siatek czworokątnych (ang. *tetrahedron*). TetGen zyskał uznanie z powodu wysokiej jakości i dokładności. Siatki czworokątne są szczególnie przydatne w metodzie elementów skończonych, ponieważ zapewniają elastyczność i dokładność w modelowaniu złożonych kształtów 3-D. TetGen oferuje szerokie spektrum funkcjonalności, w tym obsługę różnych typów danych wejściowych, takich jak chmury punktów, powierzchnie i objętości. Pliki wyjściowe TetGen można konwertować na formaty kompatybilne z Matlab/Eidors, co czyni go cennym narzędziem w procesie przygotowywania siatek do symulacji.

W przypadku bardziej złożonych wymagań dotyczących tworzenia siatek FEM, takich jak obszerne projekty inżynierskie lub badania naukowe, odpowiednim narzędziem jest komercyjne oprogramowanie ANSYS Mesh. Pakiet ANSYS Mesh umożliwia tworzenie siatek 3-D, w tym siatek heksagonalnych (układ plastra miodu) i czworokątnych. Oprogramowanie posiada spory zakres opcji umożliwiających dostosowanie siatek do konkretnych uwarunkowań

i ograniczeń związanych z obiektem badań. Z uwagi na to, że pakiet ANSYS Mesh jest komercyjnym oprogramowaniem, jego wszechstronność i szeroki zakres funkcji sprawiają, że jest on powszechnie stosowany w branży i badaniach akademickich. Pliki zawierające parametry FEM wygenerowane przez oprogramowania ANSYS można konwertować na formaty kompatybilne z Matlab/Eidors przy użyciu odpowiednich narzędzi konwersji.

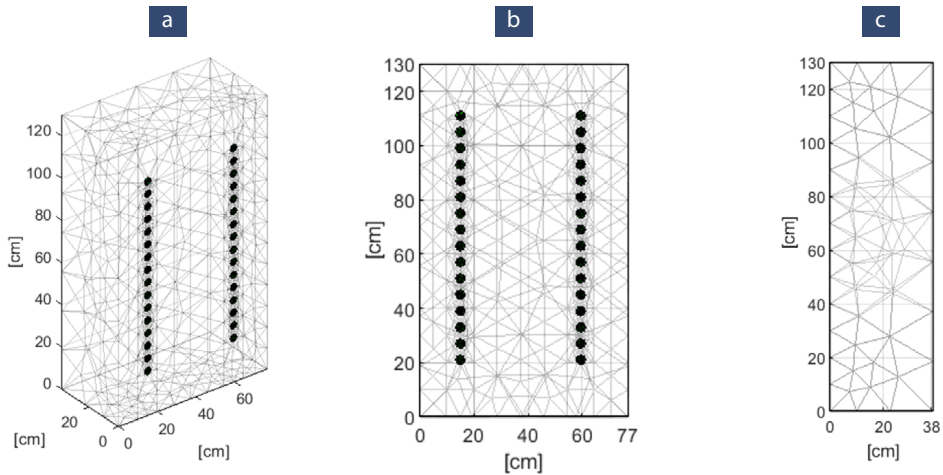
Kolejnym narzędziem przeznaczonym do tworzenia siatek FEM jest ITK-SNAP. Oprogramowania jest stosowane głównie do segmentacji obrazów, jednak oferuje również możliwości tworzenia siatek 3-D. ITK-SNAP umożliwia ręczne lub półautomatyczne tworzenie siatek na podstawie obrazów medycznych, takich jak MRI (rezonans magnetyczny) lub CT (tomografia komputerowa). Powyższa funkcjonalność jest szczególnie przydatna w aplikacjach medycznych i biologicznych, gdzie istnieje potrzeba dokładnego odwzorowania ludzkiej anatomii. Wygenerowane siatki można wyeksportować do formatów plików kompatybilnych z Matlab/Eidors, co pozwala na integrację z zaawansowanymi możliwościami symulacyjnymi tego oprogramowania.

Podczas tworzenia siatek 3-D dla Eidors lub innych aplikacji tomograficznych należy zwrócić uwagę, że gęstość i kształt elementów siatki powinny być dobrane w zależności od specyfiki problemu. Projektując siatkę FEM do generowania pomiarów symulacyjnych, należy wziąć pod uwagę konkretne wymagania związane z symulowanym procesem pomiarowym. W szczególności są to: wzorzec stymulacji elektrod, warunki brzegowe, parametry materiałowe i właściwości fizyczne obiektu badań.

Na rysunku 5.11 przedstawiono model FEM muru opisanego na początku tego rozdziału (rysunek 5.1). Siatka modelu składa się z 3050 czworobocznych elementów skończonych. Warto zauważyć, że gęstość wokseli (przestrzennych elementów skończonych) nie jest jednolita w całej objętości modelowanego muru. Obszary wokół elektrod są podzielone na większą liczbę wokseli niż obszary od nich oddalone. Wynika to z faktu, że gęstość pola elektrycznego maleje wraz z odległością od źródła prądu. Dlatego najlepszą rozdzielczość obrazu można uzyskać w obszarach leżących bliżej elektrod. Rozdzielczość obrazu spada wraz z odległością od elektrod.

W tabeli 5.1 przedstawiono szczegółowy opis pól zmiennej strukturalnej zawierającej pełną informację określającą model siatki FEM widoczny na rysunku 5.11. Głównym komponentem modelu jest zmienna strukturalna *fwd_model*, służąca do opisu i symulacji przepływu prądu elektrycznego przez badany obiekt. W skład zmiennej *fwd_model* wchodzi kilka elementów. Wśród nich kluczowa jest informacja o typie modelu, który może być prosty lub

odwrotny, zdefiniowany jako ciąg znaków w polu *type*. Nazwa modelu może być dowolna i jest przechowywana w polu *name*. Informacje o geometrii modelu zawarte są w polu *nodes*, które przedstawia współrzędne węzłów w trzech wymiarach, oraz w polu *elems*, gdzie przez indeksy węzłów zdefiniowane są elementy siatki. Taki zapis pozwala na dokładne określenie kształtu i struktury badanego obiektu. Granice modelu są określone, również przez indeksy węzłów, w polu *boundary*. Indeksy określają, które z węzłów tworzą zewnętrzną powierzchnię modelu. Pole *gnd_node* to węzeł uziemiający, kluczowy dla określenia punktu odniesienia dla potencjałów elektrycznych.



Rys. 5.11. Model FEM muru z elektrodami:
 (a) widok aksonometryczny, (b) widok ortogonalny ściany z elektrodami,
 (c) widok boczny, w którym elektrody znajdują się po lewej stronie

Elektrody, które są niezbędnym komponentem systemu do generowania i odbierania sygnałów w modelu ETI, zostały parametrycznie opisane w strukturze *electrode*. Każda elektroda ma przypisane indeksy węzłów, które wskazują jej położenie, oraz wartość $z_contact$, która opisuje opór styku elektrody mający wpływ na pomiar impedancji. Do obliczeń numerycznych wykorzystywane są specjalne funkcje. Macierz systemowa obliczana jest za pomocą funkcji *system_mat*. Funkcja *solve* służy do rozwiązywania równań modelu, a *jacobian* do obliczenia macierzy Jacobiego, która jest wymagana w iteracyjnym procesie optymalizacji do rozwiązania problemu odwrotnego.

Pole binarne *normalize_measurements* to flaga decydująca o tym, czy pomiary mają być znormalizowane. Powyższa cecha wpływa na dokładność i stabilność wyników. Pola *T_subdomain* i *T_subdomain_unique* zawierają

informacje o subdomenach elementów, co jest używane w zaawansowanych technikach modelowania do zdefiniowania różnych regionów modelu z unikalnymi właściwościami. Protokół pomiarowy, czyli tzw. stymulacja w modelu ETI, jest zdefiniowana w strukturze *stimulation*, która zawiera typ stymulacji, wzory stymulacji dla elektrod (*stim_pattern*) oraz wzory pomiarów odpowiedzi na stymulację (*meas_pattern*). Te informacje są niezbędne do sterowania przebiegiem procesu pomiarowego.

Ostatnie pole, *elem_data*, przechowuje wartości elementów skończonych siatki modelu. Jak już wcześniej wspomniano, w przypadku ETI są to wartości konduktywności elektrycznej, które są obliczane w wyniku rozwiązania problemu odwrotnego (wyjścia). Wejściami (argumentami funkcji) są tzw. jednostki umowne, czyli wartości odczytane z przetwornika, mocno skorelowane z napięciami.

Tabela. 5.1. Opis zmiennej strukturalnej modelu FEM dla pakietu Eiders


Nazwa elementu	Typ danych i wymiary	Opis
fwd_model	struct [1×1]	Główna struktura modelu prostego
├ type	char [1×9]	Typ modelu (prosty lub odwrotny)
├ name	char [1×13]	Nazwa modelu (dowolna nazwa)
├ nodes	double [1113×3]	Współrzędne węzłów modelu (x, y, z)
├ elems	double [3050×4]	Elementy siatki zdefiniowane przez indeksy węzłów
├ boundary	uint32 [2016×3]	Granice modelu zdefiniowane przez indeksy węzłów
├ gnd_node	double [1×1]	Węzeł uziemiający w modelu
├ electrode	struct [1×32]	Elektrody użyte w modelu, każda z dodatkowymi parametrami
├ nodes	double [1×12]	Indeksy węzłów danej elektrody
└ z_contact	double [1×1]	Wartość oporu styku elektrody
├ system_mat	function_handle [1×1]	Uchwyt funkcji do obliczania macierzy systemowej
├ solve	function_handle [1×1]	Uchwyt funkcji do rozwiązywania równań modelu
├ jacobian	function_handle [1×1]	Uchwyt funkcji do obliczenia macierzy Jacobiego
├ normalize_measurements	logical [1×1]	Flaga określająca, czy pomiary mają być znormalizowane
├ T_subdomain	double [3050×1]	Informacje o subdomenach elementów
├ T_subdomain_unique	double [1×3]	Unikalne wartości subdomen

Tabela. 5.1. Opis zmiennej strukturalnej modelu FEM dla pakietu Eiders

Nazwa elementu	Typ danych i wymiary	Opis
└ stimulation	struct [1×32]	Informacje o stymulacji w modelu
└ stimulation	char [1×3]	Typ stymulacji
└ stim_pattern	double [32×1]	Wzór stymulacji dla elektrod
└ meas_pattern	double [28×32]	Wzór pomiarowy odpowiedzi na stymulację
elem_data	double [3050×1]	Dane elementów modelu, takie jak konduktywność elektryczna

5.5. Protokół pomiarowy

Rysunek 5.12. przedstawia trzy początkowe subsekwencje protokołu pomiarowego dla 32 elektrod rozmieszczonych w dwóch równoległych rzędach (2×16). Panel (a) przedstawia pierwszy krok z szesnastu, w którym zasilanie przyłączono do elektrod 1 i 17. Ponieważ elektrody 1 i 17 są elektrodami zasilającymi, nie uczestniczą one w pomiarach. Na czerwono zaznaczono elektrodę wzbudzącą, natomiast kolorem niebieskim oznaczono elektrodę masową. Pozostałe elektrody zostają wykorzystane do pomiarów napięcia. Jak wynika z rysunku 5.12, dla każdej pary elektrod zasilających można dokonać 28 pomiarów napięć. Panele (b) i (c) przedstawiają kolejne kroki odpowiadające zmianom par elektrod zasilających. Taki protokół pomiarowy został wykorzystany we wszystkich pomiarach opisanych w niniejszym opracowaniu. Jego skuteczność została potwierdzona empirycznie.



Rys. 5.12. Trzy początkowe subsekwencje protokołu pomiarowego dla 32 elektrod rozmieszczonych w dwóch równoległych rzędach 2×16 : (a) subsekwencja pierwsza, (b) subsekwencja druga, (c) subsekwencja trzecia

5.6. Generowanie syntetycznych danych uczących

Problemy odwrotne, w przeciwieństwie do problemów prostych, nie mają jednoznacznych rozwiązań. Często są to problemy źle uwarunkowane (ang. *ill-posed*) w sensie Hadamarda, co oznacza, że nie spełniają wszystkich warunków dla dobrze postawionych problemów matematycznych. Dla problemów źle postawionych nie zawsze istnieje rozwiązanie, które dokładnie odpowiada obserwacjom [63]. Zgodnie z drugim kryterium, istnieje wiele różnych parametrów lub konfiguracji, które mogą prowadzić do tych samych wyników obserwacji. Ostatnie kryterium stwierdza, że małe zmiany w danych wejściowych mogą prowadzić do dużych zmian w rozwiązaniu. Powyższe wady dotyczą głównie metod deterministycznych rozwiązywania problemów odwrotnych. Aby poprawić jakość rozwiązań problemów źle postawionych, z powodzeniem stosuje się modele oparte na uczeniu maszynowym.

Wśród metod uczenia maszynowego najskuteczniejsze jest tzw. uczenie nadzorowane. Ta technika wymaga jednak dysponowania zbiorem uczącym,

w którym każda próba (obserwacja) zawiera zarówno dane wejściowe (np. pomiary lub cechy), jak i odpowiadające im etykiety wyjściowe (tzw. cele lub wzorce). Tego rodzaju zbiory uczące są wykorzystywane w procesie trenowania modeli, aby nauczyć je przewidywania wyników na podstawie nowych, nieznanych wcześniej danych. Dane wejściowe (cechy) to różne atrybuty lub właściwości, które opisują każdy przypadek. Mogą to być liczby, wartości katagoryczne, dane tekstowe, obrazy lub inne formy reprezentujące kluczowe cechy obiektu lub zjawiska.

Etykiety wyjściowe (cele) to wartości, które trenowany model ma za zadanie przewidzieć. Dla problemów klasyfikacyjnych są to konkretne klasy/kategorie (np. nazwa rozpoznanego przedmiotu, identyfikator stanu procesu). W problemach regresyjnych wyjściami są wartości liczbowe (np. wartość konduktywności, cena nieruchomości, prawdopodobieństwo). Zarówno wejścia, jak i wyjścia mogą być pojedynczymi wartościami (skalarami) lub zbiorami wartości (wektorami). W przypadku sieci LSTM wejściami mogą być nawet zbiory sekwencji, czyli struktury macierzowe. Modele mające za zadanie predykcję złożonych problemów, w których zależności między wejściem a wyjściem są nieliniowe, a wejścia i wyjścia są wektorami, wymagają dużej liczby obserwacji.

Przed rozpoczęciem procesu uczenia dane są zazwyczaj dzielone na trzy zbiory: uczący, walidacyjny i testowy. Zbiór uczący jest wykorzystywany do trenowania modelu. Zadaniem zbioru walidacyjnego jest dostrojenia hiperparametrów i ocena wydajności podczas trenowania. Metoda wczesnego zatrzymania (ang. *early stopping*), która zatrzymuje proces uczenia po zadanej liczbie następujących po sobie epok, w których błąd walidacyjny nie maleje, również wykorzystuje zbiór walidacyjny [114]. Zbiór testowy służy do ostatecznej oceny wydajności po zakończeniu całego procesu trenowania modelu. Proporcje podziału danych na poszczególne zbiory mogą się różnić, ale typowe wartości to 70% danych uczących, 15% danych walidacyjnych i 15% danych testowych.


Miarą jakości sieci neuronowej jest jej zdolność do generalizowania wyników. Zdolność do generalizacji sieci neuronowej polega na umiejętności poprawnego przewidywania wyników dla nowych, niewykorzystanych w trakcie uczenia danych. Mała liczba przypadków uczących z dużym prawdopodobieństwem doprowadzi do przeuczenia modelu (ang. *overfitting*), co będzie skutkowało brakiem zdolności do generalizacji. W konsekwencji, nawet jeśli model uzyska wysoki wskaźnik zgodności predykcji na zbiorze uczącym i walidacyjnym, to na skutek zbyt małej liczby przypadków nie sprawdzi się w praktyce.

W celu umożliwienia trenowania modelu symulacyjnie wygenerowano zbiór danych obejmujący wektory pomiarów napięcia i wektory konduktywności.

Algorytm generujący dane uczące ETI, odpowiednie do wytrenowania sieci neuronowej lub innego modelu bazującego na uczeniu maszynowym, został opracowany w języku Matlab z wykorzystaniem pakietu Eidors. Algorytm rozpoczyna się od wczytania dwóch zmiennych. Pierwsza zmienna zawiera strukturę modelu z siatką FEM. Jest to ta sama zmienna, która została szczegółowo opisana w rozdziale 5.4., w tabeli 5.1. Model struktury zawiera informacje geometryczne, węzły i elementy siatki, natomiast dane o stymulacji definiują, w jaki sposób do badanego fragmentu muru zostanie zaaplikowany prąd i jak będzie przebiegał pomiar napięć poprzez system elektrod. Zmienna druga dotyczy konfiguracji procesu stymulowania elektrod w trakcie cyklu pomiarowego, co zostało szeroko opisane w rozdziale 5.5.

Po wczytaniu powyższych zmiennych algorytm inicjalizuje nową zmienną zawierającą liczbę elektrod, konfigurację stymulacji oraz oblicza środki elementów czworościennych w siatce FEM. Następnie rozpoczyna tworzenie zbioru danych uczących poprzez dodanie dwóch scenariuszy bazowych: referencyjnego stanu obiektu, w którym wszystkie woksele mają wartość 1 oznaczającą brak wilgoci, oraz stanu całkowitego zawilgocenia, kiedy wszystkie woksele mają wartość 10. Dla stanu referencyjnego algorytm oblicza wartości konduktywności elementów, uwzględniając tzw. parametr materiałowy, czyli przewodność właściwą badanego ośrodka. Następnie algorytm oblicza odpowiedzi pomiarowe przy użyciu funkcji *fwd_solve*, czyli rozwiązując problem prosty. Uzyskane w ten sposób dane są zapisane jako pierwszy zestaw danych uczących. W przypadku stanu całkowitego zawilgocenia algorytm ustawia wartości przewodności wszystkich elementów na jednolitą wartość reprezentującą zawilgocenie i ponownie rozwiązuje problem prosty, transformując konduktywności na pomiary napięcia w modelu, zapisując przewodności elementów skończonych i odpowiedzi pomiarowe jako drugi zestaw danych.

Po zapisaniu danych dla dwóch pierwszych stanów bazowych algorytm przechodzi do pętli głównej, w której generuje losowe konfiguracje zawilgocień wewnątrz obiektu. Każda iteracja generuje losowe położenie centrum obszaru wilgotnego oraz losowe rozmiary elipsoidy. Następnie algorytm definiuje różne wartości progowe w celu zmiany przewodności w tych obszarach modelu, w których znajdują się elementy (woksele) zawilgocone. Dla każdego elementu FEM przewodność jest ustawiana na wyższą wartość, jeśli znajduje się on w wyznaczonej elipsoidzie. Rysunek 5.13 przedstawia przykładowe zawilgocenie wygenerowane przez powyższy algorytm.



Rys. 5.13. Symulacyjnie wygenerowany przypadek uczący, obrazujący losowe zawilgoconie: (a–c) widoki obszaru zawilgoconego z różnych stron, (d) wykres 448 pomiarów napięcia wyrażony w jednostkach umownych

Poszczególne obrazy na rysunku oraz wykres pokazują, jak wygląda obszar zawilgoconia oraz jak zmieniają się pomiary napięcia w odpowiedzi na to zawilgoconie. Panele (a), (b) i (c) przedstawiają model muru z elektrodami, gdzie obszar zawilgoconia jest zaznaczony jako ciemnoczerwony. Trzy różne perspektywy dają lepszy ogłęd modelu. Widoki aksonometryczne (a) i (c) pozwalają zobaczyć głębokość i położenie zawilgoconia względem elektrod. Widok ortogonalny (b) ściany z elektrodami przedstawia rozkład zawilgoconia od frontu, wyraźnie pokazując umiejscowienie elektrod w dwóch rzędach na ścianie.

Wykres (d) przedstawia wyniki 448 pomiarów napięcia wyrażone w jednostkach umownych. Wahania napięcia pokazują reakcje na zawilgoconie z uwzględnieniem wpływu losowych elementów modelu. Linie przedstawiają różnice w pomiarach między elektrodami, co sugeruje, jak zmiany przewodności wpływają na rozkład potencjału na powierzchni muru. Dodatnie i ujemne wartości napięcia (jednostek umownych) odzwierciedlają kierunek różnicy potencjałów między elektrodami, co ma związek z kierunkiem przepływu prądu. W kontekście konduktywności badanego materiału, a tym samym zawilgoconia, istotna jest przede wszystkim wielkość bezwzględna zmierzonego napięcia, ponieważ to ona wskazuje na zmiany w przewodności materiału. Zerowa wartość napięcia oznacza, że obszar między elektrodami jest suchy.

Rysunek 5.12 kompleksowo przedstawia model zawilgocenia muru z różnymi widokami oraz pomiarami, co umożliwi zrozumienie problemu odwrotnego w kontekście elektrycznej tomografii impedancyjnej.

Po przetworzeniu wszystkich elementów algorytm analizuje, czy dana konfiguracja przewodności nie jest jednorodna, co jest objawem zawilgocenia. Jeśli tak, algorytm oblicza odpowiedzi pomiarowe dla tej konfiguracji przy użyciu funkcji *fwd_solve* i zapisuje wyniki w zbiorze danych uczących. Proces ten jest wielokrotnie powtarzany w kolejnych iteracjach, generując szerokie spektrum losowych zawilgoceń. Różnorodne odpowiedzi pomiarowe stanowią podstawę do skutecznego trenowania modeli ETI o dużej efektywności użytkarnej.

Końcowym krokiem algorytmu jest zapisanie wynikowego zbioru danych uczących w postaci pliku. Symulując różne scenariusze i rozkłady przewodności elektrycznej w badanym obiekcie, algorytm jest w stanie generować reprezentatywne zestawy danych uczących dla modelu algorytmicznego, transformującego pomiary na obrazy w ramach systemu tomograficznego.

5.7. Preprocessing – przygotowanie danych do trenowania, walidacji i testowania

Proces przygotowania danych jest jednym z kluczowych elementów skutecznego opracowania i oceny modeli ETI. Obejmuje on gromadzenie/generowanie, przetwarzanie i podział danych na zbiory uczący, walidacyjny i testowy.

Pierwszym krokiem jest zgromadzenie danych tomograficznych, które zostaną wykorzystane do trenowania, walidacji i testowania modeli uczenia maszynowego. Dane mogą być zarówno rzeczywiste, pochodzące z pomiarów ETI, jak i syntetyczne, wygenerowane symulacyjnie przy użyciu algorytmu.

W kolejnym kroku dane mogą zostać poddane wstępnemu przetwarzaniu (ang. *preprocessing*). Powyższe działania mogą obejmować w szczególności normalizację wartości, uwzględnienie szumu pomiarowego, redukcję zmiennych wejściowych wzajemnie skorelowanych i inne operacje.

5.7.1. Normalizacja danych

Normalizacja danych to proces przekształcania pierwotnych wartości do określonego przedziału. Celem jest usunięcie różnic w skalach danych i ustandaryzowanie ich do porównywalnego zakresu. Poprzez normalizację dane są skalowane w taki sposób, aby miały zbliżone wartości lub rozkłady, co eliminuje

potencjalne problemy związane z różnicami w jednostkach miar lub skalach wartości. Dzięki normalizacji zazwyczaj uzyskuje się poprawę wydajności algorytmów uczenia maszynowego. Eliminacja różnic w skalach cech ułatwia porównywanie danych poprzez ustandaryzowanie ich do wspólnego zakresu. Do innych korzyści należy zwiększenie stabilności numerycznej obliczeń, szczególnie w przypadku algorytmów opartych na gradientach. W rezultacie normalizacja danych przyczynia się do lepszej generalizacji modelu, ułatwia analizę danych oraz zapewnia stabilność i skuteczność obliczeń. Normalizację można stosować nie tylko na wejściu modelu, lecz także po każdej warstwie, która przekształca wejścia na nowe wartości.

Wśród najczęściej stosowanych metod normalizacji należy wymienić normalizację Min-Max, normalizację Z-Score oraz normalizację logarytmiczną. Pierwsza z nich opiera się na skalowaniu wartości do przedziału $[0, 1]$, co polega na odjęciu od każdej wartości danych wartości minimalnej i podzieleniu wyniku przez różnicę wartości maksymalnej i minimalnej. Znormalizowaną wartość danej cechy metodą Min-Max można obliczyć jako:

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (5.1)$$

gdzie: X to wartość danej cechy, X_{min} to minimalna wartość danej cechy w zbiorze danych, X_{max} to maksymalna wartość danej cechy w zbiorze danych.

Druga metoda, oparta na odchyleniu standardowym, polega na odjęciu od każdej wartości danych średniej i podzieleniu wyniku przez odchylenie standardowe. Wyraża to formuła

$$X_{norm} = \frac{X - \mu}{s} \quad (5.2)$$

gdzie: μ to średnia wartość danej cechy w zbiorze danych, s to odchylenie standardowe danej cechy w zbiorze danych. Normalizacja logarytmiczna opiera się na zastosowaniu funkcji logarytmicznej do każdej wartości danych i może być wyrażona formułą $X_{norm} = \log X$. Domyślną metodą normalizacji stosowaną w oprogramowaniu Matlab jest metoda centroidowa (ang. *zerocenter*). Polega ona na odjęciu od każdej wartości średniej wartości ze zbioru danych. W rezultacie wszystkie wartości danych zostają przesunięte tak, aby ich średnia wynosiła zero. Podczas procesu uczenia maszynowego, w algorytmach takich jak regresja liniowa i sieci neuronowe, zastosowanie normalizacji typu centroid zwykle poprawia konwergencję. Dzieje się tak, ponieważ normalizacja

zapewnia wszystkim cechom podobną skalę. Ułatwia to algorytmowi identyfikację i naukę zależności między cechami a celem. W niektórych modelach uczenia maszynowego, do których zalicza się także regresja liniowa, interpretacja parametrów modelu jest łatwiejsza, gdy dane są znormalizowane wokół zera (średnia wynosi zero). Stanowi to kolejną zaletę tej metody. Normalizację centroidową można wyrazić formułą $X_{norm} = X - \mu$. Trzeba zauważyć, że normalizacja centroidowa może nie być odpowiednia dla wszystkich typów danych. W niektórych przypadkach normalizacja może prowadzić do utraty informacji lub utrudniać interpretację wyników. Dlatego przed zastosowaniem normalizacji ważne jest, aby rozumieć zarówno specyfikę problemu, jak i użytych danych.

Wybór odpowiedniej metody normalizacji zależy od wielu czynników, takich jak rozkład danych, obecność wartości ekstremalnych oraz wymagania konkretnego algorytmu uczenia maszynowego. W przypadku typów danych innych niż liczbowe, stosuje się inne metody, takie jak kodowanie one-hot lub kodowanie binarne. Celem jest przekształcenie innych typów danych w dane numeryczne, które można następnie znormalizować. Normalizacja jest ważnym krokiem w procesie analizy danych: umożliwia poprawę wydajności algorytmów, ułatwia porównywanie danych oraz zwiększa stabilność numeryczną obliczeń.

5.7.2. Zaszumianie danych pomiarowych

W celu uwzględnienia realistycznych warunków i zwiększenia odporności modelu na szum zawarty w danych pomiarowych dane syntetyczne można symulacyjnie zaszumiać. Zazwyczaj proces sztucznego zaszumiania odbywa się poprzez dodanie szumu Gaussa o określonym poziomie. Szum ten symuluje różnice między danymi rzeczywistymi a danymi uzyskanymi z symulacji.

Szum w pomiarach ETI stanowi istotny problem, negatywnie wpływający na jakość uzyskiwanych obrazów oraz utrudniający poprawną interpretację wyników. Źródła szumu można podzielić na wewnętrzne i zewnętrzne. Wewnętrzne źródła obejmują szum termiczny, wynikający z chaotycznego ruchu elektronów w przewodniku, szum elektrolityczny, związany z ruchem jonów w elektrolicie, szum kontaktowy, pochodzący z niestabilnych połączeń elektrycznych między elektrodami a badanym obiektem, oraz szum polaryzacyjny, wynikający z procesów polaryzacji i depolaryzacji elektrod. Zewnętrzne źródła szumu obejmują szum elektromagnetyczny, generowany przez pola elektromagnetyczne urządzeń elektronicznych, szum mechaniczny, wynikający z wibracji lub ruchów obiektu

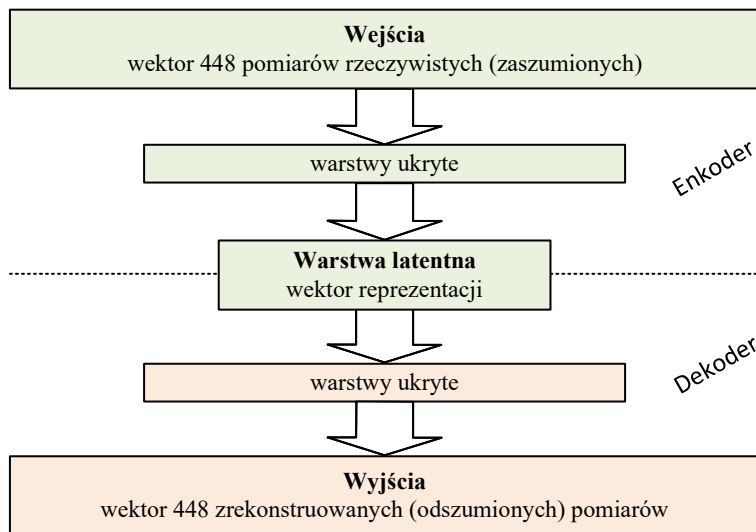
badanego lub elektrod, oraz szum cyfrowy, związany z kwantyzacją sygnałów analogowych na cyfrowe. Szum negatywnie wpływa na dokładność diagnoz i utrudnia śledzenie zmian w czasie, dlatego kluczowe jest identyfikowanie i redukcja szumu w celu uzyskania wiarygodnych wyników ETI. Skoro nie można całkowicie uniknąć szumu w trakcie pomiarów rzeczywistych, wskazane jest, aby w warunkach symulacyjnych nie pomijać tego zjawiska.

Symulacyjne dodanie szumu do danych pomiarowych umożliwia ocenę odporności modelu na zakłócenia i niestabilności w danych. Ponadto sprawia, że model będzie w stanie generalizować na nowe, nieznane dane wejściowe. Dodanie syntetycznego zaszumienia przybliży model symulacyjny do rzeczywistych warunków pomiarowych, które mogą być obciążone pewnym poziomem szumu. Nie ma podstaw by twierdzić, że sztuczne zaszumienie danych symulacyjnych jest zawsze potrzebne, ale jest to opcja, która powinna być analizowana przed planowaniem procesu uczenia każdego modelu ETI.

5.7.3. Odszumianie pomiarów rzeczywistych z wykorzystaniem autoenkoderów

Z uwagi na charakterystyki prądów elektrycznych i zakłóceń występujących w badanych obiektach rzeczywistych, dane pomiarowe pozyskiwane z ETI zawierają szum utrudniający prawidłową rekonstrukcję obrazów [43, 75, 100]. W tym kontekście jednym z nowocześniejszych podejść do odszumiania surowych danych są autoenkodery [79, 94]. Autoenkodery są rodzajem sieci neuronowych, które uczą się reprezentacji wejściowych danych w bardziej skompresowanej formie [125]. Składają się one z dwóch głównych części: enkodera, sieci neuronowej, która przekształca dane wejściowe na zredukowaną reprezentację wewnętrzną warstwy latentnej, oraz dekodera, który próbuje odtworzyć oryginalne dane na podstawie tej reprezentacji [9, 162]. Warstwa latentna (ukryta) w autoenkoderze to warstwa, która znajduje się głęboko wewnątrz struktury pomiędzy warstwą wejściową a warstwą wyjściową i reprezentuje skompresowaną wersję danych wejściowych. Jest to wewnętrzna, abstrakcyjna reprezentacja, która zawiera najważniejsze cechy danych w zredukowanej formie. Warstwa latentna odgrywa kluczową rolę w kodowaniu informacji, umożliwiając modelowi naukę istotnych cech, które mogą zostać wykorzystane do rekonstrukcji (dekodowania) danych wyjściowych z minimalną utratą informacji. W procesie uczenia autoenkoder uczy się odwzorowywać dane wyjściowe, minimalizując różnice pomiędzy własnym wejściem a wyjściem [165]. Ten proces jest kluczowy w kontekście odszumiania, ponieważ

autoenkoder uczy się ignorować szum w danych wejściowych i generować czyste, zrekonstruowane dane wyjściowe. Na rysunku 5.14 przedstawiono przykładową strukturę autoenkodera odsumiającego dane pomiarowe.



Rys. 5.14. Przykładowa struktura autoenkodera odsumiającego

Warstwa wejściowa i wyjściowa są wektorami składającymi się z 448 pomiarów. Warstwa ukryta (latentna) składa się z 64 neuronów. Dzięki takiej strukturze neurony warstwy latentnej zmuszane są do skompresowania 448-elementowego wektora pomiarowego do 64-wartościowej reprezentacji. Jest to sposób na pozbycie się zbędnych informacji, w tym także szumu pomiarowego.

Autoenkodery można trenować na dużych zbiorach danych symulacyjnych. Dzięki temu mogą się one nauczyć charakterystyki szumu i odpowiednich wzorców danych pomiarowych. Na etapie trenowania autoenkodera zbiór uczący składa się z danych zasumionych oraz odpowiadających im danych niezasumionych. Sieć neuronowa uczy się na tych parach, jak odseparować szum od wartościowych informacji. Po zakończeniu procesu trenowania autoenkoder może być zastosowany do przetwarzania nowych danych zasumionych. W ten sposób wyniki uzyskane na jego wyjściu są pozbawione szumu. Ponieważ mamy do czynienia z problemem regresyjnym, nie jest możliwe całkowite odsumienie pomiarów. W zależności od struktury autoenkodera, parametrów procesu uczenia, jakości i ilości posiadanych danych uczących, specyfiki problemu i wielu innych czynników poziom redukcji szumu może się znacząco wahać.

Po zakończeniu procesu odszumiania dane mogą być użyte do rekonstrukcji obrazu tomograficznego. Odszumione dane pomiarowe są podstawą do uzyskania obrazów rekonstrukcyjnych o wyższej jakości niż w przypadku danych surowych. Dzięki temu wizualizacja funkcji wewnętrznych organizmu jest dokładniejsza, co umożliwi lepszą diagnozę i monitorowanie stanu zawilgocenia badanego fragmentu muru.

W trakcie prac badawczych nad modelami wykorzystanymi w niniejszym opracowaniu sprawdzono skutki, jakie przyniesie odszumianie danych autoenkoderem. Stwierdzono, że zarówno w przypadku obrazowania murku w warunkach laboratoryjnych, jak również w przypadku Złotej Bramy w Gdańsku zastosowanie odszumiania danych nie poprawia jakości rekonstrukcji. Przyczyną jest fakt, że sieci neuronowe wytrenowane na danych wysokiej jakości, dzięki swoim właściwościom uogólniającym, mają zdolność do radzenia sobie z szumem. Dodatkowe odszumianie może być zbędne, a nawet szkodliwe, jeśli sieć została nauczona, aby radzić sobie z pomiarami o pewnym poziomie zaszumienia.

Odszumianie danych pomiarowych w elektrycznej tomografii impedancyjnej z wykorzystaniem autoenkoderów stanowi obiecujące podejście do problemu zniekształceń wynikających z zakłóceń podczas wykonywania pomiarów. Mimo wyzwań, jakie niesie za sobą ten proces, autoenkodery mogą poprawić jakość obrazów ETI, umożliwiając dokładniejsze diagnozy oraz lepsze monitorowanie badanych obiektów. Pomimo faktu, że to rozwiązanie wymaga dalszych badań i ulepszeń, to już teraz otwiera nowe perspektywy w obrazowaniu ETI.

5.7.4. Redukcja wzajemnie skorelowanych zmiennych wejściowych

W elektrycznej tomografii impedancyjnej, podobnie jak w przypadku innych modeli predykcyjnych opartych na uczeniu maszynowym, istnieje potencjalny problem skorelowanych zmiennych wejściowych. Wspomniana korelacja może wynikać z samej natury pomiarów. Zmiany natężenia pola elektrycznego w jednym regionie badanego obszaru wpływają na zmierzone napięcia w różnych punktach układu elektrod, prowadząc do sytuacji, w której pomiary zawierają informacje częściowo redundantne. Skorelowane zmienne wejściowe mogą prowadzić do nadmiarowości informacji, a także wprowadzać szумы i błędy, co negatywnie wpływa na dokładność rekonstrukcji.

Jedną z najbardziej znanych metod redukcji wzajemnie skorelowanych zmiennych jest analiza głównych składowych (PCA, ang. *principal component*

analysis), która pozwala na przekształcenie skorelowanych zmiennych w zestaw głównych składowych o niższym stopniu korelacji. Dzięki temu procesowi możliwe jest zmniejszenie wymiaru danych wejściowych bez znaczącej utraty informacji.

Innym podejściem do tego problemu jest wykorzystanie selekcji cech (ang. *feature selection*), gdzie spośród dostępnych pomiarów wybiera się tylko te, które są najbardziej informatywne. W metodzie selekcji cech chodzi więc o wybór podzbioru zmiennych najbardziej istotnych dla danego zadania analitycznego spośród dostępnych danych wejściowych. Głównym celem tej metody jest zwiększenie efektywności modelowania poprzez redukcję wymiarów danych, która polega na eliminacji zmiennych nadmiarowych lub mało istotnych, które mogłyby wprowadzać niepotrzebny szum lub złożoność. Określenie „najbardziej informatywne” odnosi się do tych cech, które dostarczają najwięcej wartościowej informacji w kontekście konkretnego zadania, takiego jak klasyfikacja czy regresja. Takie cechy mają silny związek z przewidywaną wartością i zawierają unikalną informację, niepowielającą się z innymi cechami. Wybierając zmienne najbardziej informatywne, można zredukować ilość danych wejściowych, zachowując jednocześnie lub nawet poprawiając jakość przewidywań modelu.

Algorytmy selekcji, takie jak Lasso (ang. *least absolute shrinkage and selection operator*) czy metody opierające się na drzewach decyzyjnych, potrafią efektywnie zidentyfikować zbędne zmienne, pozwalając na ich eliminację. Istnieje możliwość stworzenia rankingu zmiennych wejściowych w kolejności od najmniej skorelowanych do najbardziej redundantnych, dzięki czemu można dowolnie ustawić granicę odcięcia/odrzućenia zmiennych o zbyt dużym stopniu skorelowania.

W odniesieniu do problemu skorelowanych zmiennych wejściowych coraz częściej stosuje się techniki uczenia maszynowego. Modele regresji wielowymiarowej, sieci neuronowe, autoenkodery czy algorytmy typu „ensemble” są trenowane w taki sposób, aby uwzględniały zależności między różnymi pomiarami. Rolą algorytmu jest także minimalizacja poziomu zaszumienia danych w sekwencji pomiarowej, a także tzw. nadmiarowości. Nadmiarowość dotyczy sytuacji, kiedy wartości wektora pomiarowego są wzajemnie skorelowane, redundantne lub niezmiennie.

Problem skorelowanych zmiennych wejściowych w ETI można rozwiązać poprzez stosowanie zaawansowanych technik analizy danych. Metody takie jak PCA, selekcja cech czy modele uczenia maszynowego przyczyniają się do usprawnienia procesu rekonstrukcji obrazów, umożliwiając uzyskanie lepszych rezultatów obrazowania.

5.7.5. Analiza wpływu zmiennych wejściowych na wyniki modelu

Problem nieskorelowanych zmiennych wejściowych z wyjściami dotyczy sytuacji, w której pomiary napięć uzyskane z układu elektrod wykazują słabą lub znikomą zależność z wyjściami, czyli konduktywnością elementów skończonych siatki FEM badanego obiektu. Jest to zjawisko szczególnie problematyczne, gdy celem jest precyzyjne odtworzenie dystrybucji przewodności w badanym obiekcie, ponieważ brak wyraźnych korelacji ogranicza dokładność rekonstrukcji obrazu. Nieskorelowane z tomogramem dane pomiarowe mogą prowadzić do powstania niejednoznacznych map przewodności, co utrudnia interpretację wyników oraz identyfikację rozkładów zawilgocenia.

Analiza wrażliwości w kontekście ETI polega na badaniu, w jakim stopniu zmiany w poszczególnych pomiarach napięć wpływają na wyniki rekonstrukcji konduktywności. Metody lokalne, takie jak metoda różnic skończonych, analizują wpływ małych modyfikacji napięcia na określony obszar przewodności, co umożliwia zrozumienie efektów lokalnych. Natomiast metody globalne, do których należy analiza Monte Carlo, obejmują szerokie spektrum zmian dotyczących wielu pomiarów jednocześnie. Wymieniona metoda polega na wykorzystaniu symulacji losowych do oceny wpływu zmienności różnych parametrów wejściowych na wyniki modelu. Metoda Monte Carlo umożliwia sprawdzenie wpływu różnych konfiguracji pomiarów wejściowych na wektor wyjściowy modelu. Stanowi to element tzw. analizy wrażliwości, polegającej na ustaleniu procentowego wpływu poszczególnych wartości wejściowych na wygląd tomogramu. Powyższe podejście umożliwia uzyskanie całościowego obrazu zależności między wejściami a wyjściami, a także identyfikację tych pomiarów, które są najbardziej istotne dla odwzorowania rozkładu konduktywności w obrębie siatki elementów skończonych. Eliminując pomiary nieistotne, można zmniejszyć złożoność obliczeniową modelu, co ułatwia jego trenowanie.

Inną grupą metod służących do podnoszenia jakości danych wejściowych poprzez ich redukcję jest analiza istotności. Analiza istotności zmiennych wejściowych w uczeniu maszynowym pozwala zidentyfikować te cechy, które mają największy wpływ na dokładność rekonstrukcji obrazów. Wśród metod stosowanych w analizie istotności zmiennych wejściowych w uczeniu maszynowym wyróżnić można testy statystyczne, które określają wpływ danej cechy na wynik, oceniając procentowo korelację między zmienną wejściową a zmienną docelową. Popularne są testy takie jak analiza wariancji (ANOVA) czy test chi-kwadrat, które dostarczają metryk porównawczych dla zmiennych

kategorycznych. Te metody dostarczają cennych informacji na temat wpływu poszczególnych cech, choć nie są w stanie uchwycić pełnego, nieliniowego charakteru interakcji między zmiennymi.

Dla zmiennych regresyjnych (liczb rzeczywistych) najczęściej stosowane są metody oceniające istotność zmiennych poprzez analizę korelacji czy regresji. Adekwatną metodą regresyjną jest korelacja Pearsona. Wspomniana metoda umożliwia pomiar liniowej zależności między zmiennymi ciągłymi. Współczynnik korelacji Pearsona określa siłę i kierunek związku między zmienną wejściową a zmienną docelową. Inną skuteczną metodą jest Lasso. Jest to technika regularyzacji, która nakłada dodatkowe ograniczenia na współczynniki regresji, wymuszając zerowe wartości dla mniej istotnych zmiennych. Jest to pomocne w trakcie procesu selekcji cech.

Innym podejściem do oceny istotności zmiennych jest wykorzystanie modeli uczenia maszynowego. Na przykład algorytm lasów losowych, ze swoją zdolnością do losowego próbkowania cech i agregowania wyników wielu drzew decyzyjnych, oferuje naturalną metodę oceny istotności zmiennych poprzez badanie wpływu każdej z nich na dokładność klasyfikacji lub regresji. Gdy zmienna jest losowo modyfikowana lub usuwana, wpływ tej zmiany na wynik modelu pozwala ocenić jej znaczenie dla procesu decyzyjnego. Lasy losowe, poprzez agregację wielu drzew decyzyjnych, dają dokładniejsze wyniki w zakresie istotności. Podobne podejście stosuje się w technice zwanej rekurencyjną eliminacją cech (ang. *recursive feature elimination*), która polega na iteracyjnym trenowaniu modelu, eliminując najmniej istotne cechy w każdym kroku, aż do uzyskania optymalnego podzbioru.

Modele oparte na uczeniu głębokim również oferują narzędzia do oceny istotności cech [91]. W przypadku sieci neuronowych z wieloma warstwami analiza gradientów wstecznych pozwala na śledzenie wpływu każdej zmiennej wejściowej na końcowy wynik modelu. Dzięki tej technice można wykrywać subtelne wzorce w danych, których klasyczne metody statystyczne nie są w stanie zidentyfikować.

W metodzie regresji liniowej oraz regresji wielokrotnej analizowany jest wpływ zmiennych wejściowych na zmienną docelową, szacując wartości współczynników. Wielkość współczynników i ich istotność statystyczna (*p-value*) pomagają zidentyfikować najważniejsze zmienne.

W kontekście tomografii ETI analiza istotności zmiennych wejściowych pozwala określić, które wartości wejściowe z wektora pomiarowego mają największy wpływ na rekonstrukcję obrazów. Dzięki temu procesowi można zoptymalizować strukturę sekwencji wejściowej modelu uczenia maszynowego,

zwiększając efektywność obrazowania i zdolność do generowania obrazów o wysokiej rozdzielczości.

W elektrycznej tomografii impedancyjnej problem nieskorelowanych lub nieistotnych zmiennych wejściowych może obniżać jakość odwzorowań dystrybucji konduktywności, co utrudnia uzyskanie wartościowych wyników. Analizy wrażliwości i istotności pomagają zidentyfikować pomiary napięć, które są kluczowe dla jakości rekonstrukcji, umożliwiając zaprojektowanie skuteczniejszego modelu transformującego pomiary na obrazy tomograficzne.

Analizy wrażliwości i istotności są elementami selekcji cech (ang. *feature selection*), która ma na celu usunięcie zbędnych zmiennych wejściowych. Oba typy analizy działają w synergii, dostarczając różnorodnych, a zarazem komplementarnych spojrzeń na proces selekcji cech. Analiza wrażliwości, skupiając się na elastyczności modelu, pozwala określić, które zmienne są stabilne i wpływowe, natomiast analiza istotności, oparta na miarach statystycznych, umożliwia skonstruowanie minimalnego zbioru cech wejściowych o maksymalnym wpływie na wynik. Obie metody umożliwiają podniesienie jakości modeli predykcyjnych opartych na uczeniu maszynowym.

5.8. Warianty architektury sieci neuronowej

W tym rozdziale przedstawiono kilka modeli sieci neuronowych, które zostały zastosowane w ramach eksperymentów badawczych dotyczących pomiaru wilgotności murów przy użyciu metody elektrycznej tomografii impedancyjnej. Opracowanie kilku wariantów modeli pozwoliło na przeprowadzenie porównań kluczowych różnic, zalet oraz ograniczeń poszczególnych architektur, umożliwiając pełniejsze zrozumienie ich efektywności i adaptacyjności w specyficznym kontekście badawczym.

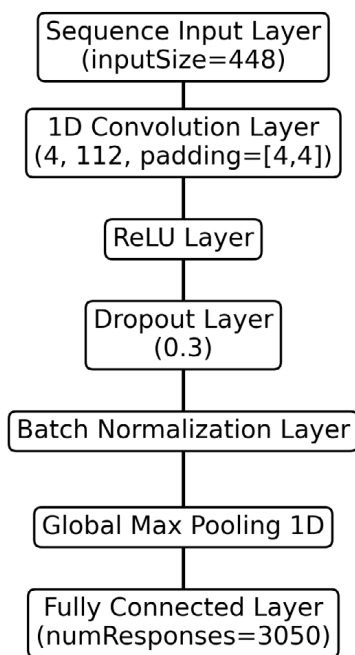
5.8.1. Sieć neuronowa z warstwą konwolucyjną

Rysunek 5.15 i tabela 5.2 przedstawiają strukturę sieci neuronowej z warstwą konwolucyjną, której zadaniem jest konwersja wektora 448 pomiarów napięć wygenerowanych przez elektrody na obraz składający się z 3050 elementów przestrzennej siatki FEM. Pomimo faktu, że obraz jest przestrzenny, warstwy sieci są jednowymiarowe (1-D). Jest to podyktowane wektorowym (sekwencyjnym) formatem danych wejściowych i regresyjnym charakterem problemu.

Pierwszą warstwą, która przyjmuje dane sekwencyjne o określonym rozmiarze, jest *sequenceInputLayer*. Zmienna *inputSize* określa liczbę cech każdego elementu w sekwencji. Warstwa ta nosi nazwę „feature”, co jest istotne dla identyfikacji i odwołań w bardziej złożonych architekturach sieciowych.

Tabela. 5.2. Lista warstw sieci CNN

Lp.	Typ warstwy	Opis
1	Sequence Input	448-elementowe wejście sekwencyjne
2	1-D Convolution	112 filtrów 4-elementowych z krokiem 1 i dopełnieniem (ang. <i>padding</i>) [4 4]
3	ReLU	Funkcja transferowa ReLU
4	Dropout	30% deaktywowanych neuronów
5	Batch Normalization	Normalizacja partii
6	1-D Global Max Pooling	Redukcja złożoności, wyróżnienie najbardziej istotnych cech
7	Fully Connected	3050-elementowa warstwa w pełni połączona



Rys. 5.15. Struktura warstw modelu sieci CNN

Następną warstwą jest *convolution1dLayer*. Jej parametry wskazują, że konwolucja 1-D będzie wykonywana za pomocą 112 filtrów z rozmiarem filtra równym 4. Parametr *Padding* ustawiony na [4, 4] pozwala na dodanie zer na

końcach sekwencji. Umożliwia to filtrowi zachowanie wymiarów wyjściowych zbliżonych do wymiarów wejściowych.

Warstwa aktywacji *reluLayer* stosuje funkcję transferową ReLU (ang. *rectified linear unit*), która wprowadza nieliniowość do modelu, przepuszczając tylko dodatnie wartości sygnału. Warstwa ReLU jest standardem w uczeniu głębokim. Zwiększa ona dynamikę uczenia i umożliwia uniknięcie problemu z zanikającym gradientem.

Warstwa *dropoutLayer* z parametrem równym 0,3 realizuje proces losowej dezaktywacji 30% neuronów. „Dropout” jest techniką regularyzacji używaną do zapobiegania nadmiernemu dopasowaniu poprzez zmuszenie sieci do tworzenia bardziej odpornych i zrównoważonych reprezentacji cech.

Kolejna warstwa, *batchNormalizationLayer*, normalizuje aktywacje poprzedzającej warstwy na każdym etapie procesu uczenia. Przyczynia się to do stabilizacji tego procesu, przyspiesza konwergencję i umożliwia stosowanie wyższych szybkości uczenia. W praktyce oznacza to, że dzięki zastosowaniu odpowiednich technik, takich jak normalizacja wsadowa (ang. *batch normalization*), można bezpiecznie zwiększyć współczynnik uczenia w procesie trenowania sieci neuronowej. Współczynnik uczenia, inaczej nazywany szybkością uczenia, to parametr w algorytmie optymalizacyjnym, który określa, jak dużą zmianą wag sieci neuronowej może być odpowiedź na błąd funkcji straty (ang. *loss function*) wykryty w pojedynczej iteracji procesu uczenia.

Warstwa *globalMaxPooling1dLayer* redukuje wymiary danych poprzez wybranie maksymalnej wartości z każdego kanału cech w ramach całej długości sekwencji. Działanie tej warstwy rozpoczyna się od przeglądania każdego kanału cech w danej sekwencji i wyboru największej cechy z całego zestawu wartości. To działanie sprowadza informacje z całej sekwencji do pojedynczego zestawu wartości maksymalnych dla każdego kanału. Selekcja maksymalnych wartości z sekwencji znacząco redukuje liczbę wymiarów danych, co pomaga w zmniejszeniu złożoności modelu i redukuje liczbę parametrów. Jest to szczególnie korzystne w przypadku, gdy dane wejściowe mają długie sekwencje lub duże wymiary. Ponieważ opisywana warstwa redukuje ilość danych, ograniczone zostaje ryzyko przeuczenia. Model pozbawiony przez warstwę *globalMaxPooling1dLayer* wielu potencjalnych nośników informacji automatycznie skupia się na najbardziej istotnych cechach sekwencji.

Ostatnią warstwą jest *fullyConnectedLayer*. Jest to klasyczna warstwa w pełni połączona, która agreguje cechy z całej sekwencji do postaci, która może być użyta do dalszej klasyfikacji lub regresji, zależnie od zastosowania

sieci. W tym przypadku liczba neuronów w warstwie *fullyConnectedLayer* jest równa liczbie elementów skończonych siatki FEM, czyli 3050.

Każda z wyżej opisanych warstw odgrywa istotną rolę w przetwarzaniu i analizie danych sekwencyjnych, gdzie kolejne warstwy transformują dane wejściowe na coraz bardziej abstrakcyjne reprezentacje, pozwalając modelowi na naukę złożonych i trudnych do uchwycenia zależności ukrytych w danych pomiarowych. Algorytm 5.1 przedstawia sposób zakodowania struktury sieci neuronowej i konfiguracji procesu trenowania modelu w języku Matlab.

Algorytm. 5.1. Matlab R2024a – kodowanie architektury modelu CNN i procesu uczenia

```
% Parametry wejść i wyjść
inputSize = 448; % długość sekwencji wejściowej
numResponses = 3050; % wektor wyjściowy

% struktura sieci neuronowej
layers = [
    sequenceInputLayer(inputSize,"Name","sequence")
    convolution1dLayer(4,112,"Name","conv1d_1","Padding",[4 4])
    reluLayer("Name","relu_1")
    dropoutLayer(0.3,"Name","dropout")
    batchNormalizationLayer("Name","batchnorm")
    globalMaxPooling1dLayer("Name","gmpool1d")
    fullyConnectedLayer(numResponses,"Name","fc_1")];

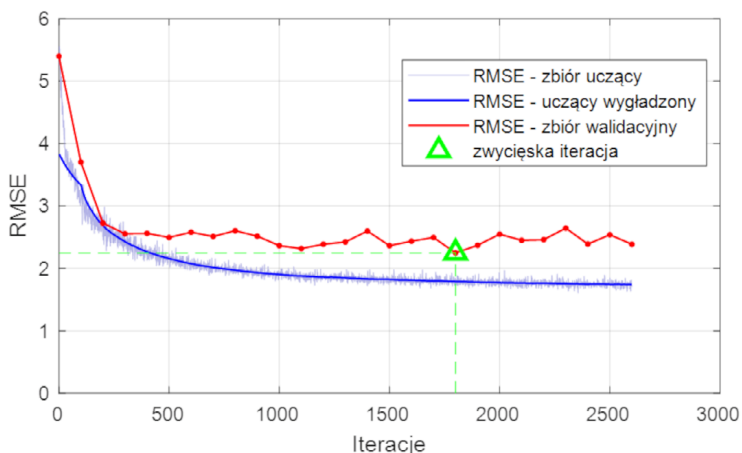
% konfiguracja procesu uczenia sieci neuronowej
options = trainingOptions('adam', ... % algorytm optymalizacji
    'ExecutionEnvironment','auto', ... % wybór: CPU lub GPU
    'MaxEpochs',500, ... % maksymalna liczba epok
    'ValidationData',{ValidInput,ValidPattern}, ... % ustawienie walidacji
    'ValidationFrequency',100, ... % częstość walidacji
    'ValidationPatience',8, ... % maks. liczba epok z niemalejącą stratą
    'MiniBatchSize', 128, ... % wielkość mini-partii
    'Shuffle','every-epoch', ... % tasuje dane przed każdą epoką
    'Metrics','rmse'); % używa błędu RMSE do walidacji modelu
```

Proces trenowania sieci neuronowej ma zasadniczy wpływ na jakość predykcyjną modelu. Parametry trenowania określają sposób, w jaki sieć jest iteracyjnie aktualizowana podczas procesu uczenia w oparciu o dostarczone

dane. Powyższy fragment kodu ma na celu skonfigurowanie procesu uczenia sieci neuronowej w środowisku MATLAB. Do tego celu wykorzystywana jest biblioteka Deep Learning Toolbox. Ustawienie „adam” jako metody optymalizacji pozwala skorzystać z algorytmu adaptacyjnego szacowania momentu (ang. *adaptive moment estimation*), znanego z adaptacyjnego dostosowywania tempa uczenia i efektywności w problematyce trenowania głębokich sieci neuronowych. Parametr „ExecutionEnvironment” ustawiony na „auto” umożliwi automatyczny wybór wykorzystywanego sprzętu (CPU lub GPU) dostępnego w systemie. Dzięki ustawieniu „MaxEpochs” na 500 sieć będzie trenowana przez maksymalnie 500 pełnych cykli, z uwzględnieniem wszystkich danych uczących. Opcja „ValidationData” pozwala na wskazanie zbiorów danych (pomiarów i wzorców obrazów), które będą używane do walidacji modelu w trakcie uczenia, co jest kluczowe dla monitorowania i zapobiegania przeuczeniu. Wartość „ValidationFrequency” ustawiona na 100 oznacza, że walidacja modelu będzie przeprowadzana co 100 iteracji, a „ValidationPatience” równa 8 wskazuje, że proces trenowania zostanie przerwany, jeśli przez 8 kolejnych epok nie zaobserwuje się poprawy wyników wskazanej metryki, jaką w tym przypadku jest RMSE (formuła 5.4) na zbiorze walidacyjnym. Parametr „MiniBatchSize” ustawiony na poziomie 128 określa liczbę próbek danych przetwarzanych jednocześnie w jednej iteracji.

Ustawienie parametru „Shuffle” na „every-epoch” sprawia, że dane są tasowane, czyli ich kolejność jest losowo zmieniana przed każdą nową epoką. Losowe zmiany kolejności wektora danych są pomocne w zapobieganiu nadmiernemu dopasowaniu sieci do danych uczących. Metryka „rmse” (*root mean square error*) jest używana do oceny jakości modelu na zbiorze walidacyjnym. Każdy z powyższych parametrów wpływa na efektywność procesu uczenia, umożliwiając dostosowanie modelu w trakcie jego tworzenia.

Na rysunku 5.15 przedstawiono wykres błędu RMSE w trakcie trenowania wyżej opisanej sieci neuronowej. Łączna liczba iteracji wynosiła 2600. Ponieważ wielkość minipartii (ang. *minibatch*) została ustalona na 128, a liczba przypadków w zbiorze uczącym wynosiła $N = 30678$, to jednokrotne przeliczenie wszystkich przypadków uczących, czyli jedna epoka, obejmowała 239 minipartii.



Rys. 5.16. Wykres funkcji błędu RMSE w procesie trenowania sieci CNN

Wynika to z podzielenia wielkości zbioru uczącego przez wielkość minipartii $30678/128 \approx 239$. Linia jasnoniebieską zaznaczono błąd RMSE dla poszczególnych iteracji. Linia ciemnoniebieską oznaczono uśrednioną (wygładzoną) wartość RMSE. Linia czerwoną oznaczono wartości błędu RMSE dla zbioru walidacyjnego. Błąd walidacyjny był obliczany co 100 iteracji. Zielonym trójkątem oznaczono iterację, która uzyskała najmniejszy błąd RMSE wg kryterium wczesnego zatrzymania (ang. *early stopping*). Jak wcześniej wspomniano, proces trenowania miał się zakończyć w dwóch przypadkach. Przypadek pierwszy dotyczył stanu, w którym po ośmiu kolejnych walidacjach błąd walidacji modelu nie spadał. Drugie kryterium zatrzymania określało maksymalną wartość parametru ograniczającego liczbę epok do 500. W rozpatrywanym przypadku uczenie sieci neuronowej zakończyło się automatycznie po spełnieniu pierwszego kryterium. Na rysunku 5.16 zielony trójkąt nie jest umiejscowiony na końcu wykresu, lecz właśnie 8 przeliczeń walidacyjnych wcześniej. Minimalny błąd walidacji $RMSE = 2,2479$ został uzyskany w 1800 iteracji. Metoda wczesnego zatrzymania jest skutecznym rozwiązaniem zapobiegającym przeuczeniu sieci. Zapewnia także automatyczne zatrzymanie procesu uczenia w odpowiednim momencie. Charakterystyczny, hiperboliczny i asymptotyczny kształt linii błędu uczącego, brak dużych i sporadycznych fluktuacji oraz wyraźna współbieżność linii błędu uczącego i walidacyjnego świadczą o braku przeuczenia modelu. Również fakt, że błąd walidacyjny jest nieco większy niż błąd uczący (linia czerwona znajduje się ponad linią niebieską) jest zrozumiałym zjawiskiem. Powodem jest dążenie dopasowania modelu do danych zawartych w zbiorze uczącym, ponieważ to one stanowią podstawę wyliczenia funkcji straty. Zbiór walidacyjny służy jedynie do

testowania warunku wczesnego zatrzymania. Dane zawarte w zbiorze walidacyjnym są więc większym wyzwaniem dla modelu, niż znane mu i po wielokroć przeliczane w iteracjach dane uczące.

Funkcja straty (ang. *loss*) wykorzystana w opisywanym modelu wylicza błąd średniokwadratowy między generowanymi wynikami sieci a wartościami wzorcowymi. Z uwagi na to, że wektor wyjściowy składa się z liczb rzeczywistych, mamy do czynienia z problemem regresyjnym. Funkcja straty jest obliczana według wzoru:

$$Loss = \frac{1}{2N} \sum_{i=1}^M (Y_i - T_i)^2 \quad (5.3)$$

gdzie N oznacza całkowitą liczbę obserwacji w zbiorze uczącym, M jest całkowitą liczbą odpowiedzi do każdej obserwacji i jednocześnie rozdzielczością siatki FEM. W opisywanym przypadku $N = 30678$, natomiast $M = 3050$. Y_i oznacza wygenerowaną przez model wartość predykcyjną i -tego woksela obrazu tomograficznego, natomiast T_i jest wartością referencyjną (wzorcową) i -tego woksela. Analogicznie błąd RMSE przyjmuje postać wzoru: (5.4).

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^M (Y_i - T_i)^2} \quad (5.4)$$

5.8.2. Sieć neuronowa z warstwą LSTM

Kolejnym modelem wytrenowanym w oparciu o te same dane, które zostały wykorzystane do wytrenowania modelu CNN, był model głębokiej sieci neuronowej wykorzystującej warstwę LSTM. Tabela 5.3 i rysunek 5.17 przedstawiają architekturę modelu. Szczegółowe informacje na temat działania sieci LSTM zostały zawarte w rozdziale 4.4. Rekurencyjne sieci LSTM.

Struktura sieci LSTM składa się z ośmiu głównych warstw. Pierwszą warstwą jest *Sequence Input*. Jest to wejście sekwencyjne, które przyjmuje dane w postaci wektora o długości 448. Ta warstwa nie posiada parametrów uczenia (ang. *learnable parameters*), co oznacza, że jest jedynie pasywnym elementem wyjściowym dla danych, który nie dokonuje żadnych przekształceń.

Druga warstwa to LSTM z 1024 jednostkami ukrytymi. Rozmiary parametrów uczenia dla tej warstwy to 4096×448 dla wag wejściowych, 4096×1024 dla wag rekurencyjnych i 4096×1 dla biasów. Wymiary stanów

to 1024×1 dla stanu ukrytego oraz 1024×1 dla stanu komórki, co wskazuje na dużą pojemność tej warstwy w zakresie przechowywania informacji sekwencyjnych.

Warstwa trzecia, *Batch Normalization*, czyli normalizacja partii, ma na celu stabilizację i przyspieszenie uczenia poprzez normalizację aktywacji. Warstwa ta posiada parametry uczenia offset (1024×1) oraz scale (1024×1), które są dostosowywane podczas trenowania.

Czwartą warstwą jest *dropout* z 50% prawdopodobieństwem wyłączenia losowych neuronów. Ta warstwa funkcjonuje jak mechanizm regularyzacji. Nie posiada ona parametrów uczenia, co jest charakterystyczne dla warstw typu dropout.

Piątą warstwą to warstwa w pełni połączona, *Fully Connected*, z 500 neuronami, które transformują dane z poprzednich warstw do wyjścia o niższej wymiarowości. Parametry uczenia to wagi (500×1024) i biasy (500×1).

Szóstą warstwą, tangens hiperboliczny, jest warstwą aktywacji. Ta warstwa również nie posiada parametrów uczenia. Jej główną funkcją jest wprowadzenie nieliniowości do przetwarzanych danych.

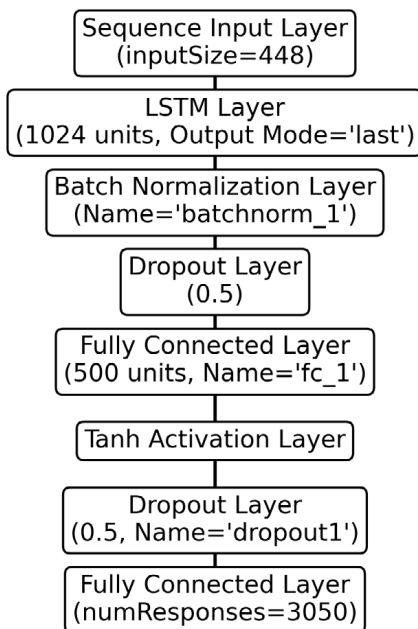
Kolejna warstwa *dropout* również ma 50% prawdopodobieństwo dezaktywacji neuronów i nie posiada parametrów uczenia, pełniąc rolę regularyzacji. Ostatnia, ósma warstwa to kolejna warstwa *Fully Connected*, w pełni połączona, z 3050 neuronami. Warstwa ta finalizuje przetwarzanie danych do postaci ostatecznych odpowiedzi sieci. Parametry uczenia to wagi (3050×500) i biasy (3050×1).

Tabela. 5.3. Lista warstw sieci LSTM

Lp.	Typ warstwy	Opis
1	Sequence Input	448-elementowe wejście sekwencyjne
2	LSTM	LSTM z 1024 jednostkami ukrytymi
3	Batch Normalization	Normalizacja partii
4	Dropout	50% deaktywowanych neuronów
5	Fully Connected	500-elementowa warstwa w pełni połączona
6	Tanh	Warstwa aktywacji z funkcją tangens hiperboliczny
7	Dropout	50% deaktywowanych neuronów
8	Fully Connected	3050-elementowa warstwa w pełni połączona

Na rysunku 5.17 znajduje się schemat blokowy poszczególnych warstw sieci neuronowej. Warto zauważyć, że w środek sieci wstawiono warstwę w pełni połączoną, liczącą jedynie 500 neuronów, która znajduje się między warstwą LSTM z 1024 jednostkami a warstwą wyjściową liczącą 3050 neuronów.

Nadaje to sieci kształt przypominający autoenkoder, gdzie warstwa latentna działa jak filtr, który odsiewa nieistotne informacje. Ten zamysł towarzyszył koncepcji projektowej niniejszego modelu.



Rys. 5.17. Struktura warstw modelu sieci LSTM

Algorytm. 5.2. przedstawia kodowanie architektury modelu LSTM i procesu uczenia. Parametr `layers` odzwierciedla architekturę i parametry warstw modelu. Z kolei zbiór parametrów procesu uczenia `options` jest tworzony za pomocą specjalnej funkcji `trainingOptions`. Proces trenowania modelu został sparametryzowany analogicznie jak do uczenia modelu CNN.

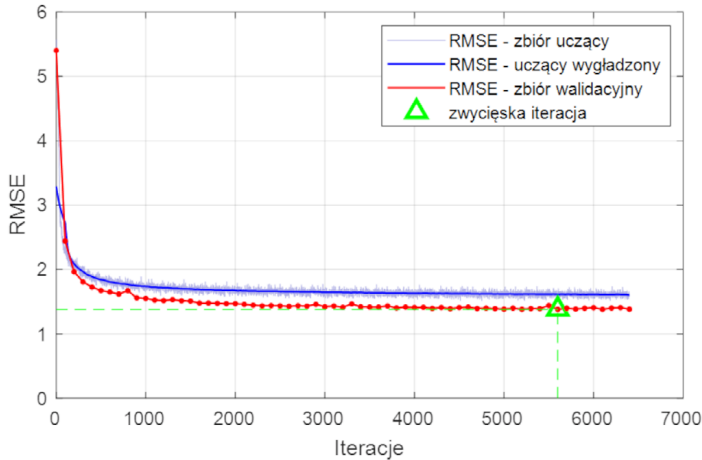
Algorytm. 5.2. Matlab R2024 – kodowanie architektury modelu LSTM i procesu uczenia

```
% Parametry wejść i wyjść
inputSize = 448; % długość sekwencji wejściowej
numResponses = 3050; % wektor wyjściowy

% struktura sieci neuronowej
layers = [
    sequenceInputLayer(inputSize,"Name","sequence")
    lstmLayer(1024,"Name","lstm","OutputMode","last")
    batchNormalizationLayer("Name","batchnorm_1")
    dropoutLayer(0.5,"Name","dropout")
    fullyConnectedLayer(500,"Name","fc_1")
    tanhLayer("Name","tanh")
    dropoutLayer(0.5,"Name","dropout1")
    fullyConnectedLayer(numResponses,"Name","fc_2")];

% konfiguracja procesu uczenia sieci neuronowej
options = trainingOptions('adam', ... % algorytm optymalizacji
    'ExecutionEnvironment','auto', ... % wybór: CPU lub GPU
    'MaxEpochs',500, ... % maksymalna liczba epok
    'ValidationData',{ValidInput,ValidPattern}, ... % ustawienie walidacji
    'ValidationFrequency',100, ... % częstość walidacji
    'ValidationPatience',8, ... % maks. liczba epok z niemalejącą stratą
    'MiniBatchSize', 128, ... % wielkość mini-partii
    'Shuffle','every-epoch', ... % tasuje dane przed każdą epoką
    'Metrics','rmse'); % używa błędu RMSE do walidacji modelu
```

Na rysunku 5.18 prezentowany jest wykres funkcji błędu RMSE (Root Mean Square Error) w procesie trenowania sieci LSTM. Wykres zawiera dane z całego procesu uczenia, obejmującego 7000 iteracji. Jak widać na wykresie, błąd RMSE dla zbioru uczącego (oznaczony jasnoniebieską linią) oraz dla zbioru uczącego wygładzonego (oznaczony ciemnoniebieską linią) spada gwałtownie w początkowej fazie uczenia, a następnie stabilizuje się, osiągając asymptotyczny kształt. Linia czerwona, reprezentująca błąd RMSE dla zbioru walidacyjnego, pokazuje podobną tendencję, co świadczy o dobrej generalizacji modelu dla danych walidacyjnych.



Rys. 5.18. Wykres funkcji błędu RMSE w procesie trenowania sieci LSTM

Zielony trójkąt wskazuje na iterację o numerze 5600. Ta iteracja zgodnie z kryterium wczesnego zatrzymania osiągnęła najmniejszy błąd wynoszący $RMSE = 1,3809$. Proces uczenia sieci został zakończony przed osiągnięciem maksymalnej liczby iteracji z powodu braku dalszej poprawy błędu walidacyjnego przez określoną liczbę epok, co jest zgodne z zastosowanym kryterium wczesnego zatrzymania. Takie zakończenie procesu uczenia ma na celu zapobieganie przeuczeniu, umożliwiając sieci zachowanie zdolności do generalizacji podczas analizowania nowych, nieprzetwarzanych wcześniej danych.

Analiza wykresu RMSE pozwala zauważyć, że sieć efektywnie nauczyła się złożonych zależności występujących w danych bez nadmiernego dopasowania, co jest potwierdzone przez stabilny i niski poziom błędu na zbiorze walidacyjnym. Ponadto brak dużych fluktuacji w wartościach błędu RMSE świadczy o wysokiej stabilności procesu uczenia, co także stanowi pozytywną rekomendację dla jakości modelu.

5.8.3. Sieć neuronowa o strukturze wielogałęzistej

Kolejnym modelem wytrenowanym na potrzeby rozwiązania tomograficznego problemu odwrotnego jest sieć neuronowa o strukturze trójgałęzistej, zawierająca warstwy LSTM. Struktura modelu została opisana w tabeli 5.4 i na rysunku 5.19. Pierwszą warstwą opisywanego modelu wielogałęzistej jest warstwa wejściowa o nazwie „sequence”, będąca wektorem o długości 448 jednostek.

Tabela. 5.4. Lista warstw sieci wielogałęziowej

Lp.	Typ warstwy	Opis
1	Sequence Input	448-elementowe wejście sekwencyjne
2	biLSTM	LSTM z 1024 jednostkami ukrytymi
3	Batch Normalization	Normalizacja partii
4	Dropout	50% deaktywowanych neuronów
5	Fully Connected	256-elementowa warstwa w pełni połączona
6	Tanh	Warstwa aktywacji z funkcją tangens hiperboliczny
7	Batch Normalization	Normalizacja partii
8	Dropout	50% deaktywowanych neuronów
9	Fully Connected	256-elementowa warstwa w pełni połączona
10	Tanh	Warstwa aktywacji z funkcją tangens hiperboliczny
11	Batch Normalization	Normalizacja partii
12	Dropout	50% deaktywowanych neuronów
13	Fully Connected	256-elementowa warstwa w pełni połączona
14	Tanh	Warstwa aktywacji z funkcją tangens hiperboliczny
15	Batch Normalization	Normalizacja partii
16	Dropout	50% deaktywowanych neuronów
17	Concat	768-elementowy wektor konkatencji łączący trzy wejścia z warstw 256-elementowych
18	biLSTM	LSTM z 1024 jednostkami ukrytymi
19	Batch Normalization	Normalizacja partii
20	Fully Connected	3050-elementowa warstwa w pełni połączona

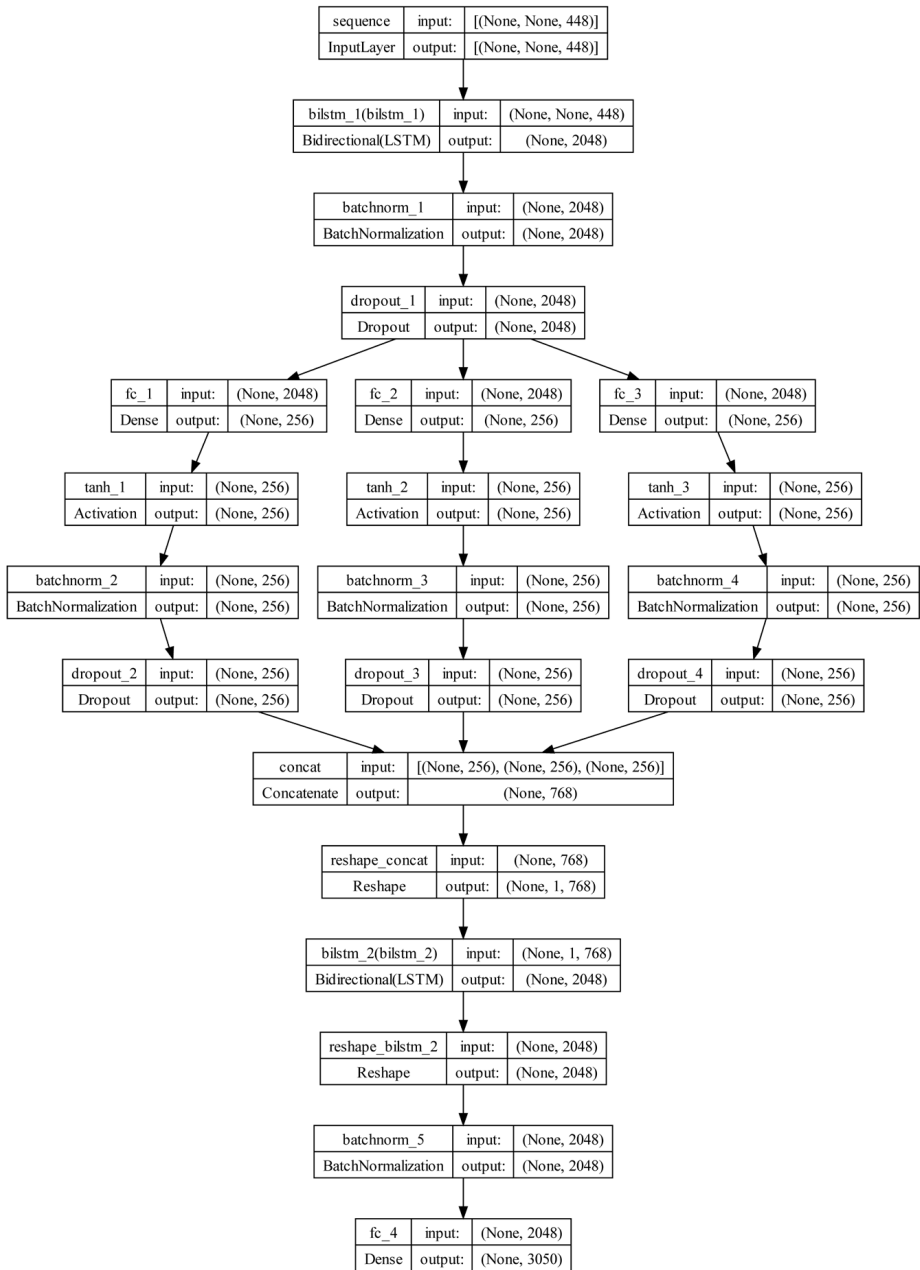
Następnie przetwarzanie danych kontynuowane jest przez warstwę bi-directional LSTM (biLSTM_1), która zawiera 1024 jednostki ukryte. Powyższa warstwa umożliwia efektywne przetwarzanie danych sekwencyjnych z uwzględnieniem kontekstu zarówno poprzedzającego, jak i następującego.

Porównując diagram przedstawiony na rysunku 5.19 z algorytmem 5.3. zawierającym kodowanie architektury modelu wielogałęziowego można zauważyć pewną różnicę w opisie warstwy biLSTM. Wg algorytmu opis warstwy jest następujący: `biLstmLayer(1024, "Name", "biLstm_1", "OutputMode", "last")`. Jak widać, argument informujący o liczbie elementów ukrytych wynosi 1024. Z kolei na rysunku 5.18 opis bloków warstw `biLstm_1` i `biLstm_2` informuje, że obie te warstwy mają na wyjściu wektory złożone z 2048 jednostek.

W strukturze przedstawionej na rysunku 5.19, opisy „None” odnoszą się do nieokreślonych wymiarów tensorów w warstwach sieci neuronowej, które

mogą zmieniać się w zależności od konkretnego zestawu danych. W zależności od rodzaju warstwy i miejsca występowania „None” może np. reprezentować liczbę próbek (batch size) lub odnosić się do zmiennych wymiarów sekwencji czasowych lub przestrzennych, jeśli takowe są obecne w danych wejściowych. Przykładowo dla warstwy „InputLayer” z wyjściem opisanym jako „[(None, None, 448)]” pierwsze „None” oznacza nieokreśloną liczbę próbek, drugie „None” oznacza zmienną długość sekwencji, a 448 to liczba cech (wymiar przestrzeni cech). Taki sposób zapisu sprawia, że diagram jest elastyczny w stosunku do liczby przetwarzanych próbek oraz długości danych wejściowych.

Dyskrepancja pomiędzy informacją w kodzie a tym, co pokazuje diagram, wynika z natury warstwy Bidirectional LSTM (biLSTM). Warstwa Bidirectional LSTM w rzeczywistości składa się z dwóch warstw LSTM, z których każda przetwarza dane wejściowe w przeciwnym kierunku: jedna przetwarza dane od początku do końca, a druga – od końca do początku. W kodzie argument `bilstmLayer(1024,...)` oznacza, że każda z warstw LSTM wewnątrz biLSTM ma 1024 jednostki. Wynika z tego, że każda z tych dwóch warstw LSTM generuje wektor o długości 1024 dla każdej sekwencji. Natomiast argument „Output-Mode”, „last” oznacza, że z każdej warstwy LSTM (w ramach bidirectional) zwracany jest tylko ostatni wyjściowy wektor z sekwencji, co jest typowe dla wielu zadań przetwarzania sekwencji, gdzie interesuje nas wynik na końcu przetwarzanej sekwencji.



Rys. 5.19. Struktura sieci neuronowej o strukturze wielogłęźnej

Algorytm. 5.3. Matlab: kodowanie architektury modelu wielogłęziowego

```
lgraph = layerGraph(); % Inicjalizacja grafu warstw

% Definicja i dodawanie pierwszej (centralnej) grupy warstw
tempLayers = [
    sequenceInputLayer(inputSize,"Name","sequence")
    bilstmLayer(1024,"Name","bilstm_1","OutputMode","last")
    batchNormalizationLayer("Name","batchnorm_1")
    dropoutLayer(0.5,"Name","dropout_1)];
lgraph = addLayers(lgraph,tempLayers); % Dodanie warstw do grafu

% Definicja i dodawanie drugiej (lewej) grupy warstw
tempLayers = [
    fullyConnectedLayer(256,"Name","fc_1")
    tanhLayer("Name","tanh_1")
    batchNormalizationLayer("Name","batchnorm_2")
    dropoutLayer(0.5,"Name","dropout_2)];
lgraph = addLayers(lgraph,tempLayers); % Dodanie warstw do grafu

% Definicja i dodawanie trzeciej (centralnej) grupy warstw
tempLayers = [
    fullyConnectedLayer(256,"Name","fc_2")
    tanhLayer("Name","tanh_2")
    batchNormalizationLayer("Name","batchnorm_3")
    dropoutLayer(0.5,"Name","dropout_3)];
lgraph = addLayers(lgraph,tempLayers); % Dodanie warstw do grafu

% Definicja i dodawanie czwartej (prawej) grupy warstw
tempLayers = [
    fullyConnectedLayer(256,"Name","fc_3")
    tanhLayer("Name","tanh_3")
    batchNormalizationLayer("Name","batchnorm_4")
    dropoutLayer(0.5,"Name","dropout_4)];
lgraph = addLayers(lgraph,tempLayers); % Dodanie warstw do grafu

% Definicja i dodawanie piątej (centralnej i łączącej) grupy warstw
tempLayers = [
    concatenationLayer(1,3,"Name","concat")
    bilstmLayer(1024,"Name","bilstm_2","OutputMode","last")
    batchNormalizationLayer("Name","batchnorm_5")
    fullyConnectedLayer(numResponses,"Name","fc_4)];
lgraph = addLayers(lgraph,tempLayers); % Dodanie warstw do grafu
```

Algorytm. 5.3. Matlab: kodowanie architektury modelu wielogałęziowego

```
% usunięcie zmiennych pomocniczych
clear templayers;

% łączenie grup/gałęzi warstw w jeden model sieciowy
lgraph = connectLayers(lgraph,"dropout_1","fc_1");
lgraph = connectLayers(lgraph,"dropout_1","fc_2");
lgraph = connectLayers(lgraph,"dropout_1","fc_3");
lgraph = connectLayers(lgraph,"dropout_2","concat/in1");
lgraph = connectLayers(lgraph,"dropout_3","concat/in2");
lgraph = connectLayers(lgraph,"dropout_4","concat/in3");
```

Ponieważ model ma dwie warstwy biLSTM (przetwarzające sekwencje w przeciwnych kierunkach), każda z nich zwraca wektor o długości 1024, zaś wyjście całej warstwy biLSTM jest konkatencją tych dwóch wektorów. Stąd na diagramie widnieje wartość wyjściowa 2048 (1024 z jednej strony + 1024 z drugiej strony). To wyjaśnia, dlaczego wyjście warstwy na diagramie jest podane jako 2048, mimo że każda pojedyncza LSTM ma 1024 jednostki. Po warstwie „bilstm_1” znajduje się warstwa normalizacji partii (batchnorm_1), która stabilizuje uczenie przez normalizację wyjść z poprzedniej warstwy, a po niej umieszczono warstwę „dropout_1”, która losowo dezaktywuje 50% neuronów, co zapobiega przeuczeniu sieci.

Dalej struktura rozgałęzia się na trzy niezależne ścieżki, każda z nich składa się z trzech warstw: w pełni połączonej (fc_1, fc_2, fc_3), warstwy aktywacji tangens hiperboliczny (tanh_1, tanh_2, tanh_3) oraz kolejnej normalizacji partii (batchnorm_2, batchnorm_3, batchnorm_4). Każda z tych gałęzi zawiera również warstwę typu dropout (dropout_2, dropout_3, dropout_4), ponownie dezaktywującą 50% neuronów. Wyjścia o długości wektora 256 z tych trzech gałęzi są następnie łączone w jedną warstwę przez operację konkatencji (concat), tworząc wektor o długości 768 ($256 + 256 + 256 = 768$) jednostek.

Łączenie gałęzi w sieciach neuronowych może być realizowane przez konkatencję lub sumowanie. Są to dwie różne metody fuzji informacji pochodzących z wielu gałęzi lub warstw. Każda z wymienionych metod ma swoje specyficzne zastosowania i efekty oddziałujące na wyniki działania sieci, co jest decydujące w kontekście architektury i celu danego modelu.


Konkatencja polega na połączeniu wyjść z różnych gałęzi poprzez ich dosłowne złączenie w jeden dłuższy wektor. Jeśli gałąź A generuje wektor o długości n , a gałąź B wektor o długości m , to po konkatencji otrzymujemy

wektor o długości $n + m$. Taka metoda zachowuje wszystkie informacje z obu gałęzi, nie dochodzi do ich zmieszania w sensie matematycznym. Konkatenacja jest szczególnie przydatna w sytuacji, gdy model powinien nauczyć się, jakie cechy z poszczególnych gałęzi są najbardziej istotne i jak je różnicować.

Sumowanie polega na dodaniu do siebie odpowiadających sobie elementów wektorów wyjściowych z różnych gałęzi. Aby to umożliwić, wszystkie łączone wektory powinny mieć tę samą długość. Jeśli wektory mają długość n , to wynik sumowania również będzie miał długość n . Metoda sumowania warstw prowadzi do bezpośredniego połączenia informacji z różnych źródeł. Sumowanie może być przydatne, gdy celem jest wzmocnienie określonych cech sygnału lub gdy różne gałęzie sieci są wyspecjalizowane w detekcji różnych, ale równie ważnych cech danej próbki. Wybór metody łączenia gałęzi sieci neuronowej zależy od specyficznych wymagań zadania i charakterystyki przetwarzanych przez model danych. Każda z dwóch wymienionych metod łączenia gałęzi sieci ma swoje zalety i może być bardziej odpowiednia w różnych scenariuszach.

Scalany w warstwie konkatenacji wektor jest poddawany przeliczeniom realizowanym przez kolejną warstwę biLSTM (bilstm_2). Jest to warstwa posiadająca 1024 jednostki ukryte. Duża liczba jednostek ukrytych zapewnia złożone przetwarzanie sekwencyjne, co zazwyczaj przekłada się na dokładniejsze identyfikowanie ukrytych zależności między wejściami a wyjściami. Po warstwie biLSTM dane przechodzą przez kolejną normalizację partii (batchnorm_5), a następnie trafiają do końcowej warstwy w pełni połączonej (fc_4), która generuje wektor wyjściowy o długości 3050 jednostek. Taka architektura pozwala na złożone przetwarzanie danych uzyskanych z różnych przypadków wzorcowych. Jest to szczególnie użyteczne w zadaniach wymagających rozumienia i integracji różnorodnych cech wejściowych w kontekście sekwencyjnym.

Rysunek 5.20 przedstawia wykres funkcji błędu RMSE, czyli podstawowego średniego błędu kwadratowego, w procesie trenowania sieci wielogałęziowej.



Rys. 5.20. Wykres funkcji błędu RMSE w procesie trenowania sieci wielogałęzowej

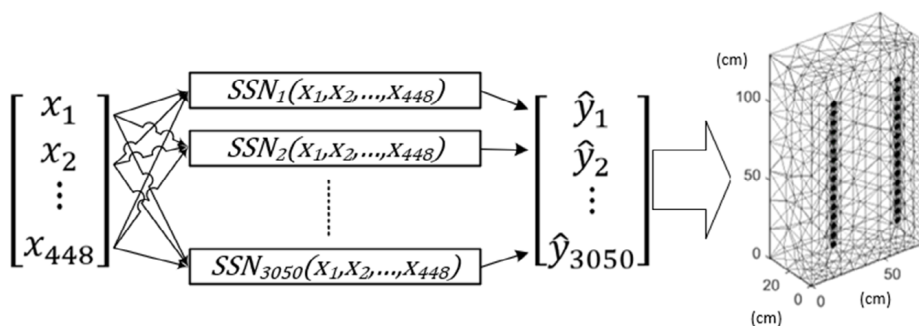
Cały cykl procesu uczenia obejmuje 5300 iteracji. Wykres błędu RMSE dla zbioru uczącego zarówno wygładzony, jak i uwzględniający wszystkie przypadki (niebieska linia) w początkowej fazie gwałtownie spadał, by następnie ustabilizować się na niskim poziomie. W końcowej fazie wykres ma przebieg asymptotyczny. Wykres świadczy o stabilizacji RMSE, co jest dowodem zdolności modelu do generalizacji nowych danych wejściowych. Linia czerwona, reprezentująca błąd RMSE dla zbioru walidacyjnego, jest współbieżna z linią błędu zbioru uczącego, co jest dowodem braku przeuczenia modelu.

Najniższy błąd walidacyjny $RMSE = 1,0809$, oznaczony zielonym trójkątem, został osiągnięty w iteracji numer 4500. Proces uczenia sieci został zaprojektowany, aby jednocześnie zapobiegać przeuczeniu i umożliwić sieci zachowanie zdolności do generalizacji. Kompromisem było ustawienie parametru określającego maksymalną liczbę odczytów błędu walidacyjnego na 8, co oznacza automatyczne zatrzymanie procesu uczenia, w przypadku gdy osiem kolejnych błędów walidacyjnych nie przyniesie poprawy. W rezultacie, pomimo że cały cykl procesu uczenia obejmował 5300 iteracji, iteracja 4500 została uznana za najlepszą i to sieć sparametryzowana właśnie po tej iteracji została zachowana.

Stabilny i niski poziom błędów RMSE na zbiorze walidacyjnym pokazuje, że sieć dobrze nauczyła się skomplikowanych zależności zawartych w danych. Ponadto brak znacznych wahań wartości RMSE wskazuje na wysoką stabilność procesu uczenia, co dobrze rokuje w kontekście jakości zaprojektowanego modelu.

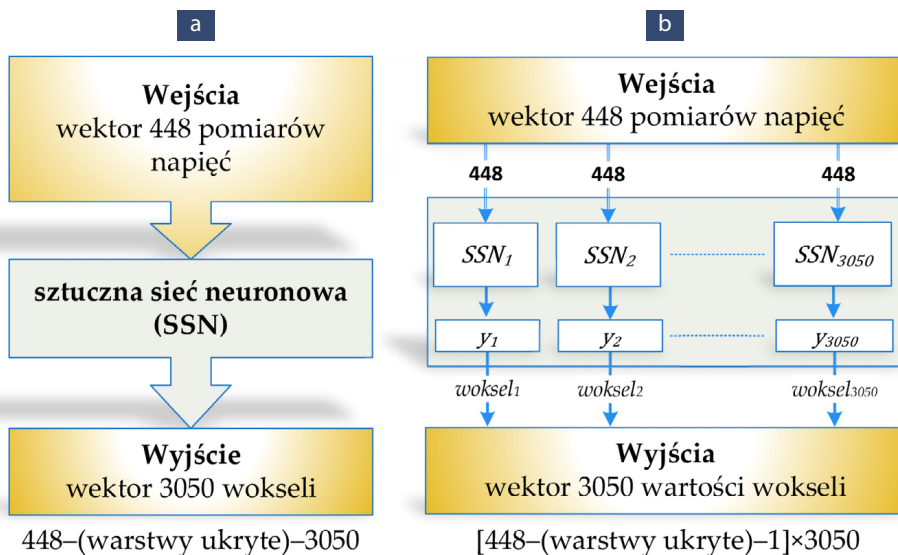
5.8.4. Wielokrotna sztuczna sieć neuronowa

Koncepcja wielokrotnych sztucznych sieci neuronowych (WSSN) została opisana w rozdziale 4.2. Wielokrotne sztuczne sieci neuronowe. WSSN to struktura składająca się z wielu osobno wytrenowanych sieci neuronowych (SSN) z pojedynczym wyjściem. Struktura zawiera tyle SSN, ile wynosi rozdzielczość siatki FEM. W opisywanym przypadku rozdzielczość jest równa 3050 wokseli, tak więc struktura WSSN zawiera 3050 sieci neuronowych, przy czym SSN dla każdego woksela był wytrenowany przy użyciu tego samego 448-elementowego wektora pomiarowego. Trenowanie polegało więc na dostosowaniu wag i biasów do danej wartości woksela (rys. 5.21).



Rys. 5.21. Zasada działania modelu WSSN

Rysunek 5.22 przedstawia porównanie dwóch podejść do modelowania sieci neuronowych w kontekście elektrycznej tomografii impedancyjnej (ETI) stosowanej do detekcji wilgoci w murach. Na rysunku zilustrowano dwa modele: tradycyjny model sztucznej sieci neuronowej (SSN) oraz koncepcję WSSN (wielokrotnej SSN), która zakłada trenowanie wielu sieci SSN z pojedynczymi wyjściami. W modelu tradycyjnym, przedstawionym na rysunku 5.22 (a), pojedyncza sieć neuronowa przekształca wejściowy wektor złożony z 448 pomiarów napięć bezpośrednio na wektor wyjściowy składający się z 3050 przestrzennych elementów skończonych (wokseli), które reprezentują obraz rekonstrukcyjny. Struktura tej sieci jest prosta w koncepcji, choć może być złożona obliczeniowo ze względu na dużą liczbę parametrów do nauczenia (ang. *learnables*) oraz wysoką wymiarowość danych wejściowych i wyjściowych.



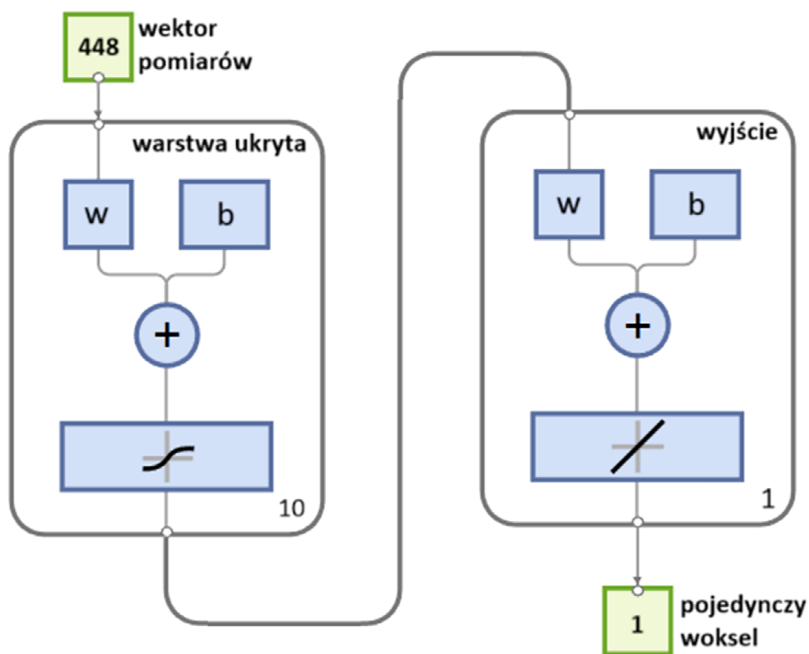
Rys. 5.22. Porównanie koncepcji WSSN na tle tradycyjnej sieci neuronowej: (a) tradycyjny model SSN, (b) koncepcja WSSN, zakładająca trenowanie wielu SSN

Widoczna na rysunku 5.22 (b) koncepcja WSSN wprowadza istotne modyfikacje poprzez zastosowanie wielu jednowyjściowych sieci SSN, gdzie każda z nich, oznaczona jako SSN_i , jest odpowiedzialna za przetwarzanie tych samych 448 pomiarów napięć, ale każda przewiduje tylko jedną wartość wyjściową y_i , odpowiadającą pojedynczemu wokselowi. W rezultacie przedmiotowy model składa się z 3050 sieci z pojedynczym neuronem na wyjściu, gdzie każda wartość określa jeden woksel. Łączna liczba wokseli odpowiada rozdzielczości siatki FEM (ang. *finite element method*) używanej do rekonstrukcji obrazu tomograficznego.

Każda jednowyjściowa SSN jest prostsza w strukturze i wymaga mniej zasobów obliczeniowych niż sieć typu „sekwencja → sekwencja” z wektorem na wyjściu. Prócz tego mniejsze modele są łatwiejsze do trenowania, co może przyspieszyć proces nauki i zwiększyć stabilność modelu. Redukcja złożoności i wymiarowości może również przyczynić się do większej precyzji i efektywności modelu w praktycznych zastosowaniach. Koncepcja WSSN, polegająca na przypisywaniu poszczególnych sieci pojedynczym wokselom, umożliwia lepsze dostosowanie modelu do specyficznych, lokalnych właściwości obrazu. Stanowi to dużą zaletę, zwłaszcza w przypadku zastosowań modelu do zadań takich jak detekcja wilgoci w murach, gdzie celem jest wychwycenie różnic wilgotności w obrębie wybranego fragmentu muru.

Wadą WSSN jest konieczność trenowania wielu modeli, co zwiększa całkowity czas i koszt obliczeniowy procesu uczenia maszynowego, zwłaszcza przy dużej liczbie wokseli. Tego rodzaju sieć jest dość wolna podczas rekonstrukcji obrazów tomograficznych, co ma znaczenie w środowiskach dynamicznych. Akurat badanie zawilgocenia ścian budynków nie jest nacechowane dynamizmem, więc ten problem tu nie występuje.

Rysunek 5.23 przedstawia schemat zastosowanego modelu sieci neuronowej. Sieć ma 448 wejść, 10 neuronów w warstwie ukrytej i 1 neuron w warstwie wyjściowej. Warstwa ukryta wykorzystuje logistyczną funkcję transferową. W warstwie wyjściowej funkcja transferowa ma przebieg liniowy.




Rys. 5.24. Diagram pojedynczej sieci neuronowej wykorzystanej w modelu WSSN

Wykres przedstawiony na rysunku 5.24 ilustruje przebieg procesu uczenia modelu sieci WSSN dla pojedynczego woksela. Na osi poziomej oznaczonej jako „epoki” pokazano liczbę epok, czyli pełnych cykli uczenia modelu, natomiast na osi pionowej znajduje się średni błąd kwadratowy (MSE), który jest miarą błędów modelu.

Na wykresie widoczne są cztery linie reprezentujące poszczególne zbiory danych. Linia niebieską oznaczono średni błąd kwadratowy na zbiorze danych uczących. Widać wyraźny trend malejący, co oznacza, że model z każdą

epoką poprawia swoje dopasowanie do danych uczących. Liniją zieloną oznaczono błąd dla zbioru walidacyjnego. Ten zbiór danych nie jest używany bezpośrednio do uczenia modelu. Służy on do monitorowania momentu zatrzymania procesu uczenia, wykorzystując do tego funkcję wczesnego zatrzymania (ang. *early stopping*). Wykres dla zbioru testowego oznaczono linią czerwoną. Dane należące do tego zbioru służą do ostatecznej oceny jakości modelu po zakończeniu procesu uczenia.



Rys. 5.24. Przebieg procesu uczenia modelu WSSN. Najmniejszy błąd walidacyjny wyniósł $MSE = 1,7935$ w epoce 12

Przecięcie linii przerywanych (zielony punkt) oznacza moment, w którym uzyskano najmniejszy błąd walidacyjny. W prezentowanym przypadku, w 12. epoce błąd MSE osiągnął najmniejszą wartość $MSE = 1,7935$. W początkowych iteracjach/epokach błędy na wszystkich zbiorach są stosunkowo wysokie, co jest typowe dla wczesnych etapów uczenia sieci neuronowej, gdy model jeszcze nie zdołał nauczyć się istotnych wzorców z danych. Z biegiem czasu, w miarę jak model uczy się na danych uczących, błąd ten znacząco spada, co jest widoczne szczególnie w przypadku linii niebieskiej odnoszącej się do zbioru uczącego.

W 12. epoce błąd walidacyjny osiąga minimum, a następnie zaczyna nieznacznie rosnać lub pozostaje na stałym poziomie. Ten fakt może wskazywać na wystąpienie zjawiska nadmiernego dopasowania, czyli tzw. przeuczenia (ang. *overfitting*), kiedy model zaczyna nadmiernie dopasowywać się do danych

uczących kosztem zdolności do generalizacji. Objawia się to również tym, że błąd dla zbioru uczącego (niebieska linia) nadal maleje, podczas gdy błędy walidacyjny i testowy (zielona i czerwona linia) pozostają na wyższym poziomie i są do siebie zbliżone, co świadczy o dobrej generalizacji do momentu minimum błędu walidacyjnego.

Rozbieżność między błędem uczącym a walidacyjnym/testowym po 12. epoce wskazuje na nadmierne dopasowanie, które jest typowym problemem w uczeniu modeli maszynowych. Nadmierne dopasowanie oznacza, że model nauczył się specyficznych wzorców z danych uczących, które niekoniecznie będą obecne w nowych, nieznanymi danych. Metoda wczesnego zatrzymania (ang. *early stopping*) jest techniką stosowaną w celu zapobiegania nadmiernemu dopasowaniu. Polega ona na przerwaniu treningu, gdy błąd walidacyjny przestaje się poprawiać przez określoną liczbę epok. W przypadku przedstawionego wykresu najlepszy moment zatrzymania to 12. epoka, gdzie błąd walidacyjny był najniższy.

W kontekście tomografii ETI zdolność modelu do generalizacji jest kluczowa, ponieważ zadaniem modelu jest skuteczne przewidywanie rozkładu przewodnictwa elektrycznego w nowych, nieznanymi próbkach na podstawie ograniczonej liczby pomiarów powierzchniowych. Zatem utrzymanie niskiego błędu walidacyjnego i testowego jest istotne dla praktycznej użyteczności modelu w warunkach rzeczywistych. Model prezentowany na wykresie rokuje dobrze, tym bardziej że trening został zatrzymany w optymalnym momencie (12. epoka). Odpowiedni dobór momentu zatrzymania procesu uczenia przyczynił się do uzyskania najlepszego kompromisu między dokładnością na zbiorze uczącym a zdolnością do generalizacji na nowych danych.

Tabela 5.5 przedstawia rezultaty trenowania modelu sieci neuronowej WSSN dla losowo wybranego woksela. Zawiera ona informacje na temat liczby obserwacji, średniego błędu kwadratowego *MSE* oraz współczynnika korelacji *R* dla trzech różnych zbiorów danych: uczącego, walidacyjnego i testowego.

Tabela. 5.5. Rezultaty trenowania modelu WSSN dla losowo wybranego woksela

Zbiory \ Parametry	Liczba obserwacji	MSE	R
Uczący	22876	0,1125	0,9967
Walidacyjny	4901	1,7935	0,9443
Testowy	4901	1,0273	0,9689

Łączna liczba wygenerowanych symulacyjnie obserwacji wynosiła $N = 32\,678$. Zbiór uczący składa się z 22 876 obserwacji, dla których model osiągnął $MSE = 0,1125$ oraz bardzo wysoką wartość wskaźnika korelacji wynoszącą $R = 0,9967$. Niski MSE, a zarazem wysoki wskaźnik R wskazują na bardzo dobre dopasowanie modelu do danych uczących. Na tej podstawie można wnioskować, że model skutecznie nauczył się wzorców obecnych w danych.

Wskaźnik korelacji $R_{T\hat{y}}$, znany również jako współczynnik korelacji Pearsona, jest miarą liniowej zależności pomiędzy dwoma zbiorami danych. Dla danych rzeczywistych (wzorcowych) T_i oraz przewidywanych przez model (rekonstrukcji) T_i wskaźnik korelacji $R_{T\hat{y}}$ można wyrazić za pomocą następującego wzoru:

$$R_{T\hat{y}} = \frac{\sum_{i=1}^N (T_i - \bar{T}) (\hat{y}_i - \bar{\hat{y}})}{\sqrt{\sum_{i=1}^N (T_i - \bar{T})^2 \sum_{i=1}^N (\hat{y}_i - \bar{\hat{y}})^2}} \quad (5.5)$$


gdzie: T_i – rzeczywiste wartości, \hat{y}_i – przewidywane wartości, \bar{T} – średnia wartość rzeczywistych wartości, $\bar{\hat{y}}$ – średnia wartość przewidywanych wartości, N – liczba obserwacji. Powyższa formuła określa stopień, w jakim zmienne y i \hat{y} są liniowo skorelowane. Wartość $R_{T\hat{y}}$ mieści się w przedziale od -1 do 1 , gdzie: $R_{T\hat{y}} = 1$ oznacza doskonałą dodatnią korelację liniową, $R_{T\hat{y}} = -1$ oznacza doskonałą ujemną korelację liniową, $R_{T\hat{y}} = 0$ oznacza brak korelacji liniowej. W praktyce wysoka wartość $R_{T\hat{y}}$ (bliska 1 lub -1) wskazuje na silną zależność liniową między wartościami rzeczywistymi a przewidywanymi, co jest pożądane w kontekście oceny wydajności modelu predykcyjnego, takiego jak model używany w elektrycznej tomografii impedancyjnej.

Wracając do analizy tabeli 5.5 – zbiór walidacyjny zawiera 4901 obserwacji, a uzyskane dla niego wartości MSE i $R_{T\hat{y}}$ wynoszą odpowiednio 1,7935 i 0,9443. Znacznie wyższy MSE w porównaniu ze zbiorem uczącym oraz niższy współczynnik korelacji wskazują na to, że model, pomimo dobrego dopasowania do danych uczących, zaczyna przejawiać symptomy nadmiernego dopasowania, co prowadzi do gorszej wydajności na nowych danych, które nie były używane podczas treningu. Zbiór testowy, podobnie jak walidacyjny, składa się z 4901 obserwacji. Dla tego zbioru uzyskano MSE wynoszące 1,0273 oraz wskaźnik korelacji $R_{T\hat{y}}$ na poziomie 0,9689. Wyniki te są lepsze niż dla zbioru walidacyjnego. Świadczy to o wysokiej zdolności modelu do generalizacji i to pomimo tego, że różnice pomiędzy MSE dla

zbiorów uczącego, walidacyjnego i testowego wciąż wskazuje na pewien poziom nadmiernego dopasowania.

Wysoki współczynnik korelacji R_{Ty} dla zbioru uczącego wskazuje, że model jest bardzo dobrze dopasowany do danych, na których był trenowany. Jednakże różnica w wartościach MSE i R_{Ty} dla zbiorów walidacyjnego i testowego podkreśla konieczność stosowania technik regularyzacji oraz wczesnego zatrzymania (early stopping) w celu poprawy zdolności modelu do generalizacji na nowe, nieznanne dane. Przedstawione wyniki trenowania WSSN wskazują, że model ma potencjał do skutecznego zastosowania w tomografii ETI, jednak z uwagi na tendencje do przeuczenia podczas procesu trenowania wymagane jest stosowanie technik zapobiegającym nadmiernemu dopasowaniu.

Rysunek 5.25 przedstawia trzy wykresy ilustrujące przebiegi procesu uczenia wielokrotnej sztucznej sieci neuronowej (WSSN) w kontekście elektrycznej tomografii impedancyjnej (ETI). Każda z trzech części rysunku odzwierciedla kluczowe parametry i miary związane z optymalizacją modelu w trakcie kolejnych epok uczenia.



Rys. 5.25. Najmniejszy błąd walidacyjny wyniósł 1,7935 w epoce 12

Pierwsza część rysunku ukazuje zmiany gradientu w kolejnych epokach. Gradient jest miarą nachylenia funkcji błędu w przestrzeni parametrów modelu. Dzięki gradientowi znany jest kierunek i wielkość korekt, które należy


zastosować w stosunku do wag w procesie uczenia. Na omawianym wykresie, wraz z kolejnymi iteracjami widoczny jest ogólny trend spadkowy, co jest symptomem, że wartość funkcji błędu trenowanego modelu stopniowo zbliża się do minimum. W 18. epoce gradient osiąga wartość 0,012538. Oznacza to, że proces uczenia zmierza ku stabilizacji, a zmiany wag są coraz mniejsze.

Druga część rysunku przedstawia zmianę wartości momentu w trakcie uczenia. Momentum jest parametrem, który pomaga w przyspieszeniu procesu uczenia poprzez uwzględnienie poprzednich kierunków zmian wag. Umożliwia to szybsze pokonywanie dolin i wzniesień widocznych na wykresie funkcji błędu. Duże fluktuacje momentu mogą wskazywać na poszukiwanie optymalnego rozwiązania w złożonej przestrzeni parametrów. W 18. epoce moment wynosi $1e-06$, co jest bardzo małą wartością, sugerującą, że model zbliża się do punktu, w którym dalsze zmiany są minimalne.

Trzecia część rysunku ilustruje kryterium maksymalnej liczby testów walidacyjnych przeprowadzanych w poszczególnych epokach. Jest to *de facto* obraz metody wczesnego zatrzymania uczenia modelu. Na wykresie można zauważyć, że do 12. epoki liczba testów walidacyjnych jest stosunkowo stała, co odpowiada etapowi, w którym model jeszcze się uczy i dopasowuje do danych uczących. Po 12. epoce, gdzie najmniejszy błąd walidacyjny wynosił 1,7935, liczba testów walidacyjnych zaczyna gwałtownie rosnąć, co może świadczyć o próbach modelu w dalszej optymalizacji i dopasowywaniu do danych walidacyjnych, mimo że główny proces uczenia już się zakończył. Zmniejszający się gradient i stabilizujące wartości momentu wskazują, że model zbliża się do optymalnego rozwiązania. Natomiast rosnąca liczba testów walidacyjnych po 12. epoce podkreśla znaczenie ciągłej walidacji i adaptacji modelu w celu zapewnienia jego zdolności do generalizacji i skutecznego działania w warunkach rzeczywistych.

Rysunek 5.26 przedstawia histogram błędów, który odzwierciedla rozkład odchyłań między obrazami wzorcowymi (wejściami) a rekonstrukcjami (wyjściami) WSSN. Oś pozioma, oznaczona jako „Odchylenia”, przedstawia liczbowe wartości różnic między rzeczywistymi wartościami a wartościami przewidywanymi przez model. Odchylenia zostały podzielone na 20 równych przedziałów. Oś pionowa reprezentuje liczbę instancji, czyli częstość występowania poszczególnych odchyłań mieszczących się w określonych przedziałach.

Histogram zawiera cztery różne zbiory danych: zbiór uczący (niebieskie słupki), zbiór walidacyjny (zielone słupki), zbiór testowy (czerwone słupki) oraz linię oznaczającą błąd zerowy (pomarańczowa linia pionowa). Słupki reprezentują liczbę przypadków, w których różnica między wzorcami a wyjściami sieci mieściła się w określonym przedziale wartości.




Rys. 5.26. Histogram błędu z 20 przedziałami

Kształt wykresu jest asymetryczny, lecz skoncentrowany wokół wartości bliskiej zero. Taki kształt sugeruje, że większość przewidywań modelu WSSN jest bardzo bliska rzeczywistym wartościom. Niebieskie słupki zbioru uczącego dominują w centralnej części histogramu. To z kolei świadczy o dobrym dopasowaniu modelu do danych uczących. Zielone słupki zbioru walidacyjnego i czerwone słupki zbioru testowego również są skupione wokół linii oznaczającej wartość zerową, chociaż z nieco większym rozproszeniem. Jest to typowe w przypadku walidacji i testowania, ponieważ dotyczy predykcji danych, które dla modelu są zupełnie nieznane.

Można przyjąć, że rozkład odchyłeń na histogramie jest zbliżony kształtem do krzywej rozkładu normalnego. Pomimo że kształt histogramu nie jest idealnie symetryczny, błędy predykcji mają tendencję do kształtowania się zgodnie z rozkładem normalnym. Większość odchyłeń na wykresie jest niewielka, a większe błędy MSE występują rzadziej. Jest to pozytywny prognostyk odnośnie do jakości modelu, wskazujący na jego potencjał do generalizacji wyników. Skoncentrowanie odchyłeń wokół zera wskazuje na wysoką dokładność modelu. Pomimo pewnych rozprożeń w zbiorach walidacyjnym i testowym, ogólny rozkład błędów jest zgodny z oczekiwaniami dla dobrze funkcjonującej sieci neuronowej, co potwierdza skuteczność zastosowanego podejścia w analizie tomograficznej.

Rysunek 5.27 ilustruje statystykę regresyjną dla zbioru testowego, przedstawiając relację pomiędzy wzorcowymi wartościami wokseli a wartościami

przewidywanymi przez model WSSN w kontekście obrazowania ETI. Na wykresie znajdują się trzy elementy: punkty oznaczone kółkami, czerwona linia regresji oraz przerywana linia wzorcowa. Kółka reprezentują indywidualne wartości wokseli w zbiorze testowym, pokazując, jak rzeczywiste wartości są mapowane przez model. Oś pozioma („wzorzec”) reprezentuje wzorcowe wartości wokseli, czyli rzeczywiste wartości przewodnictwa elektrycznego, natomiast oś pionowa przedstawia wartości przewidywane przez model.



Rys. 5.27 Statystyka regresyjna dla zbioru testowego. Korelacja $R = 0,96891$

W rozpatrywanym przypadku wszystkie wartości przyjmują 1 lub 10. Są to umowne wartości konduktywności, które dla obszarów suchych wynoszą „1”, a dla obszarów wilgotnych „10”. „Wyjście” odpowiada wartościom przewidzianym przez sieć neuronową. Oś pionowa na przedstawionym wykresie opisana jest zależnością: $\text{wyjście} = 0,95 \cdot \text{wzorzec} + 0,18$. Jest to formuła linii regresji, która najlepiej dopasowuje wyjścia i wejścia widoczne na wykresie w postaci rozproszonych punktów. Wartość 0,95 jest współczynnikiem nachylenia linii regresji. Współczynnik wskazuje, że każda jednostka wzorca przekłada się na 0,95 jednostki na osi wyjścia. Wartość (+0,18) jest stałą (przesunięcie *y-intercept*) linii regresji, która informuje, że kiedy wartość wzorca wynosi zero, linia regresji przecina oś pionową w punkcie 0,18. Tak więc formuła na osi

pionowej opisuje sposób, w jaki model regresji przekształca wartości wzorca do wartości wyjściowych. W powyższej formule wartość początkowa wynosi 0,18, a stosunek zmiany jest równy 0,95.

Analiza przebiegu linii widocznych na wykresie dostarcza istotnych informacji o jakości modelu. Czerwona linia regresji przebiega blisko przerywanej linii wzorcowej. Oznacza to, że model dobrze przewiduje wartości wokseli. Współczynnik korelacji $R = 0,96891$ dla zbioru testowego potwierdza wysoką zgodność między wartościami przewidywanymi a rzeczywistymi. To z kolei stanowi dowód dużej precyzji modelu w zakresie przewidywania rozkładu przewodnictwa elektrycznego wewnątrz muru. Choć widoczne są pewne odchylenia od linii wzorcowej, szczególnie na końcach zakresu wartości, jednak są one minimalne i nie wpływają znacząco na ogólną ocenę modelu.

5.9. Dobór metody uczenia maszynowego

Poniżej przedstawiono przykład umożliwiający dobór metody uczenia maszynowego do konkretnych danych. Nie jest to jednak dobór nieograniczony, lecz wybór spośród dwóch metod – metody najmniejszych kwadratów lub maszyny wektorów nośnych (SVM). Obie metody mogą być zastosowane w ramach regresji liniowej.

W regresji liniowej metodą najmniejszych kwadratów (ang. *least squares*) funkcja celu składa się z dwóch części: błędu kwadratowego oraz terminu regularyzacji, którym może być $L1$ (Lasso) lub $L2$ (Ridge). Ogólna postać funkcji celu jest następująca:

$$\min_w \left(\sum (y_i - f(x_i, w))^2 + \lambda R(w) \right) \quad (5.6)$$

gdzie: y_i jest rzeczywistą wartością (wzorcem) dla i -tej obserwacji, $f(y_i, w)$ to wartość przewidywana przez model dla i -tej obserwacji, w jest wektorem wag modelu, λ (Lambda) to parametr regularyzacji, $R(w)$ to funkcja regularyzacji ($L1$ lub $L2$).

Metoda najmniejszych kwadratów minimalizuje sumę kwadratów różnic między obserwowanymi wartościami a wartościami przewidywanymi przez model. Dla metody najmniejszych kwadratów termin regularyzacji $R(w)$ jest regularyzacją typu $L2$ (ang. *ridge regression*), która penalizuje duże wartości wag:

$$R(w) = \|w\|_2^2 \quad (5.7)$$

Funkcja celu z regularyzacją $L2$ przyjmuje więc postać:

$$\min_w \left(\sum (y_i - f(x_i, w))^2 + \lambda \sum w_j^2 \right) \quad (5.8)$$

W kontekście regresji liniowej SVM znajduje płaszczyznę hiperprzestrzeni, która najlepiej oddziela różne klasy danych lub przewiduje wartości ciągłe. Dla metody SVM termin regularyzacji $R(w)$ jest regularyzacją typu $L1$ (ang. *Lasso regression*), która prowadzi do rzadkich wag, czyli wielu wag równych zero:

$$R(w) = \|w\|_1 \quad (5.9)$$

Funkcja celu z regularyzacją $L1$ (Lasso) może być zapisana jako:

$$\min_w \left(\sum (y_i - f(x_i, w))^2 + \lambda \sum |w_j| \right) \quad (5.10)$$

W regresji SVM funkcja celu również składa się z dwóch części: błędu epsilon-niewrażliwego oraz terminu regularyzacji, który również może być $L1$ lub $L2$. Funkcja celu dla regresji SVM z regularyzacją $L2$ przyjmuje postać:

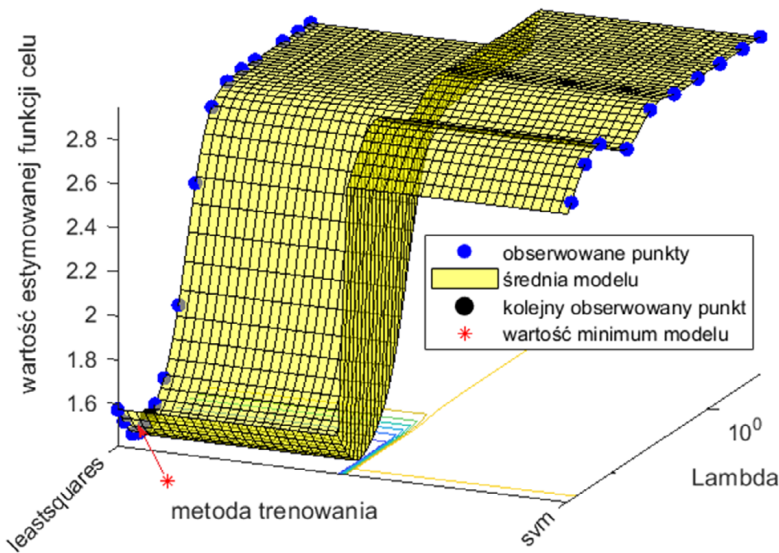
$$\min_w \left(\frac{1}{2} \|w\|_2^2 + C \sum \max(0, |y_i - f(x_i, w)| - \varepsilon) \right) \quad (5.11)$$

gdzie: C – parametr regularyzacji, który określa kompromis między błędem a regularyzacją, ε – szerokość marginesu epsilon-niewrażliwego. Minimalizacja funkcji celu jest realizowana w procesie optymalizacji. Istnieje możliwość wyboru metody optymalizacji, jednak w tym przypadku została zastosowana popularna metoda stochastycznego spadku gradientu (ang. *stochastic gradient descent*) [88, 145].

Rysunek 5.28 przedstawia trójwymiarowy wykres optymalizacji funkcji celu w modelu regresji liniowej dla różnych parametrów λ i dwóch metod uczenia (metody najmniejszych kwadratów, czyli *leastsquares*, oraz SVM) w kontekście dopasowywania danych wokselowych.

Punkty obserwacji (niebieskie punkty) to zaobserwowane wartości funkcji celu dla różnych kombinacji parametrów. Średnia modelu (żółta powierzchnia) przedstawia wartość funkcji celu oszacowaną na podstawie modelu predykcyjnego. Kolejny punkt (czarna kropka) to kolejny punkt podlegający ocenie w procesie optymalizacji. Minimalna wartość modelu (czerwona gwiazdka) oznacza minimalną możliwą wartość funkcji celu, która została oszacowana

przez model. Najmniejsza wartość funkcji celu została osiągnięta metodą najmniejszych kwadratów (leastsquares).



Rys. 5.28. Dobór metody trenowania, leastsquares lub SVM, z wykorzystaniem regresji liniowej

W tabeli 5.6 przedstawiono formuły funkcji straty wykorzystane w zależności od metody regresji liniowej – leastsquares lub SVM.


Tabela. 5.6. Funkcja celu w zależności od metody uczenia

Metoda uczenia	Algorytm	Zakres odpowiedzi	Funkcja straty
leastsquares	Regresja liniowa metodą najmniejszych kwadratów	$y \in (-\infty, \infty)$	$\ell[y, f(x)] = \frac{1}{2} [y - f(x)]^2$
SVM	Regresja z użyciem maszyny wektorów nośnych	$y \in (-\infty, \infty)$	$\ell[y, f(x)] = \max[0, y - f(x) - \varepsilon]$

Elementem funkcji straty jest $f(x) = x\beta + b$, gdzie: β jest wektorem współczynników, x jest obserwacją z p -zmiennych predykcyjnych, b jest skalarnym wyrazem wolnym. W funkcji straty dla SVM ε to wartość progowa, poniżej której błędy przewidywać nie są uwzględniane.

Optymalizowana funkcja celu różni się w zależności od wybranej metody i rodzaju regularyzacji. W przypadku leastsquares funkcja celu minimalizuje błąd kwadratowy z dodatkowym terminem regularyzacji $L1$ lub $L2$. W przypadku regresji SVM funkcja celu minimalizuje błąd ε z dodatkowym terminem regularyzacji $L2$.

Wykres 5.29 ilustruje minimalną wartość funkcji celu w zależności od liczby ewaluacji funkcji. Przedstawia on zarówno minimalne wartości obserwowane (czerwone kropki), jak i minimalne wartości estymowane (zielone trójkąty). Na osi poziomej znajdują się kolejne ewaluacje funkcji celu, a na osi pionowej przedstawiono wartości minimalne funkcji celu. Na wykresie można zaobserwować, że początkowo, w pierwszych pięciu ewaluacjach, wartość funkcji celu gwałtownie spada z poziomu około 2,8 do około 1,4. Po tej fazie wartości minimalne funkcji celu stabilizują się wokół 1,4 dla pozostałych ewaluacji.



Rys. 5.29 Wykres minimalnej funkcji celu względem liczby ewaluacji

Powiązana z rysunkiem 5.29 tabela 5.7 przedstawia szczegółowy przebieg procesu doboru metody uczenia, uwzględniając iteracje, ocenę wyniku, wartość funkcji celu, najlepszy dotychczasowy wynik z obserwacji, najlepszy wynik estymowany, parametr Lambda oraz najlepszą dla danej iteracji metodę (leastsquares lub SVM). Analizując tabelę w kontekście rysunku 5.29, można zauważyć, że w pierwszych pięciu iteracjach wartości funkcji celu i metody treningowe są zróżnicowane. Odpowiada to gwałtownemu spadkowi wartości funkcji celu na wykresie. Iteracje oznaczone jako „Best” (np. iteracje 1, 3, 6, 25) wskazują na osiągnięcie najlepszych wyników wśród wcześniejszych iteracji. Jest to zgodne z punktami oznaczonymi na wykresie. Od około szóstej iteracji, kiedy funkcja celu osiąga wartość około 1,4, zauważalna jest stabilizacja minimalnej wartości funkcji celu, co odzwierciedla stabilne wartości na wykresie od tej iteracji. Minimalne wartości obserwowane i estymowane (czerwone kropki i zielone trójkąty) są do siebie bardzo zbliżone. Dowodzi to

wysokiej zgodności między wartościami rzeczywistymi a przewidywanymi przez model estymacjami.

Tabela. 5.7. Przebieg procesu doboru metody uczenia

Iteracja	Ocena	Funkcja celu	Najlepszy dotąd wynik z obserwacji	Najlepszy dotąd wynik estymowany	Lambda	Metoda
1	Best	2,753	2,753	2,753	8,6612E-08	svm
2	Accept	2,934	2,753	2,7643	0,018824	svm
3	Best	1,503	1,503	1,5266	1,1348E-07	leastsquares
4	Accept	2,7478	1,503	1,5031	20,288	leastsquares
5	Accept	1,5781	1,503	1,503	0,000014183	leastsquares
6	Best	1,4077	1,4077	1,4085	6,4557E-07	leastsquares
7	Accept	1,419	1,4077	1,4108	1,2686E-06	leastsquares
8	Accept	2,9345	1,4077	1,4112	551,37	svm
9	Accept	1,4079	1,4077	1,4094	7,5644E-07	leastsquares
10	Accept	1,409	1,4077	1,4093	7,5615E-07	leastsquares
11	Accept	1,4109	1,4077	1,4096	7,5279E-07	leastsquares
12	Accept	2,7337	1,4077	1,4096	0,025916	leastsquares
13	Accept	2,7479	1,4077	1,4097	552,3	leastsquares
14	Accept	2,9345	1,4077	1,4098	4,3636	svm
15	Accept	2,8281	1,4077	1,4099	0,000065613	svm
16	Accept	2,3694	1,4077	1,4097	0,00058997	leastsquares
17	Accept	2,7473	1,4077	1,4098	0,7334	leastsquares
18	Accept	2,9338	1,4077	1,4098	2,5608E-06	svm
19	Accept	2,9344	1,4077	1,4098	0,30841	svm
20	Accept	2,9345	1,4077	1,4099	64,741	svm
21	Accept	2,9341	1,4077	1,4098	0,0010708	svm
22	Accept	1,8659	1,4077	1,4095	0,000079049	leastsquares
23	Accept	2,7477	1,4077	1,4095	120,94	leastsquares
24	Accept	1,4858	1,4077	1,4094	4,7274E-06	leastsquares
25	Best	1,4065	1,4065	1,4089	6,9154E-07	leastsquares
26	Accept	2,6654	1,4065	1,4089	0,0041134	leastsquares
27	Accept	1,5756	1,4065	1,4089	5,5266E-08	leastsquares
28	Accept	2,8865	1,4065	1,409	4,297E-07	svm
29	Accept	1,4215	1,4065	1,4082	3,2098E-07	leastsquares
30	Accept	2,7453	1,4065	1,4083	0,15002	leastsquares

Na podstawie analizy informacji zawartych w tabeli 5.7 można stwierdzić, że optymalizacja została zakończona, osiągając maksymalną liczbę 30 ewaluacji funkcji celu. Najlepszy zaobserwowany wykonalny punkt został osiągnięty dla wartości parametru Lambda wynoszącej $6,6223e-07$ przy użyciu metody leastsquares. Wartość funkcji celu dla tego punktu wyniosła 1,2754, podczas gdy oszacowana wartość funkcji celu wyniosła 1,2769. Najlepszy oszacowany wykonalny punkt, zgodnie z modelami leastsquares i SVM, został uzyskany dla wartości parametru Lambda wynoszącej $6,4829e-07$ również przy użyciu metody leastsquares. Oszacowana wartość funkcji celu dla tego punktu wyniosła 1,2769. Uzyskane wyniki wskazują na wysoką zgodność między wartościami zaobserwowanymi a oszacowanymi. W kontekście minimalizacji funkcji celu świadczy to o dobrej efektywności zarówno zastosowanego modelu, jak również wykorzystanej metody optymalizacji.

5.10. Rekonstrukcje obrazów uzyskane dzięki danym symulacyjnym

Tabela 5.8 przedstawia obrazy wzorcowe (referencyjne) dla czterech przypadków pomiarowych oraz rekonstrukcje ETI wykonane następującymi metodami: Gaussa–Newtona, regularyzacji Tikhonova, Total Variation, maszyna wektorów nośnych (SVM), elastic net, regresji liniowej, wielokrotnej sieci neuronowej (WSSN), konwolucyjnej sieci neuronowej (CNN), sieci LSTM, sieci LSTM+CNN, sieci wielogałęziowej LSTM.

Analiza rekonstrukcji dla każdego z czterech przypadków umożliwia ocenę skuteczności i dokładności poszczególnych metod. W przypadku nr 1 obrazy rekonstrukcyjne wykonane metodami Gaussa–Newtona oraz regularyzacji Tikhonova wydają się dobrze odwzorowywać strukturę wzorca, choć w niektórych miejscach zauważalne są rozmycia i artefakty. Metoda Total Variation lepiej zachowuje krawędzie, co może być korzystne w rekonstrukcji szczegółowych struktur. SVM generuje obrazy o wyraźnych konturach, jednak z nieco większym poziomem szumów w porównaniu z metodami opartymi na regularyzacji. Metoda elastic net, choć skuteczna w prostszych przypadkach, może nieco gorzej radzić sobie z bardziej złożonymi rozkładami zawilgoceń.

Regresja liniowa, ze względu na swoją prostotę, często nie radzi sobie ze złożonymi obrazami, co jest widoczne w przypadkach nr 2 i nr 3, gdzie rekonstrukcje są mniej wyraźne. Wielokrotna sztuczna sieć neuronowa (WSSN), mimo że trenuje sieci dla pojedynczych wokseli, a każda z sieci ma na wyjściu nie wektor,

lecz tylko jedną wartość skalarną, osiąga wysoką jakość rekonstrukcji. Dzięki temu, mimo że jest to zwykła gęsta warstwa typu „dense” zawierająca 10 neuronów ukrytych, zwielokrotniona do rozdzielczości obrazu wyjściowego, jakością dorównuje nowoczesnym architekturom sieciowym. WSSN poprawia wyniki szczególnie w przypadkach z bardziej skomplikowaną geometrią, gdzie obserwujemy lepsze odwzorowanie szczegółów w porównaniu z prostszymi metodami.

Konwolucyjna sieć neuronowa (CNN) daje bardzo dobre rezultaty, szczególnie w przypadku nr 4, gdzie złożoność struktury jest najlepiej odwzorowalna. Sieć LSTM, zaprojektowana do przetwarzania sekwencyjnego, może nieco mniej efektywnie radzić sobie z pojedynczymi obrazami w porównaniu z CNN, jednak połączenie LSTM z CNN (sieć LSTM+CNN) wykazuje znaczną poprawę. Widać to zwłaszcza w odwzorowywaniu dynamicznych aspektów obrazu, czyli złożoności i zmienności strukturalnych. Sieć wielogałęziowa LSTM, która łączy zalety obu podejść, daje najbardziej zadowalające wyniki w większości przypadków. Zachowuje przy tym zarówno szczegółowość, jak i dynamikę obrazów wzorcowych.

Z przedstawionych rezultatów wynika, że najlepsze odwzwierciedlenie obrazów wzorcowych uzyskano za pomocą sieci wielogałęziowej LSTM. Sugeruje to, że połączenie różnych podejść do analizy obrazu może prowadzić do lepszych wyników w rekonstrukcji ETI. Metody bazujące na sieciach neuronowych, szczególnie CNN i kombinacje LSTM+CNN, wykazują widoczną przewagę nad tradycyjnymi metodami w zakresie zachowania szczegółowości i dokładności rekonstrukcji.

Tabela. 5.8. Porównanie rekonstrukcji uzyskanych różnymi metodami

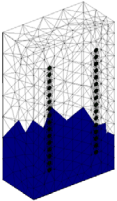
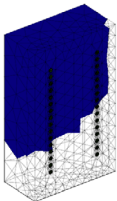
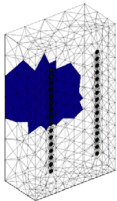
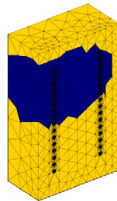
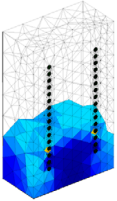
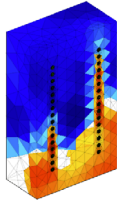
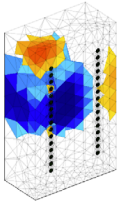
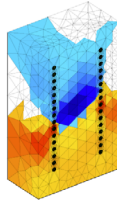
Metoda	Przypadek nr 1	Przypadek nr 2	Przypadek nr 3	Przypadek nr 4
Wzorzec				
Metoda Gaussa-Newtona				

Tabela. 5.8. Porównanie rekonstrukcji uzyskanych różnymi metodami

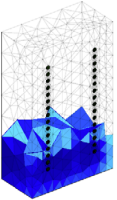
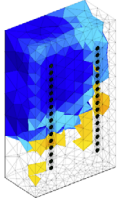
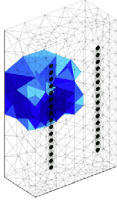
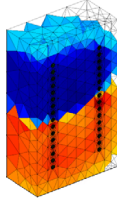
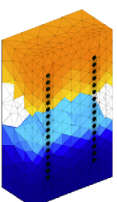
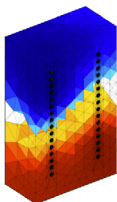
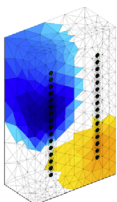
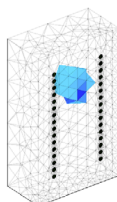
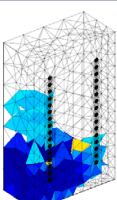
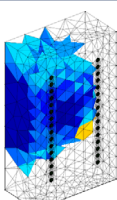
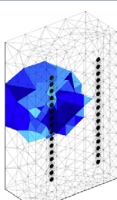
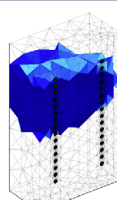
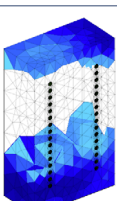
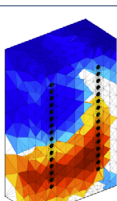
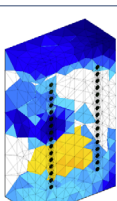
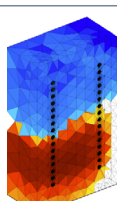
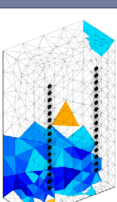
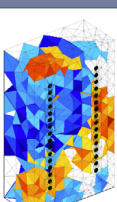
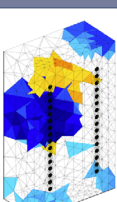
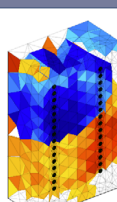
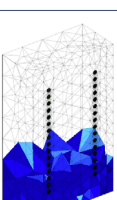
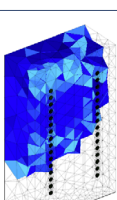
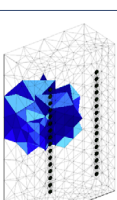
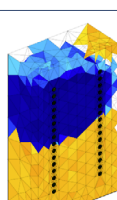
Regularyzacja Tikhonova				
Metoda Total Variation				
Maszyna wektorów nośnych (SVM)				
elastic net				
Metoda	Przypadek nr 20	Przypadek nr 40	Przypadek nr 110	Przypadek nr 320
Regresja liniowa				
WSSN				

Tabela. 5.8. Porównanie rekonstrukcji uzyskanych różnymi metodami

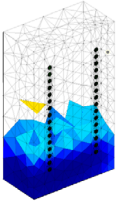
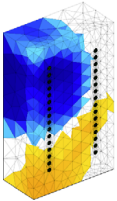
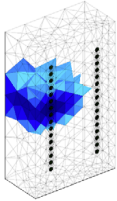
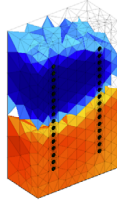
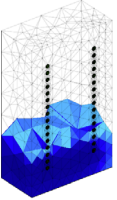
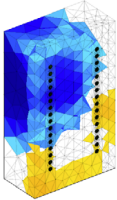
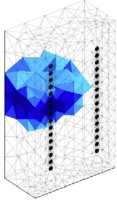
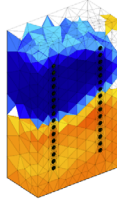
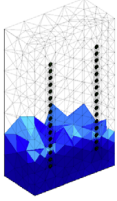
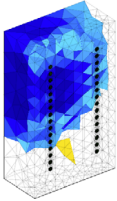
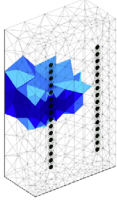
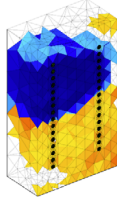
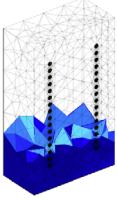
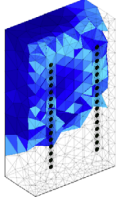
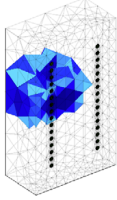
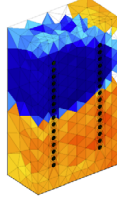
CNN				
LSTM				
LSTM+CNN				
Wielogałęziowa LSTM				

Tabela 5.9 przedstawia wskaźniki jakości rekonstrukcji dla przypadku nr 1, obejmujące Root Mean Square Error (RMSE), Peak Signal-to-Noise Ratio (PSNR), Structural Similarity Index Measure (SSIM) oraz współczynnik Pearsona R_{Ty} . Metoda Gaussa–Newtona charakteryzuje się wartością RMSE równą 4,141, co wskazuje na stosunkowo wysoką średnią wartość błędu. Wskaźnik PSNR wynosi 7,6578, co sugeruje umiarkowany poziom szumu w zrekonstruowanym obrazie. SSIM, wynoszący 0,0279, wskazuje na niską jakość strukturalną rekonstrukcji, a R_{Ty} na poziomie 0,9024 świadczy o wysokiej korelacji rekonstrukcji z obrazami wzorcowymi. Warto przy tym nadmienić, że SSIM to miara, która ocenia, jak dobrze zrekonstruowany obraz zachowuje lokalne i globalne cechy oryginału, takie jak krawędzie, tekstury i inne elementy strukturalne. Z kolei stabilność metody w kontekście rekonstrukcji obrazu odnosi się do jej zdolności do generowania spójnych i niezawodnych wyników. Ma to szczególne znaczenie w przypadku niewielkich zmian wartości danych

pomiarowych. Innymi słowy, stabilność metody ocenia, jak bardzo wyniki rekonstrukcji są wrażliwe na drobne perturbacje lub szумы w danych wejściowych. Wskaźnik R_{Ty} jest miarą tej stabilności.

Tabela. 5.9. Wskaźniki jakości rekonstrukcji dla przypadku nr 1

Metoda	RMSE	PSNR	SSIM	R_{Ty}
Gausa–Newtona	4,1410	7,6578	0,0279	0,9024
Regularyzacja Tikhonova	1,3540	17,369	0,6965	0,9527
Total Variation	4,4890	6,9579	0,0804	0,7653
SVM	2,7680	11,156	0,3875	0,6894
elastic net	9,7300	0,2377	-0,4230	0,8059
Regresja liniowa	7,7920	2,1676	-0,3400	0,7123
WSSN	0,5450	25,277	0,8250	0,9888
CNN	1,9300	14,289	0,5016	0,9303
LSTM	1,1760	18,591	0,7226	0,9501
LSTM+CNN	0,9730	20,238	0,7443	0,9662
Wielogłęziowa LSTM	0,8070	21,858	0,7764	0,9765

Kolejną analizowaną metodą jest regularyzacja Tikhonova. Metoda ta wykazuje znacznie niższe RMSE, równe 1,3540. Oznacza to mniejsze odchylenie rekonstrukcji od wartości wzorcowych. PSNR wynoszący 17,369 sugeruje, że rekonstrukcja jest mniej zaszumiona w porównaniu z metodą Gaussa–Newtona. Wartość SSIM wynosząca 0,6965 oznacza, że strukturalna jakość obrazu jest znacznie lepsza, a R_{Ty} na poziomie 0,9527 wskazuje na bardzo dobrą korelację wzorców i rekonstrukcji.

Metoda Total Variation charakteryzuje się RMSE równym 4,4890, co jest porównywalne z metodą Gaussa–Newtona, ale PSNR na poziomie 6,9579 sugeruje wyższy poziom zaszumienia rekonstrukcji. Wskaźnik SSIM wynoszący 0,0804 jest niski, a korelacja R_{Ty} na poziomie 0,7653 wskazuje na niższą stabilność metody. SVM (ang. *support vector machine*) osiąga RMSE na poziomie 2,7680, co jest umiarkowaną wartością błędu. PSNR wynoszący 11,156 wskazuje na umiarkowany poziom zaszumienia rekonstruowanych obrazów tomograficznych, natomiast SSIM równy 0,3875 sugeruje umiarkowaną jakość strukturalną rekonstrukcji. Wskaźnik korelacji Pearsona R_{Ty} na poziomie 0,6894 wskazuje na niższą jakość metody SVM od TV.

Elastic net wykazuje bardzo wysokie RMSE, równe 9,7300, co jest dużą średnią wartością błędu. PSNR wynoszący 0,2377 wskazuje na wysoki poziom zaszumienia rekonstrukcji, a SSIM równy -0,4230 sugeruje bardzo niską jakość

strukturalną. Wartość wskaźnika korelacji R_{Ty} na poziomie 0,8059 wskazuje na średnią stabilność modelu.

Regresja liniowa charakteryzuje się najwyższym RMSE równym 7,7920 oraz bardzo niskim PSNR, wynoszącym 2,1670. SSIM na poziomie -0,3400 również wskazuje na niską jakość strukturalną, a R_{Ty} wynoszący 0,7123 sugeruje niskie skorelowanie rekonstrukcji z obrazami wzorcowymi. Regresja liniowa zakłada liniową zależność między zmiennymi wejściowymi a wyjściowymi. W przypadku skomplikowanych struktur i wzorców w obrazach zależności te są często nieliniowe, co skutkuje słabym rezultatem tej metody. Metoda WSSN osiąga najniższe RMSE równe 0,5450, co wskazuje na bardzo niski błąd rekonstrukcji. PSNR wynoszący 25,277 oznacza niski poziom zaszumienia rekonstruowanego tomogramu, a SSIM równy 0,8250 świadczy o wysokiej jakości strukturalnej rekonstrukcji. R_{Ty} na poziomie 0,9888 sugeruje bardzo wysoką korelację rekonstruowanych obrazów z wzorcami.

Metoda CNN (*convolutional neural network*) charakteryzuje się RMSE równym 1,9300. PSNR wynoszący 14,280 świadczy o niskim poziomie zaszumienia obrazu wyjściowego. Wskaźnik SSIM równy 0,5016 oznacza dobrą jakość strukturalną, a R_{Ty} na poziomie 0,9303 sugeruje wysoką jakość ocenianego modelu. Sieć LSTM (*long short-term memory*) osiąga RMSE równy 1,1760 oraz PSNR wynoszący 18,591, co jest niskim poziomem zaszumienia obrazów rekonstrukcyjnych. Wskaźnik SSIM równy 0,7226 wskazuje na dobrą jakość strukturalną modelu, a R_{Ty} na poziomie 0,9501 daje wysoką ocenę odnośnie do jakości modelu. Metoda LSTM+CNN charakteryzuje się RMSE równym 0,9730 oraz PSNR na poziomie 20,283, co świadczy o niskim poziomie szumu w rekonstrukcji. Wskaźnik SSIM wynoszący 0,7443 oznacza dobrą jakość strukturalną, a R_{Ty} równe 0,9662 zapewnia wysoką korelację obrazów, a tym samym i ich jakość. Z kolei wielogałęziowa sieć LSTM osiąga RMSE równy 0,8070 oraz PSNR wynoszący 21,858. Również te wartości wskaźników sugerują niski poziom szumu zawartego w rekonstruowanych obrazach. Wskaźnik SSIM równy 0,7764 oznacza wysoką jakość strukturalną, a R_{Ty} na poziomie 0,9765 sugeruje bardzo wysoką korelację uzyskiwanych na wyjściu obrazów z wzorcami.

Analiza przedstawionych wskaźników jakości rekonstrukcji dla przypadku nr 1 sugeruje, że metody oparte na sieciach neuronowych, takie jak WSSN, CNN, LSTM, LSTM+CNN oraz wielogałęziowa LSTM, osiągają lepsze wyniki pod względem RMSE, PSNR, SSIM i R_{Ty} w porównaniu z tradycyjnymi metodami takimi jak metoda Gaussa–Newtona, regularyzacja Tikhonova, Total Variation, SVM, elastic net i regresja liniowa. W szczególności metoda WSSN

wyróżnia się najniższym błędem rekonstrukcji i najwyższą jakością strukturalną obrazu, co czyni ją najbardziej efektywną spośród analizowanych metod.

Podczas interpretacji wyników analizy należy mieć na uwadze, że wskaźnik RMSE jest miarą odchylenia rekonstrukcji od wartości wzorcowych, co jest odległe od ludzkiej percepcji obrazu. Ponieważ tomografia polega na wizualizacji różnic w zawilgoceniu poszczególnych obszarów wnętrza badanego obiektu, możliwe jest, że pomimo różnic wartości bezwzględnych obraz będzie prawidłowo odzwierciedlał miejsca wilgoci. Przykładowo, jeżeli pomnożymy pierwotne wartości wokseli obrazu zrekonstruowanego przez 10 i przedstawimy je jako nowy obraz rekonstrukcyjny, to rekonstrukcja pierwotna i nowa będą wyglądać bardzo podobnie, ale błąd RMSE rekonstrukcji nowej będzie znacznie większy niż pierwotnej.

Tabela 5.10 analizuje podobne do powyższych wskaźniki dla przypadku nr 2. Metoda Gaussa–Newtona charakteryzuje się wartością RMSE wynoszącą 5,3418, co ponownie wskazuje na wysoki średni błąd rekonstrukcji. Wartość PSNR na poziomie 5,4462 sugeruje, że zrekonstruowany obraz zawiera dużo szumu w porównaniu z obrazem wzorcowym. Wskaźnik SSIM równy 0,0156 oznacza bardzo niską jakość strukturalną rekonstrukcji. Oceniana metoda nie jest więc efektywna w odtwarzaniu pierwotnych wzorców obrazu. Wskaźnik korelacji Pearsona dla analizowanej metody, określony wskaźnikiem $R_{Ty} = 0,8152$ jest na poziomie umiarkowanym. Świadczy to o niskiej odporności zrekonstruowanych obrazów tomograficznych na zmiany w sygnałach pomiarowych.

Tabela. 5.10. Wskaźniki jakości rekonstrukcji dla przypadku nr 2

Metoda	RMSE	PSNR	SSIM	R_{Ty}
Gaussa–Newtona	5,3418	5,4462	0,0156	0,8152
Regularyzacja Tikhonova	4,0900	7,7654	0,2257	0,8837
Total Variation	5,5123	5,1733	0,2407	0,6758
SVM	3,1711	9,9758	0,3224	0,6904
elastic net	8,7513	1,1586	-0,3136	0,6831
Regresja liniowa	7,9919	1,9470	-0,0565	0,5441
WSSN	1,4811	16,5882	0,6377	0,9395
CNN	3,1913	9,9206	0,3669	0,7796
LSTM	2,4343	12,2725	0,4896	0,8362
LSTM+CNN	2,0364	13,8226	0,5435	0,8855
Wielogłębiowa LSTM	1,9721	14,1014	0,5634	0,9061

W porównaniu z metodą Gaussa–Newtona regularyzacja Tikhonova wykazuje niższy RMSE, równy 4,0900, co wskazuje na mniejszy błąd rekonstrukcji. Lepsza jakość obrazu w połączeniu z mniejszym poziomem szumu jest potwierdzona przez PSNR = 7,7654. Wskaźnik SSIM wynoszący 0,2257 oznacza wyższą jakość strukturalną rekonstrukcji, a R_{Ty} na poziomie 0,8837 wskazuje na dobre skorelowanie obrazów referencyjnych z uzyskiwanymi tomogramami. Kolejna metoda, Total Variation, charakteryzuje się RMSE równym 5,5123, co jest zbliżone do metody Gaussa–Newtona, ale PSNR wynoszący 5,1733 sugeruje wyższy poziom szumu w rekonstrukcji. Wskaźnik SSIM wynoszący 0,2407 oznacza lepszą jakość strukturalną niż metoda Gaussa–Newtona, ale stabilność określona wskaźnikiem R_{Ty} na poziomie 0,6758 jest niższa, co wskazuje na niską odporność obrazów rekonstrukcyjnych na zmiany w danych pomiarowych. Metoda SVM osiąga RMSE na poziomie 3,1711, co wskazuje na umiarkowaną wartość błędu rekonstrukcji. PSNR wynoszące 9,9758 jest dowodem na lepszą jakość obrazu z mniejszym poziomem szumu, natomiast SSIM równy 0,3224 wskazuje na lepszą jakość strukturalną rekonstrukcji. Wskaźnik korelacji metody R_{Ty} wynoszący 0,6904 jest niższy w porównaniu z regularyzacją Tikhonova. Elastic net wykazuje bardzo wysokie $RMSE = 8,7513$, co wskazuje na duży błąd rekonstrukcji. PSNR wynoszące 1,1586 wskazuje na bardzo wysoki poziom szumu, a SSIM równy -0,3136 sugeruje bardzo niską jakość strukturalną. Korelacja Pearsona R_{Ty} na poziomie 0,6831 jest również niska, co jest przejawem dużej wrażliwości rekonstruowanych obrazów tomograficznych na zmiany w sygnałach pomiarowych. W świetle uzyskanych wskaźników należy stwierdzić, że w analizowanym przypadku pomiarowym metoda elastic net wyraźnie zawiodła.

Metoda regresji liniowej charakteryzuje się najwyższym RMSE równym 7,9919. Podobnie jak w przypadku elastic net, oznacza to duży błąd rekonstrukcji. PSNR wynoszące 1,9470 sugeruje wysoki poziom szumu, a SSIM równy -0,0565 oznacza niską jakość strukturalną rekonstrukcji. Korelacja R_{Ty} wynosząca 0,5441 jest najniższa spośród wszystkich metod, co wskazuje na niską odporność obrazów rekonstrukcyjnych na zmiany w danych pomiarowych. Metoda rekonstrukcji „woksel po wokselu”, jaką jest WSSN, osiąga najniższe RMSE wynoszące 1,4811 i jest to bardzo niski błąd rekonstrukcji. PSNR wynoszące 16,5882 jest dowodem na niski poziom zaszumienia, a SSIM równy 0,6377 oznacza wysoką jakość strukturalną rekonstrukcji. Wartość wskaźnika korelacji R_{Ty} wynosząca 0,9395 jest najwyższa, co jest przejawem dużej odporności rekonstruowanych obrazów tomograficznych na zmiany w sygnałach pomiarowych.

Wskaźnik RMSE dla metody CNN wynosi 3,1913 oraz $PSNR = 9,9206$. Powyższe wskaźniki świadczą o niskim zaszumieniu tomogramów uzyskiwanych tą metodą. SSIM równy 0,3669 wskazuje na dobrą jakość strukturalną rekonstrukcji, a wskaźnik korelacji R_{Ty} wynoszący 0,7796 jest umiarkowanie wysoki. Sieć LSTM osiąga wskaźnik $RMSE = 2,4343$ oraz $PSNR = 12,2725$, co świadczy o niskim poziomie szumu w rekonstrukcjach. Wskaźnik SSIM równy 0,4896 wskazuje na dobrą jakość rekonstrukcji, a R_{Ty} równy 0,8362 sugeruje dobrą korelację i stabilność metody. Dla metody LSTM+CNN wskaźnik $RMSE = 2,0364$ natomiast $PSNR = 13,8226$. Interpretacja wzmiankowanych wskaźników prowadzi do pozytywnej oceny modelu pod względem wierności odwzorowań uzyskiwanych rekonstrukcji. SSIM równy 0,5435 wskazuje na dobrą jakość strukturalną otrzymywanych obrazów, a współczynnik korelacji Pearsona $R_{Ty} = 0,8855$ jest dowodem na dość wysoką jakość opisywanej metody. Wielogłęziowa sieć LSTM osiąga wskaźnik $RMSE = 1,9721$ oraz $PSNR$ wynoszący 14,1014. Stanowi to przesłankę do pozytywnej oceny modelu, z uwagi na dobrą jakość rekonstrukcji. SSIM równy 0,5634 oznacza wysoką jakość strukturalną rekonstrukcji, a korelacja R_{Ty} wynosząca 0,9061 jest bardzo wysoka. Analiza wskaźników jakości rekonstrukcji dla przypadku nr 2 pokazuje, że zaawansowane metody oparte na sieciach neuronowych, takie jak WSSN, CNN, LSTM oraz kombinacje LSTM+CNN, osiągają lepsze wyniki w porównaniu z tradycyjnymi metodami, do których zalicza się metoda Gaussa–Newtona, regularyzacja Tikhonova, Total Variation, SVM, elastic net i regresja liniowa. W szczególności metoda WSSN wyróżnia się najniższym błędem rekonstrukcji i wysoką jakością strukturalną, co czyni ją najbardziej efektywną dla przypadku pomiarowego nr 2 spośród analizowanych metod.

W tabeli 5.11 zaprezentowano wskaźniki jakości rekonstrukcji dla przypadku nr 3. Metoda Gaussa–Newtona charakteryzuje się wartością RMSE wynoszącą 3,3213, co wskazuje na umiarkowanie wysoki średni błąd rekonstrukcji. Wartość PSNR wynosząca 9,5739 sugeruje, że zrekonstruowany obraz zawiera umiarkowany poziom szumu lub zbędnych artefaktów.

Tabela. 5.11. Wskaźniki jakości rekonstrukcji dla przypadku nr 3

Metoda	RMSE	PSNR	SSIM	R_{Ty}
Gaussa–Newtona	3,3213	9,5739	0,0119	0,8219
Regularyzacja Tikhonova	1,2075	18,362	0,4842	0,9472
Total Variation	3,5184	9,0731	0,1756	0,6245
SVM	1,1160	19,051	0,6625	0,9355
elastic net	9,2622	0,6657	-0,2269	0,6185

Tabela. 5.11. Wskaźniki jakości rekonstrukcji dla przypadku nr 3

Metoda	RMSE	PSNR	SSIM	R_{Ty}
Regresja liniowa	6,8100	3,3370	-0,2863	0,8594
WSSN	0,6661	23,5287	0,6327	0,9747
CNN	1,7984	14,9022	0,3156	0,8981
LSTM	1,1705	18,6324	0,4723	0,9241
LSTM+CNN	1,0069	19,9400	0,4976	0,9450
Wielogałęziowa LSTM	0,9874	20,1098	0,5133	0,9455

Wskaźnik SSIM równy 0,0119 oznacza bardzo niską jakość strukturalną rekonstrukcji, co sugeruje, że metoda nie jest efektywna w odtwarzaniu pierwotnych wzorców obrazu. Wartość wskaźnika korelacji metody, określona wskaźnikiem R_{Ty} wynoszącym 0,8219, jest umiarkowana, co świadczy o raczej niewielkiej odporności obrazów rekonstrukcyjnych na zmiany w danych pomiarowych. Regularyzacja Tikhonova wykazuje znacznie niższe RMSE, równe 1,2075, co wskazuje na mniejszy błąd rekonstrukcji w porównaniu z metodą Gaussa–Newtona. PSNR wynoszące 18,362 sugeruje znacznie lepszą jakość obrazu z mniejszym poziomem szumu w rekonstrukcji. Wskaźnik SSIM wynoszący 0,4842 oznacza wyższą jakość strukturalną rekonstrukcji, a R_{Ty} na poziomie 0,9472 wskazuje na dobrą korelację generowanych obrazów z referencjami. Metoda Total Variation charakteryzuje się RMSE równym 3,5184, co jest zbliżone do metody Gaussa–Newtona, ale PSNR wynoszący 9,0731 sugeruje wyższy poziom szumu w rekonstrukcji. Wskaźnik SSIM wynoszący 0,1756 oznacza lepszą jakość strukturalną niż metoda Gaussa–Newtona, ale stabilność określona wskaźnikiem R_{Ty} na poziomie 0,6245 jest niższa, co wskazuje na bardzo niską odporność rekonstruowanych obrazów tomograficznych na zmiany wartości wektorów pomiarowych. Maszyna wektorów nośnych (SVM) osiąga $RMSE = 1,1160$, co należy uznać za niski błąd rekonstrukcji. Wskaźnik PSNR wynoszący 19,051 sugeruje dobrą jakość obrazu, w którym poziom szumu jest niewielki. Wskaźnik strukturalny SSIM wynoszący 0,6625 również wskazuje na wysoką jakość rekonstrukcji. Wskaźnik korelacji Pearsona $R_{Ty} = 0,9335$ jest wysoki, co jest dowodem na dużą odporność obrazów rekonstrukcyjnych na zmiany w sygnałach pomiarowych.

Metoda elastic net wykazuje $RMSE = 9,2622$, co jest bardzo wysokim odchyleniem od obrazów wzorcowych. Wskaźnik PSNR wynoszący 0,6659 sugeruje bardzo wysoki poziom szumu, a SSIM równy -0,2269 świadczy o bardzo niskiej jakości strukturalnej obrazu wynikowego. Wskaźnik korelacji Pearsona R_{Ty} na poziomie 0,6185 jest niska, co jest przejawem bardzo słabej odporności

rekonstrukcji na zmiany w wektorach pomiarowych. Metoda regresji liniowej charakteryzuje się wysokim RMSE równym 6,8100. PSNR wynoszące 3,3370 sugeruje wysoki poziom szumu, a SSIM równy -0,2863 oznacza bardzo niską jakość strukturalną rekonstrukcji. Korelacja wygenerowanych i wzorcowych obrazów, wyrażona wskaźnikiem $R_{Ty} = 0,8594$ jest umiarkowana. Oznacza to akceptowalną odporność rekonstruowanych obrazów tomograficznych na zmiany w danych pomiarowych, choć mniejszą niż w przypadku bardziej zaawansowanych metod. WSSN osiąga bardzo niskie RMSE wynoszące 0,6661, co jest bardzo niskim błędem rekonstrukcji. PSNR wynoszące 23,5287 sugeruje bardzo niski poziom szumu, a SSIM równy 0,6327 oznacza wysoką jakość strukturalną rekonstrukcji. Wskaźnik korelacji metody R_{Ty} wynoszący 0,9747 jest najwyższy, co jest dowodem na bardzo dużą odporność obrazów rekonstrukcyjnych na zmiany wartości wektorów pomiarowych.

Metoda CNN charakteryzuje się RMSE równym 1,7984 oraz PSNR wynoszącym 14,9022, co oznacza niski poziom zaszumienia rekonstruowanych obrazów tomograficznych. SSIM równy 0,3156 wskazuje na umiarkowaną jakość strukturalną rekonstrukcji, a wskaźnik korelacji Pearsona R_{Ty} równy 0,8981 należy uznać za wysoki. Sieć LSTM osiąga wskaźnik RMSE równy 1,1705 oraz PSNR wynoszące 18,6324. Poziom szumu w rekonstrukcjach w przypadku tej metody jest więc niski. Wskaźnik SSIM równy 0,4723 wskazuje na wysoką jakość strukturalną rekonstrukcji, a R_{Ty} wynoszący 0,9213 potwierdza dobrą jakość metody. Metoda LSTM+CNN charakteryzuje się RMSE równym 1,0069 oraz PSNR wynoszącym 19,9400, co oznacza bardzo niski poziom zaszumienia rekonstrukcji. SSIM równy 0,4976 wskazuje na wysoką jakość strukturalną rekonstrukcji, a R_{Ty} wynoszące 0,9457 sugeruje wysoką korelację rekonstruowanych tomogramów z odpowiadającymi im wzorcami. Wielogałęziowa sieć neuronowa LSTM uzyskała RMSE równy 0,9874 oraz PSNR wynoszący 20,1098, co wskazuje na bardzo niski poziom zaszumienia obrazów rekonstrukcyjnych. SSIM równy 0,5133 oznacza wysoką jakość strukturalną rekonstrukcji, a korelacja R_{Ty} wynosząca 0,9455 jest bardzo wysoka. Analiza wskaźników jakości rekonstrukcji dla przypadku nr 3 potwierdza wnioski z poprzednich przypadków, że zaawansowane metody oparte na sieciach neuronowych, takie jak WSSN, CNN, LSTM oraz kombinacje LSTM+CNN, osiągają lepsze wyniki w porównaniu z metodami tradycyjnymi. W szczególności metoda WSSN ponownie wyróżnia się najniższym błędem rekonstrukcji i wysoką jakością strukturalną.

Tabela 5.12 przedstawia wskaźniki jakości rekonstrukcji dla przypadku nr 4, oceniając różne metody przy użyciu wskaźników takich jak RMSE, PSNR, SSIM oraz R_{Ty} . Metoda Gaussa–Newtona charakteryzuje się wartością RMSE

wynoszącą 5,8843, co wskazuje na dość wysoki średni błąd rekonstrukcji. Wartość PSNR wynosząca 4,6061 sugeruje, że zrekonstruowany obraz zawiera znaczny poziom szumu lub artefaktów. Wskaźnik SSIM równy 0,0306 oznacza bardzo niską jakość strukturalną rekonstrukcji, co wskazuje na słabą zdolność metody do wiernego odtwarzania oryginalnych struktur obrazu. Stabilność metody, określona wskaźnikiem R_{Ty} wynoszącym 0,8050, jest umiarkowana, co jest równoznaczne z ograniczoną odpornością rekonstrukcji na zmiany w sygnałach pomiarowych.

Tabela. 5.12. Wskaźniki jakości rekonstrukcji dla przypadku nr 4

Metoda	RMSE	PSNR	SSIM	R_{Ty}
Gaussa–Newtona	5,8843	4,6061	0,0306	0,8050
Regularyzacja Tikhonova	4,0573	7,8353	0,2036	0,9268
Total Variation	6,1230	4,2607	0,0187	0,7218
SVM	1,7222	15,2785	0,8531	0,9229
elastic net	9,6394	0,3190	-0,6009	0,7755
Regresja liniowa	6,7134	3,4611	-0,3831	0,9072
WSSN	1,1970	18,4381	0,9030	0,9634
CNN	2,4215	12,3185	0,7142	0,9163
LSTM	1,6459	15,6721	0,8453	0,9319
LSTM+CNN	1,5779	16,0387	0,8514	0,9370
Wielogałęziowa LSTM	1,4974	16,4931	0,8718	0,9447

W przypadku regularyzacji Tikhonova wskaźnik RMSE jest niższy i wynosi 4,0573. Jest to mniejszy błąd rekonstrukcji w porównaniu z metodą Gaussa–Newtona. Wskaźnik PSNR wynoszący 7,8353 sugeruje lepszą jakość obrazu z mniejszym poziomem szumu w rekonstrukcji. Wskaźnik SSIM wynoszący 0,2036 oznacza wyższą jakość strukturalną rekonstrukcji, a R_{Ty} wynoszący 0,9268 wskazuje na wysoką korelację, co jest zaletą. Metoda Total Variation charakteryzuje się RMSE równym 6,1230, co jest wyższe od wartości dla metody Gaussa–Newtona, a PSNR wynoszące 4,2607 sugeruje wysoki poziom szumu w rekonstrukcji. Wskaźnik SSIM wynoszący 0,0187 jest niski, co oznacza niską jakość strukturalną rekonstrukcji. Regresja Pearsona, określona wskaźnikiem R_{Ty} na poziomie 0,7218, jest niższa, co wskazuje na większą wrażliwość zrekonstruowanych obrazów na zmiany w danych pomiarowych. Dla metody SVM wskaźnik RMSE wynosi 1,7222, co dobrze świadczy o jakości tej metody. PSNR wynoszące 15,2785 również sugeruje dobrą jakość obrazu z niewielkim poziomem szumu, natomiast SSIM równy 0,8531 wskazuje na

bardzo wysoką jakość strukturalną rekonstrukcji. Wskaźnik korelacji metody $R_{Ty} = 0,9229$ jest wysoki, co świadczy o dużej odporności rekonstruowanych obrazów tomograficznych na zmiany wartości wektorów pomiarowych. Elastic net wykazuje bardzo wysokie RMSE, równe 9,6394, co oznacza duży błąd rekonstrukcji. PSNR wynoszące 0,3190 wskazuje na bardzo wysoki poziom szumu, a SSIM równy -0,6009 wskazuje na bardzo niską jakość strukturalną. Wskaźnik korelacji Pearsona R_{Ty} na poziomie 0,7755 jest niski, co świadczy o wrażliwości obrazów rekonstrukcyjnych na zmiany w pomiarach.

Regresja liniowa charakteryzuje się wysokim RMSE równym 6,7134, co podobnie jak w innych przypadkach pomiarowych wskazuje na duży błąd rekonstrukcji. PSNR wynoszące 3,4611 sugeruje wysoki poziom szumu, a SSIM równy -0,3831 oznacza bardzo niską jakość strukturalną rekonstrukcji. Wskaźnik Pearsona R_{Ty} wynoszący 0,9072 jest umiarkowany, co oznacza pewną odporność rekonstrukcji na zmiany w sygnałach pomiarowych, choć mniejszą niż w przypadku bardziej zaawansowanych metod. Metoda WSSN osiąga bardzo niskie RMSE wynoszące 1,1970, co wskazuje na bardzo niski błąd rekonstrukcji. PSNR wynoszące 18,4331 wskazuje na bardzo niski poziom szumu, a SSIM równy 0,9030 oznacza wysoką jakość strukturalną rekonstrukcji. Wskaźnik korelacji Pearsona R_{Ty} równy 0,9634 jest najwyższy, co oznacza dużą odporność rekonstrukcji na zmiany w danych pomiarowych.

Metoda CNN charakteryzuje się RMSE równym 2,4215 oraz PSNR wynoszącym 12,3186, co wskazuje na niski poziom zaszumienia rekonstrukcji. SSIM równy 0,7142 wskazuje na dobrą jakość strukturalną rekonstrukcji, a korelacja R_{Ty} wynosząca 0,9163 jest wysoka. Sieć LSTM osiąga RMSE równy 1,6459 oraz PSNR wynoszące 15,6721, co świadczy o niskim poziomie zaszumienia rekonstruowanych obrazów tomograficznych. Wskaźnik SSIM równy 0,8453 wskazuje na bardzo wysoką jakość strukturalną rekonstrukcji, a R_{Ty} wynoszący 0,9319 wskazuje na dobrą jakość metody. Metoda LSTM+CNN charakteryzuje się RMSE równym 1,5779 oraz PSNR wynoszącym 16,0387, co oznacza bardzo niski poziom zaszumienia rekonstrukcji. SSIM równy 0,8514 wskazuje na wysoką jakość strukturalną rekonstrukcji, a wysoka wartość współczynnika $R_{Ty} = 0,9370$ świadczy o wysokiej jakości metody. Wielogałęziowa LSTM osiąga RMSE równy 1,4974 oraz PSNR wynoszący 16,4931, co wskazuje na bardzo niski poziom zaszumienia obrazów rekonstrukcyjnych. SSIM równy 0,8718 oznacza wysoką jakość strukturalną rekonstrukcji, a korelacja R_{Ty} wynosząca 0,9447 jest bardzo wysoka. Analiza wskaźników jakości rekonstrukcji dla przypadku nr 4 potwierdza, że zaawansowane metody oparte na sieciach neuronowych, takie jak WSSN, CNN, LSTM oraz kombinacje LSTM+CNN, osiągają

lepsze wyniki w porównaniu z metodami tradycyjnymi, których przykładami są: metoda Gaussa–Newtona, regularyzacja Tikhonova, Total Variation, SVM, elastic net i regresja liniowa. Ponownie metoda WSSN wyróżnia się najniższym błędem rekonstrukcji i wysoką jakością strukturalną, co czyni ją najbardziej efektywną spośród analizowanych metod.

Analiza metod rekonstrukcji obrazów ETI w oparciu o cztery załączone tabele (5.9, 5.10, 5.11 i 5.12) umożliwia uzyskanie wstępnej oceny porównawczej danej metody na tle innych metod. Metoda Gaussa–Newtona we wszystkich przypadkach wykazuje stosunkowo wysokie wartości RMSE. Wartość wskaźnika PSNR dla tej metody jest niska, wskazując na obecność znacznego poziomu szumu w zrekonstruowanych obrazach. Wskaźnik SSIM jest bardzo niski, co świadczy o słabej jakości strukturalnej rekonstrukcji, a model nie odtwarza poprawnie pierwotnych wzorców obrazu. Wskaźnik korelacji Pearsona R_{Ty} metody Gaussa–Newtona jest umiarkowany, co oznacza, że wyniki rekonstrukcji są do pewnego stopnia odporne na niewielkie zmiany w danych wejściowych. Ogólna ocena jakości rekonstrukcji pozostaje jednak niska.

Regularyzacja Tikhonova osiąga znacznie lepsze wyniki niż metoda Gaussa–Newtona. Wartości RMSE są niskie, co wskazuje na mniejszy błąd rekonstrukcji. Wysokie wartości PSNR sugerują lepszą jakość obrazu z mniejszym poziomem szumu w rekonstrukcji. Wskaźniki SSIM są znacznie wyższe, co oznacza lepszą jakość strukturalną rekonstrukcji, wskazując, że analizowana metoda dobrze odtwarza pierwotne wzorce obrazu. Stabilność metody regularyzacji Tikhonova jest wysoka, co czyni ją bardziej niezawodną i mniej podatną na zmiany w danych pomiarowych.

Metoda Total Variation charakteryzuje się umiarkowanymi wartościami RMSE i PSNR. Na podstawie analizy ww. wskaźników można ocenić, że analizowana metoda jest mniej efektywna niż regularyzacja Tikhonova, ale lepsza od metody Gaussa–Newtona. Wskaźniki SSIM dla badanych przypadków są niskie, co oznacza słabą jakość strukturalną rekonstrukcji. Korelacja Pearsona R_{Ty} jest także niższa, co wskazuje na niską odporność zrekonstruowanych obrazów tomograficznych na zmiany wartości wektorów pomiarowych.

Dla metody SVM wartości RMSE są umiarkowane. Z kolei wartości PSNR należy uznać za stosunkowo wysokie. Interpretacja wskaźników określa analizowaną metodę jako przeciętną zarówno pod względem jakości uzyskiwanych rekonstrukcji, jak również szumu widocznego na tomogramach. Wartości SSIM dla poszczególnych przypadków przyjmują wartości od umiarkowanych do wysokich. Świadczą one o lepszej jakości strukturalnej niż w przypadku takich metod jak metoda Gaussa–Newtona i Total Variation. Korelacja Pearsona R_{Ty}

jest zmienna, ale ogólnie wyższa niż w przypadku Total Variation, co sugeruje, że metoda SVM jest bardziej niezawodna.

Elastic net cechuje się bardzo wysokimi wartościami RMSE i bardzo niskimi wartościami PSNR we wszystkich przypadkach, co wskazuje na dużą obecność szumu i słabą jakość rekonstrukcji. Wartości SSIM są bardzo niskie, co oznacza bardzo słabą jakość strukturalną. Wartość wskaźnika korelacji R_{Ty} jest zmienna, ale ogólnie niska, co czyni tę metodę jedną z najmniej efektywnych.

Regresja liniowa charakteryzuje się bardzo wysokimi wartościami RMSE i bardzo niskimi wartościami PSNR we wszystkich przypadkach. Stanowi to przesłankę do niskiej oceny tej metody, mającej odzwierciedlenie w bardzo słabej jakości rekonstrukcji i wyraźnej obecności szumu na generowanych przez model obrazach. Wskaźniki SSIM są ujemne lub bliskie zeru, co oznacza bardzo słabą jakość strukturalną. Wartość wskaźnika korelacji R_{Ty} jest zmienna, ale ogólnie niska, co czyni tę metodę jedną z najmniej niezawodnych.

Metoda WSSN we wszystkich przypadkach osiąga najniższe wartości RMSE i najwyższe wartości PSNR. Wskazuje to na bardzo dobrą jakość rekonstrukcji i niski poziom zaszumienia rekonstrukcji. Wartości SSIM są wysokie, co oznacza dobrą jakość strukturalną rekonstrukcji. Korelacja Pearsona uzyskiwana z rekonstrukcji tą metodą jest bardzo wysoka, co czyni ją jedną z najbardziej niezawodnych i efektywnych. Tego rodzaju wnioski może zaskakiwać, ponieważ warstwa w pełni połączona jest klasycznym, znanym od dawna elementem sztucznych sieci neuronowych. Czynnikiem, który wpływa na wysoką skuteczność struktury WSSN jest jednowymiarowe wyjście i łatwość uczenia się.

Metoda CNN wykazuje niskie wartości RMSE i wysokie wartości PSNR we wszystkich przypadkach, co wskazuje na dobrą jakość rekonstrukcji i niski poziom zaszumienia obrazu wyjściowego. Poziomy wskaźnika SSIM są umiarkowane do wysokich. Oznacza to dobrą jakość strukturalną rekonstrukcji. Regresja modelu wyrażona wskaźnikiem R_{Ty} jest wysoka, co czyni tę metodę niezawodną.

Sieć złożona z warstw LSTM osiąga niskie wartości RMSE i wysokie wartości PSNR, co wskazuje na dobrą jakość rekonstrukcji i niski poziom zaszumienia obrazów rekonstrukcyjnych. Wskaźniki SSIM są wysokie, co oznacza bardzo dobrą jakość strukturalną rekonstrukcji. Wysoka korelacja R_{Ty} czyni tę metodę niezawodną.

Metoda LSTM+CNN charakteryzuje się bardzo niskimi wartościami RMSE i wysokimi wartościami PSNR, co wskazuje na bardzo dobrą jakość rekonstrukcji i niski poziom zaszumienia rekonstruowanych obrazów tomograficznych. Wartości SSIM są wysokie, co jest dowodem na bardzo dobrą jakość strukturalną.


Korelacja Pearsona R_{Ty} jest bardzo wysoka, co czyni tę metodę jedną z najbardziej efektywnych i niezawodnych.

Wielogałęziowa LSTM osiąga najniższe wartości RMSE i najwyższe wartości PSNR we wszystkich przypadkach, co wskazuje na najlepszą jakość rekonstrukcji i najniższy poziom szumu. Wartości SSIM są najwyższe, co wskazuje na bardzo dobrą jakość strukturalną rekonstrukcji. Wskaźnik korelacji R_{Ty} jest najwyższy, co czyni tę metodę najbardziej efektywną i niezawodną spośród wszystkich analizowanych metod.

Analiza wszystkich czterech przypadków pomiarowych wskazuje, że zaawansowane metody oparte na sieciach neuronowych, takie jak WSSN, CNN, LSTM oraz kombinacje LSTM+CNN, osiągają najlepsze wyniki pod względem RMSE, PSNR, SSIM i stabilności wyrażonej za pomocą wskaźnika regresji R_{Ty} . W szczególności wielogałęziowa LSTM wyróżnia się jako najbardziej efektywna i niezawodna metoda rekonstrukcji obrazów ETI, przewyższając tradycyjne metody takie jak Gaussa–Newtona, regularyzacja Tikhonova, Total Variation, SVM, elastic net i regresja liniowa.


Wysokie wartości PSNR i SSIM oraz niskie wartości RMSE zazwyczaj przekładają się na wizualnie lepsze odwzorowanie obrazów wzorcowych. Trzeba przy tym pamiętać, że zastąpienie ludzkiej percepcji za pomocą miar liczbowych zawsze stanowiło wyzwanie [82, 161]. W szczególności metody WSSN, LSTM+CNN oraz wielogałęziowa LSTM, które osiągają najwyższe wskaźniki jakości, także wizualnie prezentują najwyższą zgodność z obrazami wzorcowymi. Stanowi to potwierdzenie, że wskaźniki jakości rekonstrukcji są dobrym miernikiem skuteczności metod rekonstrukcyjnych.

Na rysunku 5.30 przedstawiono wykres pudełkowy, ilustrujący wartości błędu rekonstrukcji RMSE. Każde pudełko (tzw. box) reprezentuje międzykwartyłowy rozstęp (IQR), czyli zakres wartości od pierwszego (Q1) do trzeciego kwartyłu (Q3), co oznacza, że 50% obserwacji znajduje się w zakresie pudełka. Linia wewnątrz pudełka przedstawia medianę danych, czyli wartość środkową. Wąsy rozciągają się od końca pudełka do najmniejszej i największej wartości w granicach 1,5 IQR od Q1 i Q3. Wartości leżące poza tym zakresem są uznawane za odległe (tzw. outliers), co sugeruje istnienie obserwacji oddalonych od reszty danych. Wykres pokazuje, że metoda elastic net ma najwyższe wartości RMSE, co wskazuje na największy błąd rekonstrukcji, podczas gdy WSSN i wielogałęziowa LSTM osiągają najniższe wartości RMSE.




Rys. 5.30. Wykres pudełkowy średniego wskaźnika RMSE dla poszczególnych metod

Wykres przedstawiony na rysunku 5.31 przedstawia rozkład wartości PSNR, które oceniają jakość obrazu przez pryzmat stosunku sygnału do szumu. Metody WSSN, LSTM+CNN i wielogaleziowa LSTM osiągają najwyższe wartości PSNR, co wskazuje na najlepszą jakość rekonstrukcji z najmniejszym poziomem szumu w obrazie. Metody elastic net i regresja liniowa mają najniższe wartości PSNR, co świadczy o wysokim poziomie szumu w rekonstrukcjach.




Rys. 5.31. Wykres pudełkowy średniego wskaźnika PSNR dla poszczególnych metod

Rysunek 5.32 prezentuje rozkład wartości SSIM, które oceniają jakość strukturalną rekonstrukcji obrazu. Metody SVM, WSSN, LSTM, LSTM+CNN oraz wielogałęziowa LSTM mają najwyższe wartości SSIM, co oznacza najlepszą jakość strukturalną rekonstrukcji. Metody Gaussa–Newtona, regresja liniowa i elastic net mają najniższe wartości SSIM, co wskazuje na słabą jakość strukturalną.



Rys. 5.32. Wykres pudełkowy średniego wskaźnika SSIM dla poszczególnych metod

Na rysunku 5.33 przedstawiono wartości wskaźnika Pearsona R_{Ty} , który pokazuje rozkład wartości stabilności rekonstrukcji dla każdej metody. Metody WSSN, LSTM, LSTM+CNN oraz wielogałęziowa LSTM osiągają najwyższe wartości R_{Ty} , co oznacza, że są najbardziej stabilne i odporne na zmiany w sygnałach pomiarowych. Pozostałe metody wykazują większą zmienność, co świadczy o ich niższej jakości w zakresie generowania rekonstrukcji ETI.



Rys. 5.33. Wykres pudełkowy średniego wskaźnika R-Pearsona dla poszczególnych metod

Analiza powyższych rysunków potwierdza, że zaawansowane metody oparte na sieciach neuronowych, takie jak WSSN, LSTM, LSTM+CNN oraz wielogłęziowa LSTM, wykazują najlepsze wyniki pod względem wszystkich wskaźników jakości rekonstrukcji. Metody te charakteryzują się niskimi wartościami RMSE, wysokimi wartościami PSNR i SSIM, a także wysokim poziomem współczynnika korelacji $R_{T\hat{Y}}$. Tradycyjne techniki, takie jak Total Variation, regresja liniowa, regularyzacja Tikhonova i metoda Gaussa–Newtona, są znacząco gorsze, zwłaszcza w odniesieniu do jakości strukturalnej i stabilności rekonstrukcji. Metody elastic net i regresja liniowa osiągają najgorsze wyniki we wszystkich wskaźnikach, co sprawia, że są najmniej skuteczne w rekonstrukcji obrazów ETI.

Tabela 5.13 przedstawia wskaźniki jakości rekonstrukcji dla dużej próby, obejmującej 1000 przypadków testowych. Analiza umożliwia ocenę spójności wyników metod rekonstrukcji obrazów ETI w kontekście wcześniejszych analiz, które obejmowały cztery pojedyncze przypadki pomiarowe.

Tabela. 5.13. Wskaźniki jakości rekonstrukcji dla dużej próby przypadków testowych

Metoda	RMSE	PSNR	SSIM	$R_{T\hat{Y}}$
Gaussa–Newtona	4,5355	7,9832	0,0239	0,7576
Regularyzacja Tikhonova	2,1020	15,195	0,4458	0,8544
Total Variation	4,7103	7,6323	0,1220	0,6028
SVM	5,2430	5,8278	0,0547	0,0935

Tabela. 5.13. Wskaźniki jakości rekonstrukcji dla dużej próby przypadków testowych

Metoda	RMSE	PSNR	SSIM	R_{Ty}
elastic net	9,5757	0,3846	-0,2595	0,5612
Regresja liniowa	7,0204	3,0815	-0,1434	0,7017
WSSN	0,8922	21,4309	0,6185	0,9119
CNN	2,3030	13,1962	0,3552	0,7752
LSTM	1,3462	17,8076	0,4946	0,8395
LSTM+CNN	1,2904	18,1421	0,5009	0,8470
Wielogałęziowa LSTM	1,0764	19,6988	0,5348	0,8853

Na dużej próbie danych testowych Metoda Gaussa–Newtona wykazuje stosunkowo wysokie wartości RMSE. Podobnie jak w poprzednich przypadkach, błąd rekonstrukcji w przypadku tej metody jest znaczący. Wartości PSNR są niskie, co wskazuje na obecność wysokiego zaszumienia w zrekonstruowanych obrazach. Wskaźnik SSIM również jest niski, co jest dowodem słabej jakości strukturalnej rekonstrukcji. Korelacja wyrażona za pomocą wskaźnika Pearsona R_{Ty} jest umiarkowana, podobnie jak w analizowanych wcześniej przypadkach. Ten fakt stanowi potwierdzenie, że metoda Gaussa–Newtona charakteryzuje się niewielką efektywnością i należy ją uznać za nieprzydatną.

Regularyzacja Tikhonova, podobnie jak w poprzednich analizach, wykazuje lepsze wyniki niż Gaussa–Newtona. RMSE jest niskie, co oznacza mniejszy błąd rekonstrukcji, a wartości PSNR są znacznie wyższe, wskazując na lepszą jakość obrazów rekonstrukcyjnych z mniejszym poziomem szumu. Wartości SSIM są wyższe, co świadczy o lepszej jakości strukturalnej rekonstrukcji. Korelacja metody R_{Ty} jest wysoka, co potwierdza wcześniejsze obserwacje, że regularyzacja Tikhonova jest bardziej niezawodna.

Metoda Total Variation wykazuje umiarkowane wartości RMSE i PSNR, co sugeruje, że jest mniej efektywna niż regularyzacja Tikhonova, ale lepsza niż Gaussa–Newtona. Wskaźniki SSIM są niskie, co jest przesłanką słabej jakości strukturalnej rekonstrukcji testowych. Wskaźnik Pearsona R_{Ty} jest niższy, co świadczy o niewielkiej odporności zrekonstruowanych obrazów tomograficznych na zmiany w danych pomiarowych, co jest potwierdzeniem wcześniejszych wyników.

Metoda SVM, w wyniku analizy obejmującej 1000 przypadków testowych, wykazuje wyższe wartości RMSE i niskie wartości PSNR. Sugeruje to słabą jakość rekonstrukcji i wysoki poziom szumu. Wartości SSIM są niskie, co wskazuje na niską jakość strukturalną. Wskaźnik korelacji R_{Ty} jest bardzo niski, co jest zgodne z wcześniejszymi obserwacjami, sugerującymi relatywnie

gorszą niezawodność metody SVM. Metoda elastic net ponownie wykazuje bardzo wysokie wartości RMSE i bardzo niskie wartości PSNR, co potwierdza duży błąd rekonstrukcji i wysoki poziom szumu. Wartości SSIM są bardzo niskie, co oznacza bardzo słabą jakość strukturalną. Wskaźnik korelacji R_{Ty} jest niski, co potwierdza, że metoda ta jest jedną z najmniej efektywnych i niezawodnych. Metoda regresji liniowej wykazuje bardzo wysokie wartości RMSE i bardzo niskie wartości PSNR, co wskazuje na bardzo słabą jakość rekonstrukcji i dużą obecność artefaktów. Wskaźniki SSIM są ujemne lub bliskie zeru, co oznacza bardzo słabą jakość strukturalną. Korelacja R_{Ty} jest zmienna, ale ogólnie niska, co czyni tę metodę jedną z najmniej niezawodnych, zgodnie z wcześniejszymi wynikami.


Metoda WSSN osiąga najniższe wartości RMSE i najwyższe wartości PSNR, co wskazuje na bardzo dobrą jakość rekonstrukcji i niski poziom zaszumienia obrazu wyjściowego. Wartości SSIM są wysokie, co wskazuje na dobrą jakość strukturalną rekonstrukcji. Korelacja wyrażona przez R_{Ty} jest bardzo wysoka, co czyni tę metodę jedną z najbardziej niezawodnych i efektywnych, potwierdzając wcześniejsze obserwacje.

Metoda CNN wykazuje niskie wartości RMSE i wysokie wartości PSNR, co wskazuje na dobrą jakość rekonstrukcji i niski poziom zaszumienia rekonstrukcji. Wskaźniki SSIM są umiarkowane do wysokich, co świadczy o dobrej jakości strukturalnej. Korelacja wyrażona wskaźnikiem R_{Ty} jest wysoka, co jest zgodne z wcześniejszymi obserwacjami.

LSTM osiąga niskie wartości RMSE i wysokie wartości PSNR, co wskazuje na dobrą jakość rekonstrukcji i niski poziom zaszumienia obrazów rekonstrukcyjnych. Wskaźniki SSIM są wysokie, co oznacza bardzo dobrą jakość strukturalną rekonstrukcji. Wskaźnik R_{Ty} jest wysoki, co potwierdza, że metoda ta jest niezawodna. Metoda LSTM+CNN charakteryzuje się bardzo niskimi wartościami RMSE i wysokimi wartościami PSNR, co wskazuje na bardzo dobrą jakość rekonstrukcji i niski poziom zaszumienia rekonstrukcji. Wartości SSIM są wysokie, co wskazuje na bardzo dobrą jakość strukturalną. Korelacja R_{Ty} jest bardzo wysoka, co czyni tę metodę jedną z najbardziej efektywnych i niezawodnych. Ostatnią z analizowanych metod jest metoda wielogałęziowa LSTM. Ta metoda uzyskała najniższe wartości RMSE i najwyższe wartości PSNR, co wskazuje na najlepszą jakość rekonstrukcji i najniższy poziom artefaktów. Wartości SSIM są najwyższe, co oznacza bardzo dobrą jakość strukturalną rekonstrukcji. Korelacja R_{Ty} jest najwyższa, co czyni tę metodę najbardziej efektywną i niezawodną spośród wszystkich analizowanych metod. Analiza tabeli dla dużej próby potwierdza oceny metod zawarte w poprzednich tabelach.

Metody oparte na sieciach neuronowych, takie jak WSSN, LSTM, LSTM+CNN oraz wielogłęziowa LSTM, wykazują najlepsze wyniki pod względem RMSE, PSNR, SSIM i R_T . Tradycyjne metody, takie jak Gaussa–Newtona, regularyzacja Tikhonova i Total Variation, wypadają gorzej, szczególnie pod względem jakości strukturalnej i stabilności rekonstrukcji. Metody elastic net i regresja liniowa osiągają najgorsze wyniki we wszystkich wskaźnikach, co czyni je najmniej efektywnymi w kontekście rekonstrukcji obrazów ETI.


Rysunki 5.34–5.37 są wizualizacją tabeli 5.13. Na rysunku 5.34 przedstawiono wykresy RMSE dla poszczególnych metod rekonstrukcji dla dużej próby. Tradycyjnie metoda Gaussa–Newtona wykazuje wysokie wartości RMSE, co wskazuje na znaczny błąd rekonstrukcji. W ten sam sposób metoda Total Variation i SVM mają wysokie wartości RMSE, co wskazuje na istnienie większych błędów rekonstrukcji. Metoda elastic net osiąga najwyższe wartości RMSE spośród innych metod, co świadczy o tym, że generuje największy błąd rekonstrukcji spośród wszystkich analizowanych. W przeciwieństwie do tego metody WSSN i wielogłęziowe LSTM osiągają najniższe wartości RMSE, co wskazuje na najniższy błąd rekonstrukcji i tym samym największą dokładność.



Rys. 5.34. Wykres średniego wskaźnika RMSE dla dużej próby


Rysunek 5.35 prezentuje wartości wskaźnika PSNR dla dużej próby. Na jego podstawie można wnioskować, że w zrekonstruowanych obrazach istnieje znaczny poziom zaszumienia obrazu wyjściowego, ponieważ metody Gaussa–Newtona, jak i Total Variation wykazują stosunkowo niskie wartości

PSNR. Potwierdza się, że obrazy zrekonstruowane za pomocą metody elastic net mają największy poziom szumu, ponieważ ta metoda osiąga najniższe wartości PSNR. Metody WSSN, LSTM+CNN i wielogłęziowe LSTM wykazują najwyższe wartości PSNR, co wskazuje na najlepszą jakość rekonstrukcji z najmniejszym poziomem zaszumienia.




Rys. 5.35. Wykres średniego wskaźnika PSNR dla dużej próby

Rysunek 5.36 przedstawia wykres słupkowy dla wskaźnika SSIM, który odzwierciedla jakość strukturalną rekonstrukcji obrazów. Lepsza zgodność strukturalna między zrekonstruowanym obrazem a obrazem pierwotnym jest reprezentowana przez wyższe wartości SSIM. Zarówno metody Gaussa–Newtona, jak i Total Variation wykazują bardzo niskie wartości SSIM. Metoda elastic net ma najniższe wartości SSIM, a nawet ujemne, co wskazuje na niską jakość rekonstrukcji strukturalnej. Metody WSSN, LSTM i LSTM+CNN osiągnęły najwyższe wartości SSIM, co sugeruje, że są one najbardziej efektywne w zachowywaniu struktury oryginalnego obrazu.



Rys. 5.36. Wykres średniego wskaźnika SSIM dla dużej próby

Wykres słupkowy dla wskaźnika Pearsona R_{Ty} , widoczny na rysunku 3.37, ilustruje stabilność rekonstrukcji. Większa stabilność i odporność rekonstruowanych obrazów tomograficznych na zmiany wartości wektorów pomiarowych są odzwierciedlane przez wyższe wartości R_{Ty} .



Rys. 5.37. Wykres średniego wskaźnika R-Pearsona dla dużej próby

Metoda Gaussa–Newtona i regularyzacja Tikhonova mają umiarkowane wartości korelacji Pearsona. Regularyzacja Tikhonova jest jednak nieco bardziej stabilna. Większa wrażliwość rekonstrukcji na zmiany w sekwencjach pomiarowych wynika z niższych wartości wskaźnika regresji zarówno metody Total Variation, jak i SVM. Metoda elastic net ma najniższe wartości regresji Pearsona, co oznacza niską odporność obrazów rekonstrukcyjnych wygenerowanych tą metodą na zmiany w sygnałach pomiarowych. Metody WSSN, LSTM+CNN i wielogałęziowe LSTM osiągają najwyższe wskaźniki regresji Pearsona, co potwierdza ich wysoką niezawodność.

5.11. Rekonstrukcje rozkładu zawilgoceń obiektu rzeczywistego

Wytrenowane i zweryfikowane w oparciu o dane symulacyjne modele algorytmiczne można zastosować do rekonstrukcji obrazów tomograficznych, których źródłem są pomiary wykonane w obiektach rzeczywistych. Dzięki zastosowaniu technik symulacyjnych możliwe jest wygenerowanie dużych zbiorów danych, które odzwierciedlają różnorodne scenariusze rozkładu wilgoci. Takie podejście pozwala na stworzenie kompleksowych modeli, które są w stanie przekształcić zebrane pomiary impedancji na obrazy tomograficzne. Kluczową zaletą tego podejścia jest możliwość trenowania modeli na danych syntetycznych, co znacząco obniża koszty i czasochłonność procesu, zwłaszcza w porównaniu z uciążliwym i długotrwałym zbieraniem danych rzeczywistych.

Jednym z głównych wyzwań związanych z rekonstrukcją obrazów w obiektach rzeczywistych jest utrudniona weryfikacja ich jakości. Brak obrazów referencyjnych, które mogłyby posłużyć jako wzorce do oceny dokładności rekonstrukcji, stanowi istotny problem. W praktyce dokładność rekonstrukcji często ocenia się poprzez porównanie wyników z oczekiwanymi rozkładami wilgoci, co jest subiektywne i może prowadzić do błędów oceny. Kolejnym wyzwaniem jest zmienność wartości wektorów pomiarowych zgromadzonych w warunkach rzeczywistych. Wartości te mogą znacząco różnić się od tych, które były wykorzystywane podczas trenowania modeli. Powyższe różnice mogą wynikać z wielu czynników, takich jak zmienne warunki atmosferyczne, różnorodność materiałów budowlanych wykorzystanych do budowy badanego fragmentu muru czy niejednorodność struktury ściany. Taka zmienność może prowadzić do błędów rekonstrukcji, jeśli model nie jest wystarczająco elastyczny i nie posiada zdolności do generalizacji.


Dobrze wytrenowane modele neuronowe mają duży potencjał do generalizacji, który pozwala im na tworzenie poprawnych rekonstrukcji nawet wtedy, gdy bezwzględne wartości pomiarów rzeczywistych odbiegają od wartości pomiarów symulacyjnych, na których dany model był trenowany. Modele te, dzięki swojej złożonej architekturze i zdolności do uczenia się zależności nieliniowych, mogą efektywnie adaptować się do nowych, nieznanych wcześniej danych. Ważne jest przy tym, aby proces trenowania modeli obejmował szeroki zakres scenariuszy symulacyjnych. Jakość danych uczących ma zasadniczy i decydujący wpływ na zdolność modeli do prawidłowego odtwarzania rzeczywistych rozkładów wilgoci w ścianach budynków.

Impedancyjna tomografia elektryczna nie jest metodą pomiarów wielkości bezwzględnych. Oznacza to, że nie pozwala ona na bezpośrednie określenie absolutnych, procentowych wartości wilgoci w badanym materiale. Takie informacje można uzyskać przy użyciu metod bezwzględnych, jak metoda suszarkowo-wagowa, która polega na pomiarze masy próbki przed wysuszeniem i po jej wysuszeniu, co pozwala na precyzyjne, procentowe określenie zawartości wody. Tomogramy uzyskane za pomocą ETI umożliwiają względne zobrazowanie rozkładów wilgoci opartych na różnicach w zawilgoceniu poszczególnych obszarów wewnątrz badanego fragmentu muru. Względność ta polega na umownym założeniu, które elementy skończone siatki FEM będą uważane za mokre, a które za suche. Proces ten bazuje na różnicach konduktywności elektrycznej poszczególnych wokseli, które to różnice są interpretowane jako różnice w zawilgoceniu.

Badany obiekt rzeczywisty został sztucznie zawilgocony w warunkach laboratoryjnych, dzięki czemu można było przewidzieć spodziewany rozkład jego zawilgocenia. Badany mur ceglany opisany w rozdziale 5.1. był od spodu zanurzony w wodzie o głębokości kilku centymetrów, a na górze obiektu znajdował się otoczony cegłami zbiornik z wodą. Górny zbiornik został zalany wodą poprzedniego dnia około godziny 14:00, natomiast pomiary wykonano około godziny 10 dnia następnego. Pomiędzy napełnieniem górnego zbiornika a pomiarami minęło więc około 20 godzin. W chwili pomiaru górny zbiornik nie zawierał już wody, która w większości wniknęła do wnętrza muru poprzez pory w materiale, z którego był wykonany. Drugim czynnikiem braku wody w górnym zbiorniku było jej odparowanie.

Rysunek 5.38 przedstawia walidacyjne zdjęcie muru w chwili pomiarów ETI, wykonane za pomocą kamery termowizyjnej FLIR-T540 (FLIR Systems, Inc., Wilsonville, OR, USA). Termografia jest czuła na różnice temperatur, co umożliwia identyfikację obszarów o podwyższonej wilgotności. Zawilgocone

fragmenty muru zazwyczaj mają inną temperaturę niż obszary suche, co jest widoczne na zdjęciach termowizyjnych.



Rys. 5.38. Termowizyjny obraz obiektu rzeczywistego

Źródło: materiały Netrix S.A.

Zdjęcia termowizyjne mają także swoje wady. Główną wadą termowizji jest jej powierzchowność. Wspomniana metoda bada jedynie powierzchnię obiektu, nie dostarczając informacji o stanie wnętrza muru. W praktyce oznacza to, że termografia może wykazać różnice temperatur na powierzchni, które mogą być związane z wilgocią, ale nie daje pełnego obrazu zawilgocenia wewnątrz struktury. W rezultacie możliwe jest przeoczenie głębszych problemów z wilgocią, które nie znajdują swojego odzwierciedlenia na powierzchni. Innym ograniczeniem termowizji jest wpływ warunków zewnętrznych na wyniki pomiarów. Czynniki takie jak nasłonecznienie, wiatr czy różnice temperatur w ciągu dnia mogą wpływać na dokładność i wiarygodność zdjęć termowizyjnych. Na przykład nasłoneczniona ściana może wydawać się sucha na termogramie, mimo że w rzeczywistości jest zawilgocona. Dlatego konieczne jest przeprowadzanie pomiarów w odpowiednich warunkach, co nie zawsze jest możliwe. Termografia nie dostarcza bezpośrednich informacji o stopniu zawilgocenia. Zdjęcia termowizyjne pokazują jedynie różnice temperatur, które mogą być związane z wilgocią, ale nie określają dokładnej ilości wody


zawartej w murze. Prócz tego interpretacja zdjęć termowizyjnych wymaga doświadczenia i wiedzy specjalistycznej.

Pomimo wad, zdjęcia termowizyjne mogą posłużyć jako uzupełniająca metoda walidacji dla obrazów tomograficznych uzyskanych z pomiarów rzeczywistych. Na rysunku 5.39 przedstawiono przestrzenną rekonstrukcję obiektu rzeczywistego wykonaną na siatce 3-D za pomocą modelu WSSN. Górna część rysunku przedstawia dwa widoki izometryczne, lewy i prawy, które prezentują trójwymiarowy model badanego obiektu. Kolory i ich natężenie reprezentują różnice w wartościach mierzonych parametrów mających bezpośredni wpływ na rozkład wilgoci. Wyższe wartości na skali kolorów oznaczają wyższy poziom zawilgocenia. Kolor przezroczysty oznacza brak zawilgocenia lub obszary mniej wilgotne w porównaniu z zawilgoconymi. Skala barw po prawej stronie pokazuje zakres wartości od -40 do 40, gdzie kolory od czerwonego do niebieskiego obrazują stopień zawilgocenia. Z uwagi na to, że ETI nie jest metodą pomiaru absolutnych wartości konduktywności, nie można traktować tomogramu jako obrazu przewodnictwa elektrycznego poszczególnych elementów skończonych, którego wartości można odczytać ze skali kolorów. Zamiast tego mamy tu do czynienia z tak zwaną rekonstrukcją różnicową (ang. *difference imaging*), w której za pomocą modelu matematycznego można generować dodatnie, ujemne lub zerowe wartości elementów siatki MES. W tym kontekście im niższe są wartości wygenerowane przez model, nawet ujemne, tym niższa jest konduktywność. Fizycznie konduktywność jest wielkością nieujemną, dlatego wartości elementów siatki FEM na tomogramie są z nią jedynie skorelowane.

Widok z góry, umieszczony poniżej widoków izometrycznych, pokazuje rozkład wilgoci na powierzchni poziomej obiektu. Strona elektrod jest oznaczona, co pomaga w zorientowaniu się w przestrzeni pomiarowej. Dolna część obrazu zawiera trzy widoki: widok z przodu, z prawej i z lewej strony. Widok z przodu przedstawia rozkład wilgoci na przedniej ścianie obiektu, z zaznaczonymi pozycjami elektrod (czarne kropki). Widok z prawej i widok z lewej pokazują obiekt z różnych kątów widzenia, umożliwiając ocenę zmian wilgoci z innych perspektyw.

Pomimo oczywistych zalet, analiza rozkładu wilgoci na podstawie widoków trójwymiarowych może być utrudniona z powodu zasłaniania wokseli położonych głębiej przez nieprzezroczyste woksele położone bliżej powierzchni badanego obiektu. Dlatego analiza obrazów przestrzennych nie powinna być ograniczona do pojedynczego widoku, lecz powinna obejmować wiele widoków. Każdy z tych widoków dostarcza informacji o różnym aspekcie zawilgocenia badanego obiektu, umożliwiając kompleksową analizę rozkładu

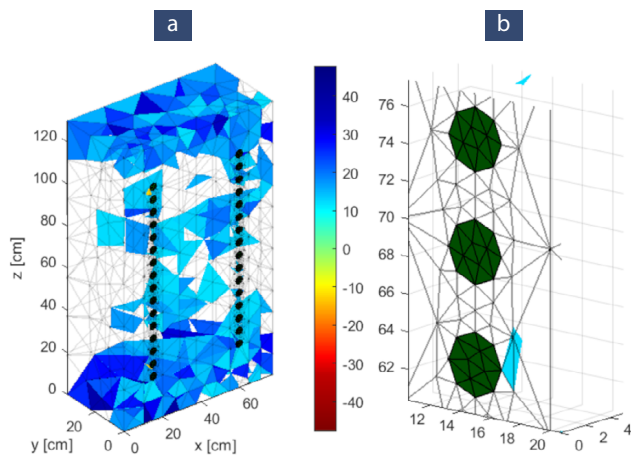
wilgoci wewnątrz muru. Kolorystyka na wszystkich widokach jest skorelowana z wcześniej wspomnianą skalą barw, co pozwala na łatwą interpretację wyników pomiarów.



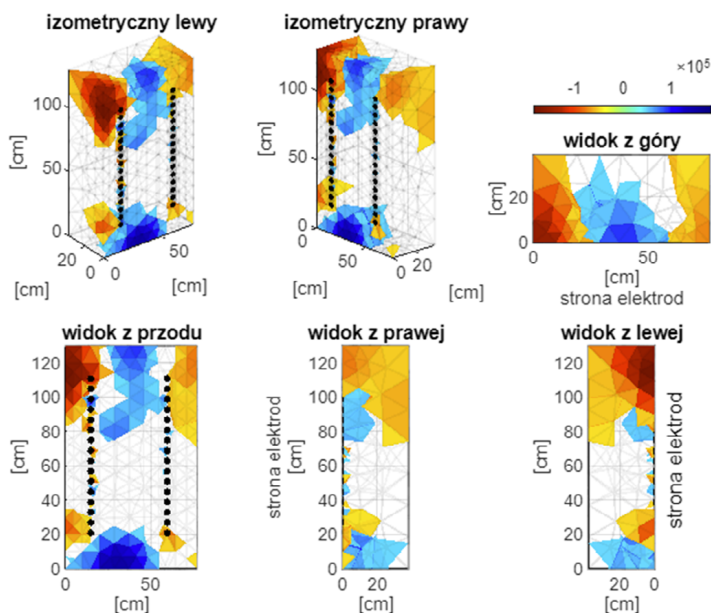
Rys. 5.39. Rekonstrukcja obiektu rzeczywistego wykonana metodą WSSN – różne widoki

Na rysunku 5.40 przedstawiono izometryczną rekonstrukcję rzeczywistą badanego obiektu w powiększeniu oraz duże powiększenie siatki FEM wokół elektrod. Jak widać gęstość siatki FEM nie jest jednorodna. Wokół elektrod, gdzie natężenie pola elektrycznego jest największe, większa jest także ilość wokseli, co przekłada się na ich mniejsze rozmiary. Im dalej od elektrod, tym mniejsze jest natężenie pola elektrycznego, a tym samym rozdzielczość rekonstrukcji spada, rosną wymiary wokseli.

Na rysunkach 5.41–5.50 przedstawiono rekonstrukcje obiektu rzeczywistego wykonane pozostałymi metodami: Gaussa–Newtona, regularyzacji Tikhonova, Total Variation, maszyna wektorów nośnych (SVM), elastic net, regresji liniowej, konwolucyjnej sieci neuronowej (CNN), sieci LSTM, sieci LSTM+CNN oraz sieci wielogałęziowej LSTM. Kolor niebieski na rysunkach oznacza obszary zawilgoczone. Rekonstrukcje różnią się w zależności od zastosowanej metody, co można zauważyć, analizując rozkład wilgoci w obrębie muru. Dla metody Gaussa–Newtona (rys. 5.41) widoczne są wyraźne, ale niejednolite obszary zawilgoczenia.



Rys. 5.40. Rekonstrukcja obiektu rzeczywistego: (a) widok aksonometryczny, (b) siatka FEM wokół elektrod w powiększeniu



Rys. 5.41. Rekonstrukcja obiektu rzeczywistego metodą Gaussa–Newtona – różne widoki

Metoda regularyzacji Tikhonova (rysunek 5.42) charakteryzuje się bardziej rozmytymi granicami obszarów wilgoci od innych metod. Pomimo tego, rekonstrukcja jest czytelna i wiarygodna w kontekście spodziewanych wyników. Metoda rekonstrukcji obrazów tomograficznych ETI oparta na regularyzacji Tikhonova posiada zarówno mocne strony, jak i słabości. Jedną z głównych zalet metody Tikhonova jest jej matematyczna prostota i dobra stabilność,

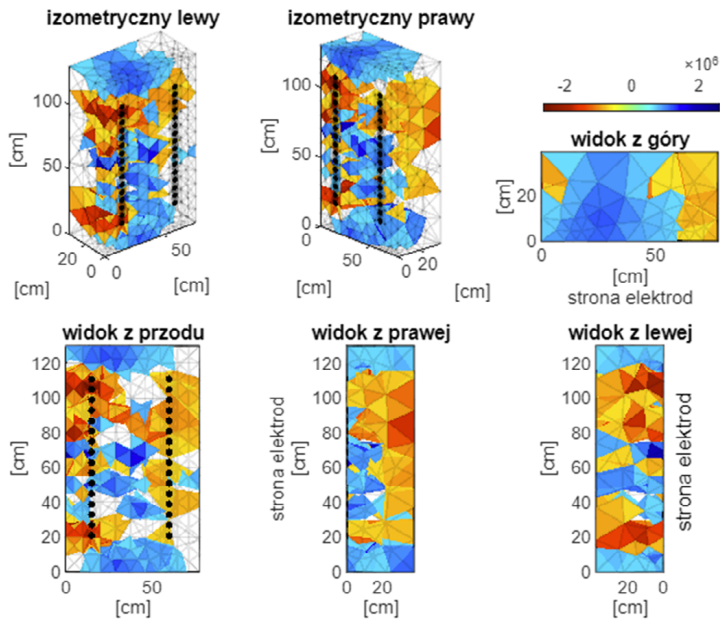
rozumiana jako tolerancja na szum pomiarowy. Formuła regularyzacji Tikhonova wprowadza dodatkowy człon do funkcji kosztu, który penalizuje duże wartości wybranych parametrów. Prowadzi to do uzyskania stabilnych i wygładzonych rozwiązań nawet w przypadku obecności szumu w danych pomiarowych. Jest to szczególnie ważne w kontekście ETI, gdzie dane mogą być obciążone znacznymi błędami, a jakość pomiarów może być obniżona przez zaszumienie.

Kolejną zaletą metody Tikhonova jest jej względna łatwość implementacji i interpretacji. Parametry regularyzacji można intuicyjnie dostosować do specyfiki problemu, co ułatwia kontrolę nad procesem rekonstrukcji. Omawiana metoda jest dobrze ugruntowana w teorii i ma szerokie zastosowanie w różnych dziedzinach nauki i techniki.

Metoda regularyzacji Tikhonova ma także ograniczenia i pewne wady. Jedną z wad jest tendencja modelu do wygładzania ostrych krawędzi. Z tego powodu drobne szczegóły nie są widoczne na zrekonstruowanych obrazach. Wprowadzenie dodatkowego członu regularyzacji sprawia, że obrazy mogą być nadmiernie wygładzone. Może to być powodem utraty istotnych informacji i powstawania zniekształceń strukturalnych. Dzięki zdolności do nieliniowego przetwarzania informacji i ekstrakcji cech, sieci neuronowe, zwłaszcza głębokie i/lub konwolucyjne, mogą lepiej rekonstruować drobne szczegóły i krawędzie.

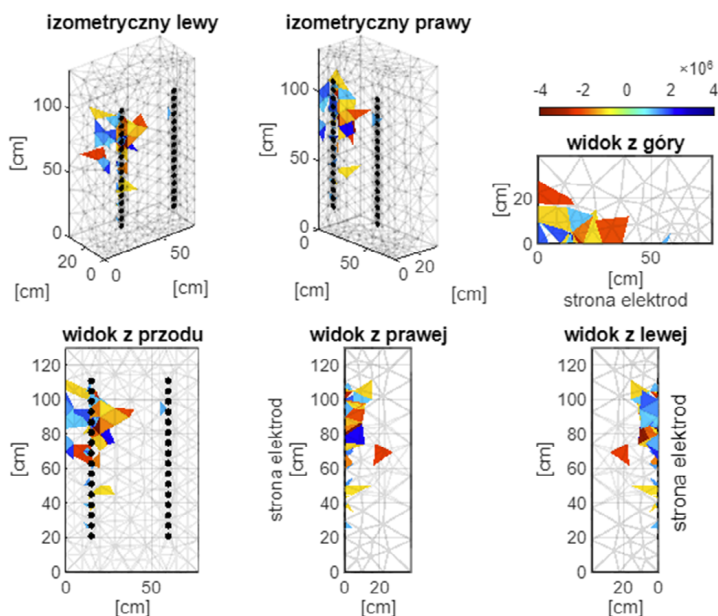
Kolejną wadą metody Tikhonova jest jej ograniczona adaptacyjność do różnych typów danych i zadań rekonstrukcji. Algorytm wymaga ręcznego dostrojenia parametrów regularyzacji, co w przypadku złożonych problemów może być czasochłonne i skomplikowane. Na tym tle wyraźniej rysuje się przewaga sieci neuronowych. Sieci mogą być trenowane na dużych zbiorach danych, co pozwala im automatycznie dostosowywać się do specyficznych uwarunkowań danego problemu i zapewnia większą elastyczność.

Metoda Tikhonova jest również bardziej ograniczona pod względem szybkości obliczeniowej w porównaniu z podejściami opartymi na sieciach neuronowych. Proces iteracyjnego rozwiązywania równań liniowych w metodzie Tikhonova może być czasochłonny, zwłaszcza dla dużych zbiorów danych. Sieci neuronowe, po odpowiednim wytrenowaniu, mogą rekonstruować obrazy znacznie szybciej dzięki efektywnym algorytmom inferencji i wykorzystaniu akceleracji sprzętowej.



Rys. 5.42. Rekonstrukcja obiektu rzeczywistego metodą regularyzacji Tikhonova – różne widoki

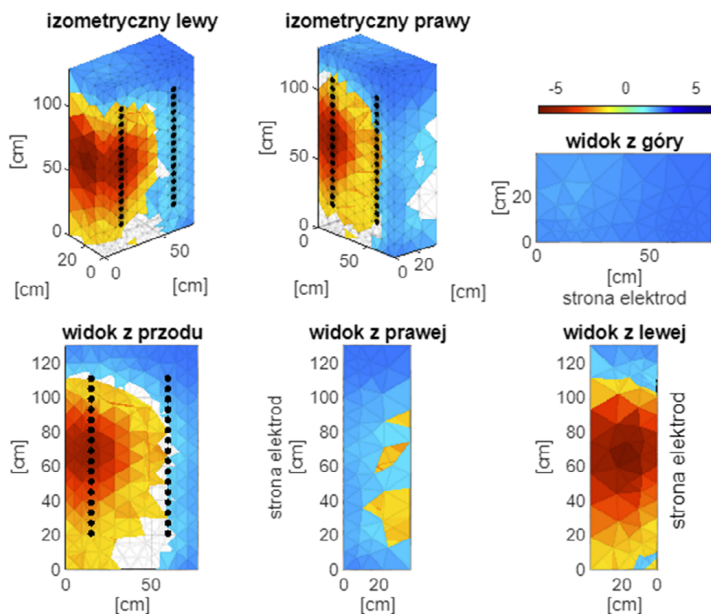
Widoczna na rysunku 5.43 rekonstrukcja metodą Total Variation (TV) charakteryzuje się ostrzejszymi granicami między obszarami wilgotnymi a suchymi, jednak, biorąc pod uwagę uzyskaną rekonstrukcję, należy uznać, że jakość tej metody w badanym przypadku jest nieakceptowalna. Najprawdopodobniej ma to związek z niską zdolnością modelu do generalizacji. Jednym z głównych problemów metody TV jest jej duża wrażliwość na szum obecny w danych pomiarowych. Ponieważ TV minimalizuje gradient obrazu, staje się podatna na zakłócenia. W następstwie metoda może generować artefakty i inne błędy rekonstrukcji, szczególnie w przypadku danych pomiarowych o niskiej jakości. Sieci neuronowe, zwłaszcza nowoczesne struktury głębokie i konwolucyjne, są w stanie lepiej radzić sobie z szumem dzięki zdolności do uczenia się reprezentacji cech bezpośrednio z danych. Pozwala to uzyskiwać bardziej odporne i dokładne rekonstrukcje. Inną słabością metody TV jest jej ograniczona zdolność do identyfikowania złożonych struktur w obrazach. Metoda TV jest skuteczna w wygładzaniu i zachowywaniu ostrych krawędzi. Nie radzi sobie jednak z bardziej skomplikowanymi wzorcami i strukturami, które mogą występować właśnie w obrazach tomograficznych. Sieci neuronowe, dzięki swojej architekturze i zdolności do modelowania nieliniowych zależności, są w stanie lepiej odwzorować skomplikowane struktury przestrzenne i tekstury w danych obrazowych.



Rys. 5.43. Rekonstrukcja obiektu rzeczywistego metodą Total Variation – różne widoki

Metoda TV jest również stosunkowo ograniczona pod względem adaptacyjności do różnych typów danych i zadań rekonstrukcji. Proces regularyzacji oparty na wariacji całkowitej wymaga dobrania odpowiednich parametrów, co jest trudne i czasochłonne. W porównaniu z deterministyczną metodą TV, sieci neuronowe potrafią automatycznie dobierać i optymalizować własne parametry. Wytrenowanie sieci neuronowej o wysokiej jakości i zdolności do generalizacji trwa krócej niż opracowanie efektywnego modelu TV.

Metoda SVM (rysunek 5.44) generuje obrazy z wyraźnie zaznaczonymi i stosunkowo jednorodnymi obszarami wilgoci. Zdolność do skutecznego radzenia sobie z małymi i średnimi zbiorami danych jest jedną z głównych zalet metody SVM. Jest to szczególnie ważne w przypadku ograniczonej ilości dostępnych danych uczących. Funkcje jądrowe umożliwiają SVM znalezienie optymalnej granicy decyzyjnej między różnymi klasami. Tak więc metoda SVM pozwala na modelowanie nieliniowych zależności w danych. Ponadto ma solidną teoretyczną podstawę i silne podstawy matematyczne, co ułatwia zrozumienie i interpretację wyników modelu. Regularyzacja SVM jest korzystna dla zapewnienia stabilności i generalizacji wyników, ponieważ pomaga kontrolować złożoność modelu i unikać zjawiska przeuczenia.



Rys. 5.44. Rekonstrukcja obiektu rzeczywistego wykonana metodą SVM – różne widoki

Metoda SVM ma również ograniczenia. Jednym z głównych problemów jest jej skalowalność. Przy dużych zbiorach danych i wysokowymiarowych przestrzeniach cech, trenowanie modelu SVM może być bardzo czasochłonne i może wymagać dużych zasobów obliczeniowych. W przeciwieństwie do nowoczesnych modeli sieci neuronowych, które mogą być efektywnie trenowane równoległe przy użyciu kart graficznych GPU (ang. *graphics processing unit*), wielordzeniowych CPU (ang. *central processing unit*) oraz TPU (ang. *tensor processing unit*), metoda SVM często staje się niewydajna w takich warunkach.

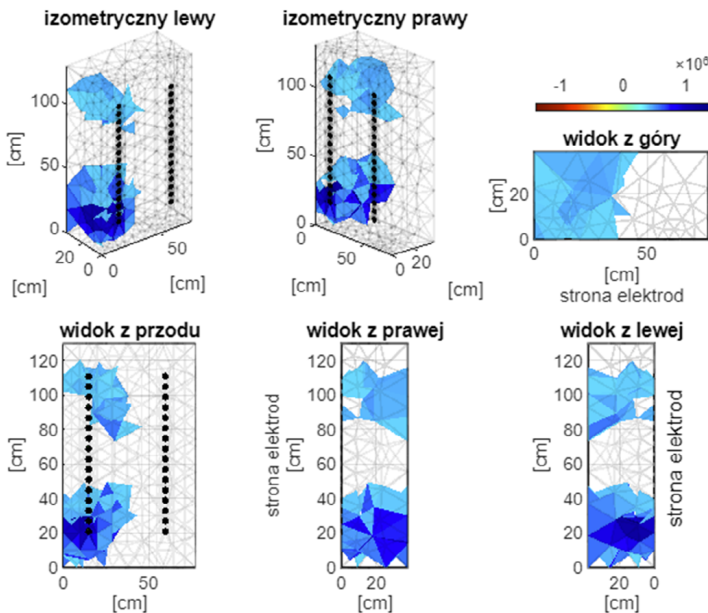
Kolejną słabością metody SVM jest jej ograniczona zdolność do automatycznej ekstrakcji cech z surowych danych. W przeciwieństwie do sieci neuronowych, zwłaszcza posiadających warstwy konwolucyjne i LSTM, które potrafią automatycznie uczyć się złożonych reprezentacji cech z danych surowych, SVM często wymaga ręcznej inżynierii cech, co może być czasochłonne i wymaga specjalistycznej wiedzy.

Rysunek 5.45 przedstawia różne widoki rekonstrukcji ETI uzyskanej z wykorzystaniem metody elastic net. Konfrontacja tomogramów z przewidywaniami wynikającymi z kontrolowanego w warunkach laboratoryjnych procesu zawilgacania muru nie pozwala uznać tej metody za dokładną. Zawilgocenia znajdują się wprawdzie w górnej i dolnej części badanego fragmentu, jednak

lokują się niesymetrycznie, po lewej stronie, co jest niezrozumiałe, mało wiarygodne i trudne do wyjaśnienia.

Zdolność do łączenia zalet regularyzacji L1 (Lasso) i regularyzacji L2 (grzbietowej) jest jedną z głównych zalet metody elastic net. Dzięki tej funkcjonalności metoda elastic net jest skuteczna w procesie selekcji cech i skutecznie rozwiązuje problem kolinearności danych. W rezultacie można osiągnąć bardziej stabilne i interpretowalne modele nadające się do rekonstrukcji obrazów tomograficznych. Ponadto metoda elastic net jest atrakcyjna dla wielu zastosowań w dziedzinie obrazowania medycznego ze względu na jej solidną, teoretyczną podstawę i stosunkowo prostą implementację.

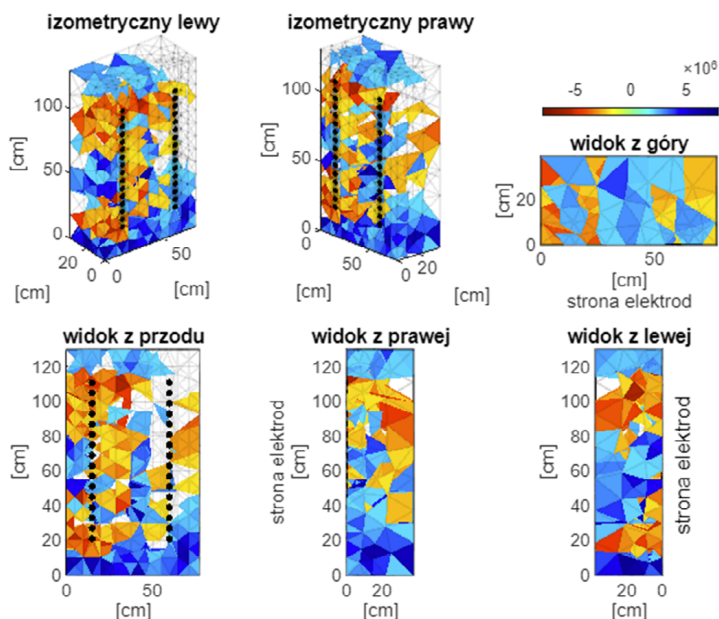
Podobnie jak inne metody, elastic net ma również ograniczenia. Jednym z głównych problemów jest słaba zdolność do modelowania nieliniowych i złożonych zależności w danych. Podczas gdy elastic net może efektywnie radzić sobie z liniowymi zależnościami i redukcją wymiarowości, możliwości tej metody są ograniczone w kontekście złożonych wzorców i struktur, które często występują w danych tomograficznych. W przeciwieństwie do elastic net, nowoczesne modele sieci neuronowych, takie jak konwolucyjne sieci neuronowe (CNN), są zaprojektowane z myślą o automatycznym wykrywaniu i modelowaniu skomplikowanych zależności nieliniowych, co czyni je bardziej efektywnymi w rekonstrukcji obrazów o wysokiej złożoności.



Rys. 5.45. Rekonstrukcja obiektu rzeczywistego wykonana metodą elastic net – różne widoki

Słabą stroną metody elastic net jest także jej podatność na dobór parametrów regularyzacji. Aby osiągnąć najlepsze wyniki, konieczne jest optymalne dostosowanie parametrów L1 i L2, co jest wyzwaniem. Sieci neuronowe, choć również wymagają dostrajania hiperparametrów, oferują narzędzia takie jak uczenie transferowe (ang. transfer learning) i zaawansowane algorytmy optymalizacji, które automatycznie dostosowują trenowane modele do specyfiki danych, co najczęściej prowadzi do lepszych wyników w zastosowaniach utylitarnych.

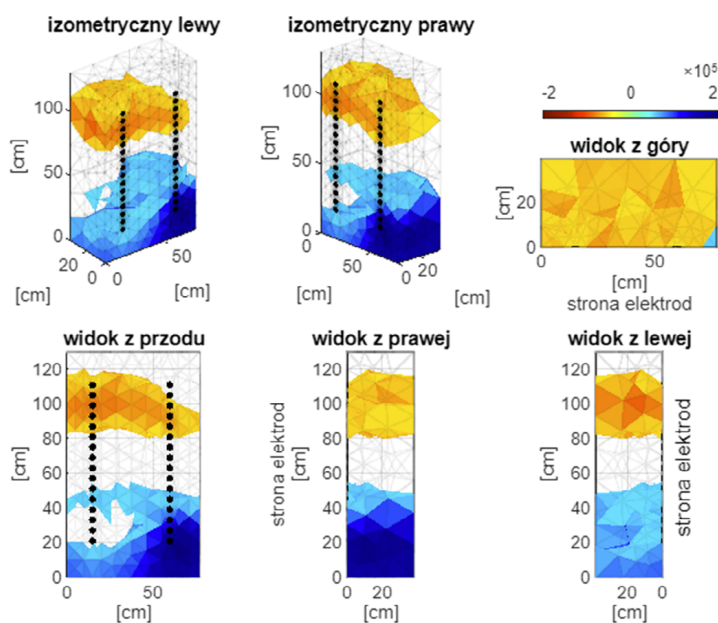
Rekonstrukcja uzyskana za pomocą regresji liniowej widoczna na rysunku 5.46 jest prawie nieczytelna. Główną słabością tej metody jest jej zdolność do modelowania tylko liniowych zależności między zmiennymi. W kontekście rekonstrukcji obrazów tomograficznych, gdzie dane często zawierają złożone i nieliniowe wzorce, regresja liniowa nie jest wystarczająca do uzyskania dokładnych i wiarygodnych rekonstrukcji. Innym problemem regresji liniowej jest jej ograniczona zdolność do radzenia sobie z dużymi zbiorami danych i wysoką wymiarowością. Chociaż model jest obliczeniowo efektywny dla małych i średnich zbiorów danych, jego wydajność może się pogorszyć w przypadku bardzo dużych zbiorów danych. Opracowując model elastic net, należy więc spodziewać się problemów ze skalowalnością. Sieci neuronowe, dzięki swojej architekturze i możliwościom wykorzystania obliczeń równoległych na jednostkach CPU, GPU i TPU, mogą przetwarzać ogromne ilości danych znacznie szybciej i efektywniej.



Rys. 5.46. Rekonstrukcja obiektu rzeczywistego metodą regresji liniowej – różne widoki

Regresja liniowa ma również ograniczenia w zakresie automatycznej ekstrakcji cech z surowych danych. Wymaga to ręcznej inżynierii cech, która może być żmudna i czasochłonna. Nowoczesne struktury sieci neuronowych posiadają zdolność do automatycznej ekstrakcji cech, co eliminuje potrzebę ręcznego przetwarzania danych i pozwala na bardziej wszechstronne i adaptacyjne podejście do rekonstrukcji obrazów.

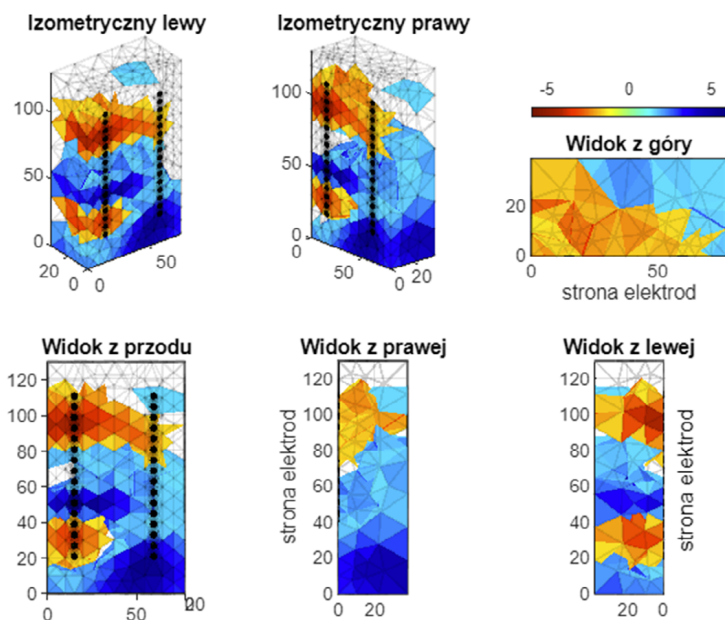
Zaprezentowana na rysunku 5.47 rekonstrukcja wygenerowana za pomocą metody CNN wskazuje na obszary zawilgocone, które są zlokalizowane w dolnej części muru. Górne partie badanego obiektu, według wskazań rekonstrukcji, są suche. Nie jest to prawdą, choć porównując zawilgoconie górnej i dolnej części fragmentu ściany, z pewnością dolna część zawiera więcej wody. Obraz rekonstrukcyjny został kolorystycznie skalibrowany w sposób zakładający binarność, która polega na zidentyfikowaniu jako wilgotny jedynie obszaru najbardziej nasyconego wodą spośród wszystkich wokseli siatki FEM. Model pomija zróżnicowane, pośrednie poziomy wilgoci, poza ekstremalnymi.



Rys. 5.47. Rekonstrukcja obiektu rzeczywistego wykonana metodą CNN – różne widoki

Sieć LSTM, z której rekonstrukcja jest widoczna na rysunku 5.48, daje wyniki z dość wyrafinowanymi wzorcami wilgoci, które lepiej oddają rzeczywiste rozkłady zawilgoconia, niż ma to miejsce w przypadku sieci CNN. Wilgoć sięga tu znacznie wyżej niż na rysunku 5.46. Prócz tego, rozkład zawilgoceń

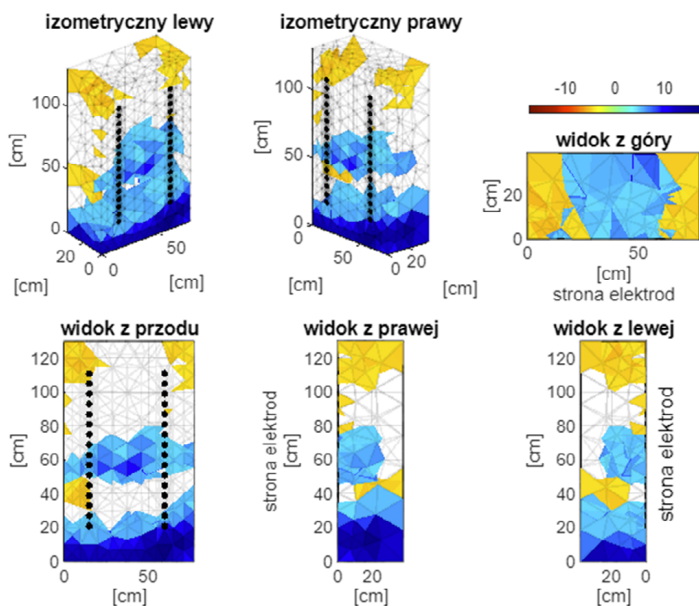
jest bardziej zgodny z logiką i subiektywnym prognozowaniem rozkładu wilgoci wynikającym ze sposobu sztucznego zawilgocenia zrealizowanego w warunkach laboratoryjnych.



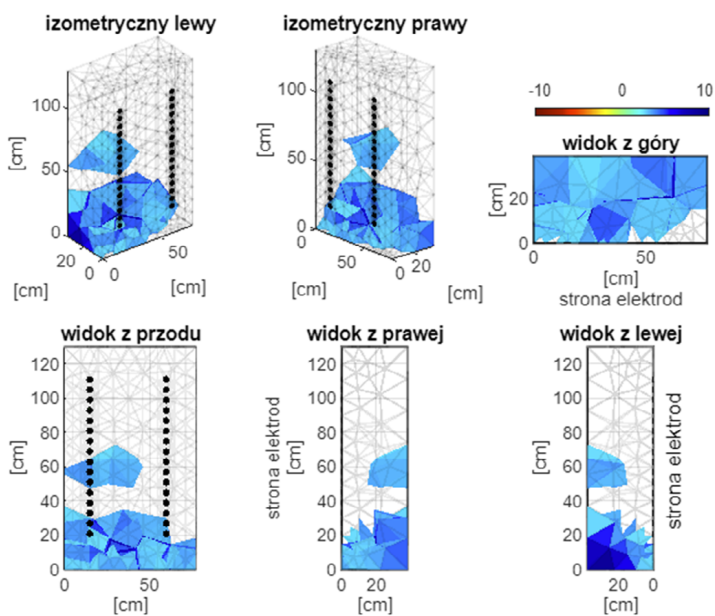
Rys. 5.48. Rekonstrukcja obiektu rzeczywistego wykonana metodą LSTM – różne widoki

Przedstawione na rysunku 5.49 rekonstrukcje, wykonane za pomocą hybrydowej sieci neuronowej zawierającej zarówno warstwy LSTM, jak i CNN, wskazują, że miejsca gromadzenia się wilgoci wewnątrz badanego muru są zlokalizowane głównie w jego dolnej części. Ma to swoje uzasadnienie, ponieważ u dołu muru wciąż znajdowała się woda, podczas gdy w górnym zbiorniku wody już nie było, jednak obraz uzyskany jedynie przy użyciu warstw LSTM wydaje się wierniejszy.

Z dużą dozą pewności można prognozować, że dolne obszary muru zawierają więcej wilgoci niż górne. Ponieważ obraz tomograficzny przedstawia różnice w stopniu zawilgocenia między różnymi obszarami muru, istotna staje się tzw. kalibracja kolorów. Prócz oczywistych czynników mających wpływ na dokładność obrazowania, jak choćby czułość urządzenia, od kalibracji kolorów zależy szczegółowość odzwierciedlania niewielkich różnic konduktywności w poszczególnych elementach skończonych siatki FEM. Kalibracja jest więc kompromisem pomiędzy potrzebą identyfikacji maksymalnej liczby poziomów zawilgocenia a czytelnością obrazu tomograficznego.



Rys. 5.49. Rekonstrukcja obiektu rzeczywistego wykonana metodą LSTM+CNN – różne widoki



Rys. 5.50. Rekonstrukcja obiektu rzeczywistego wykonana metodą wielogłęziową LSTM – różne widoki

Metoda wielogałęziowa LSTM (rysunek 5.50 prezentuje najbardziej zaawansowaną rekonstrukcję, z dobrze zdefiniowanymi obszarami zawilgocenia, co może wskazywać na jej wyższą skuteczność w porównaniu z innymi metodami.

Porównując powyższe rekonstrukcje z obrazami wygenerowanymi metodą WSSN, można zauważyć, że metoda WSSN również pokazuje wyraźne obszary zawilgocenia w murze.


Uwzględniając przewidywania wynikające ze sposobu sztucznego zawilgocenia muru, należy stwierdzić, że rekonstrukcje o najwyższym poziomie wierności uzyskano metodami WSSN i wielogałęziową LSTM. Mur był poddany intensywnemu zawilgoceniu poprzez kontakt z wodą u jego podstawy oraz poprzez dodatkowy zbiornik z wodą umieszczony na górze. Takie warunki eksperymentalne pozwoliły na dość dokładną predykcję obszarów zawilgoconych, co jest wyraźnie widoczne w wynikach uzyskanych wspomnianymi metodami. W porównaniu z innymi technikami, metody WSSN i wielogałęziowa LSTM wykazały się największą precyzją w identyfikacji obszarów zawilgoconych, co świadczy o ich zaawansowanej zdolności do modelowania rzeczywistych warunków zawilgocenia muru. Niniejsze obserwacje potwierdzają wysoką jakość tych metod wynikającą z uprzedniej analizy przeprowadzonej w oparciu o dane syntetyczne.

6. Badania wilgotności murów Złotej Bramy w Gdańsku

W celu weryfikacji prototypowego systemu elektrycznej tomografii impedancyjnej, złożonego z tomografu ETI oraz algorytmów opartych na uczeniu maszynowym, transformujących pomiary elektryczne na obrazy, przeprowadzono badania murów Złotej Bramy w Gdańsku. Złota Brama, znana również jako Brama Długouliczna, jest budowlą historyczną, która w świetle obowiązujących przepisów prawnych jest wpisana do rejestru zabytków, co świadczy o jej istotnym znaczeniu historycznym i kulturowym. Budowla ta, będąca jednym z kluczowych elementów miejskiej architektury Gdańska, ma długą i bogatą historię sięgającą XVII wieku. Brama została wybudowana w latach 1612–1614 według projektu Abrahama van den Blockego, a jej fundatorem było Bractwo św. Jerzego. Jest to konstrukcja o charakterze historycznym, której celem było podkreślenie prestiżu i zamożności Gdańska w okresie jego największego rozkwitu. Struktura murów Złotej Bramy jest solidna i masywna, z niektórymi fragmentami osiagającymi grubość zbliżoną do 2 metrów. Mury zostały wykonane z cegły ceramicznej, co było typowym materiałem budowlanym w tamtym czasie. Cegły są pokryte warstwą tynku, który nadaje budowli jej charakterystyczny wygląd. Ponadto fasady bramy są bogato zdobione rzeźbami i dekoracjami, które determinują jej znaczenie historyczne i stanowią przykład doskonałego rzemiosła artystycznego tamtej epoki.


W związku z wiekiem budowli oraz jej znaczeniem historycznym szczególnie istotne jest regularne monitorowanie stanu technicznego Złotej Bramy.

Jednym z kluczowych zagrożeń dla tego typu konstrukcji jest zawilgocenie murów, które może prowadzić do ich osłabienia, pęknięć oraz rozwoju pleśni i grzybów [40]. Zaniedbania w tej dziedzinie mogą skutkować trwałym uszkodzeniem struktury murów, elewacji, cennych rzeźb oraz dekoracji. Aby zidentyfikować i ocenić zakres zawilgocenia, Złota Brama została poddana badaniom tomograficznym przy użyciu tomografu ETI (elektryczna tomografia impedancyjna). Jak już wielokrotnie wspomniano, tomografia umożliwia nieinwazyjne badanie struktury murów, co jest szczególnie ważne w przypadku zabytków, gdzie minimalizacja ingerencji w oryginalną strukturę jest kluczowa. Badania miały na celu nie tylko ocenę obecnego stanu zawilgocenia, ale również dostarczenie danych do opracowania skutecznych strategii konserwacji i ochrony zabytku. Regularne badania stopnia zawilgocenia murów przyczyniają się do długotrwałego zachowania Złotej Bramy w dobrym stanie i jej przetrwania dla przyszłych pokoleń. Rysunek 6.1 przedstawia widoki Złotej Bramy w Gdańsku od strony Targu Węglowego i od ul. Długiej.



Rys. 6.1. Złota Brama w Gdańsku: (a) widok od strony Targu Węglowego, (b) widok od ul. Długiej

Fot. (a) Maciej Szczepańczyk, <https://commons.wikimedia.org/w/index.php?curid=3417027>, (b) Anna Hoła



Rys. 6.2. Rzut przyziemia Złotej Bramy z zaznaczonymi miejscami wykonania pomiarów
Opracowanie własne na podstawie [66]

Rysunek 6.2 przedstawia przyziemie Złotej Bramy z zaznaczonymi trzema stanowiskami wykonania pomiarów. Przykładowo czerwona kropka z opisem 1P oznacza miejsce przyłożenia do ściany prawej listwy zawierającej 16 elektrod. Analogicznie 1L i niebieska kropka oznaczają miejsce przyłożenia listwy lewej. Stosując powyższą analogię do pozostałych miejsc pomiarów, czerwony kolor kropek przypisano do listwy prawej, natomiast kolor niebieski oznacza listwę lewą. Warto zwrócić uwagę, że grubość murów mierzona prostopadle do osi listw z elektrodami ETI wynosi dla stanowiska pierwszego 150 cm, dla stanowiska drugiego 38 cm dla listwy prawej i 165 cm dla listwy lewej oraz aż 195 cm dla stanowiska trzeciego.

6.1. Modelowanie wielogłęziowej sieci neuronowej LSTM+CNN

W celu uzyskania obrazu tomograficznego o dużej rozdzielczości zastosowano przestrzenną siatkę FEM składającą się z 11 458 elementów skończonych (wokseli). W badaniach wykorzystano opisany w rozdziale 5.5. protokół pomiarowy wraz z zestawem 32 elektrod. Algorytm 6.1 przedstawia kod zapisany

w języku Matlab, który tworzy model trójgałęzistej sieci neuronowej zawierającej warstwę LSTM i CNN.

Algorytm 6.1. Matlab R2024a – kodowanie architektury modelu wielogałęzistej sieci neuronowej LSTM+CNN

```
inputSize = 448; % definiowanie wielkości wektora wejściowego
numResponses = 11458; % definiowanie wielkości wektora wyjściowego

% Utworzenie pustego obiektu net z wykorzystaniem funkcji dlnetwork
net = dlnetwork;

% Dodawanie poszczególnych warstw sieci do obiektu net...
% ...z wykorzystaniem zmiennej tymczasowej tempNet
tempNet = sequenceInputLayer(inputSize,"Name","sequence", ...
    "Normalization","zerocenter","SplitComplexInputs", true);
net = addLayers(net,tempNet);

tempNet = [
    bilstmLayer(1024,"Name","bilstm_1","OutputMode","last")
    batchNormalizationLayer("Name","batchnorm_1")
    dropoutLayer(0.5,"Name","dropout_1")];
net = addLayers(net,tempNet);

tempNet = [
    fullyConnectedLayer(256,"Name","fc_1")
    tanhLayer("Name","tanh_1")
    batchNormalizationLayer("Name","batchnorm_2")
    dropoutLayer(0.5,"Name","dropout_2")];
net = addLayers(net,tempNet);

tempNet = [
    fullyConnectedLayer(256,"Name","fc_2")
    tanhLayer("Name","tanh_2")
    batchNormalizationLayer("Name","batchnorm_3")
    dropoutLayer(0.5,"Name","dropout_3")];
net = addLayers(net,tempNet);

tempNet = [
    fullyConnectedLayer(256,"Name","fc_3")
    tanhLayer("Name","tanh_3")
    batchNormalizationLayer("Name","batchnorm_4")
    dropoutLayer(0.5,"Name","dropout_4")];
net = addLayers(net,tempNet);
```

Algorytm 6.1. Matlab R2024a – kodowanie architektury modelu wielogałęziowej sieci neuronowej LSTM+CNN


```
tempNet = [  
    convolution1dLayer(4,112,"Name","conv1d_1","Padding",[4 4])  
    batchNormalizationLayer("Name","batchnorm_1_1")  
    reluLayer("Name","relu_1")  
    dropoutLayer(0.3,"Name","dropout_5")  
    convolution1dLayer(4,112,"Name","conv1d_2","Padding",[4 4])  
    batchNormalizationLayer("Name","batchnorm_1_2")  
    reluLayer("Name","relu_2")  
    dropoutLayer(0.3,"Name","dropout_6")  
    convolution1dLayer(4,112,"Name","conv1d_3","Padding",[4 4])  
    batchNormalizationLayer("Name","batchnorm_1_3")  
    reluLayer("Name","relu_3")  
    dropoutLayer(0.3,"Name","dropout_7")  
    globalMaxPooling1dLayer("Name","gmpool1d")  
    fullyConnectedLayer(512,"Name","fc_4")];  
net = addLayers(net,tempNet);  
  
tempNet = [  
    concatenationLayer(1,4,"Name","concat")  
    bilstmLayer(1280,"Name","bilstm")  
  
    batchNormalizationLayer("Name","batchnorm_5")  
    fullyConnectedLayer(numResponses,"Name","fc_5")];  
net = addLayers(net,tempNet);  
  
clear tempNet; % usunięcie zmiennej tymczasowej  
  
% Połączenie wszystkich gałęzi sieci w jedną strukturę net  
net = connectLayers(net,"sequence","bilstm_1");  
net = connectLayers(net,"sequence","conv1d_1");  
net = connectLayers(net,"dropout_1","fc_1");  
net = connectLayers(net,"dropout_1","fc_2");  
net = connectLayers(net,"dropout_1","fc_3");  
net = connectLayers(net,"dropout_2","concat/in1");  
net = connectLayers(net,"dropout_3","concat/in2");  
net = connectLayers(net,"dropout_4","concat/in3");  
net = connectLayers(net,"fc_4","concat/in4");  
  
net = initialize(net); % inicjalizacja sieci net
```

Powyższy kod tworzy strukturę wielogałęziowej sieci neuronowej, która łączy warstwy LSTM oraz konwolucyjne. Na wstępie definiowane są wymiary wektorów wejściowego (`inputSize = 448`) oraz wyjściowego (`numResponses = 11458`). Następnie tworzona jest zmienna *dlnetwork* o nazwie *net*, która będzie zawierać warstwy sieci. Pierwszą dodaną warstwą jest warstwa wejściowa `sequenceInputLayer`, która przetwarza sekwencyjne dane wejściowe o wymiarze wektora 448-elementowego. Dane, o których mowa, są poddane procesowi normalizacji. W dalszych krokach algorytm dodaje kolejne warstwy sieci. Pierwsza warstwa to dwukierunkowa warstwa LSTM (BiLSTM) z 1024 jednostkami ukrytymi, która jest odpowiedzialna za dwukierunkową analizę danych sekwencyjnych. Zastosowanie tej warstwy ma na celu identyfikację zależności ukrytych między elementami wektorów pomiarowych, czyli między pojedynczymi pomiarami wchodzącymi w skład sekwencji pomiarowej. Po niej kolejną warstwą jest normalizacja wsadowa (Batch Normalization), która stabilizuje i przyspiesza uczenie się, oraz warstwa Dropout, która redukuje ryzyko przetrenowania sieci poprzez losowe wyłączenie neuronów z sieci. Kolejne trzy bloki to warstwy w pełni połączone (Fully Connected) z 256 neuronami, z funkcjami aktywacji tangens hiperboliczny, normalizacją wsadową oraz warstwami Dropout. Te warstwy są odpowiedzialne za transformację i obróbkę danych z wyższych poziomów abstrakcji.

Po warstwach w pełni połączonych dodawane są jednowymiarowe (wektorowe) warstwy konwolucyjne 1D, które przetwarzają sekwencje danych, wychwytyjąc lokalne wzorce w sekwencjach. Każda warstwa konwolucyjna składa się z filtrów o rozmiarze 4 i głębokości 112, z normalizacją wsadową, funkcją aktywacji ReLU oraz warstwą Dropout. Na końcu grupy warstw znajduje się globalna warstwa typu „max pooling” (Global Max Pooling), która redukuje wymiary danych. Zwieńczeniem tej grupy jest warstwa w pełni połączona z 512 neuronami.

Centralnym elementem omawianej sieci wielogałęziowej jest warstwa `concatenationLayer`, która łączy wyjścia z różnych gałęzi sieci wzdłuż pierwszego wymiaru. Istnieją dwa główne sposoby łączenia warstw – „concatenation” (łączenie) i „add” (dodawanie). Warstwa typu *concatenation* różni się od warstwy *add* tym, że zamiast sumowania wartości wyjściowych z różnych warstw, konkatenacja łączy je, tworząc jeden dłuższy wektor. To umożliwia przekazanie bardziej złożonych i bogatszych informacji do dalszych warstw. Po połączeniu danych za pomocą warstwy *concatenate*, informacje trafiają do kolejnej dwukierunkowej warstwy LSTM z 1280 jednostkami ukrytymi. Dane przechodzą przez normalizację wsadową oraz warstwę w pełni połączoną z liczbą neuronów równą liczbie odpowiedzi (`numResponses`) i jednocześnie

rozdzielczości siatki FEM, czyli 11458. Na końcu kodu wszystkie gałęzie są połączone w jedną wspólną strukturę za pomocą funkcji connectLayers, po czym sieć jest inicjalizowana. Tak zaprojektowana sieć jest gotowa do trenowania na danych sekwencyjnych, wykorzystując zalety zarówno warstw LSTM, jak i warstw konwolucyjnych. Złożona architektura sieci ma na celu ułatwienie analizy i identyfikacji złożonych wzorców ukrytych wewnątrz wektorowych struktur danych.



Rys. 6.3. Struktura wielogałęziowej sieci neuronowej LSTM+CNN

Rysunek 6.3 przedstawia schemat struktury wielogałęziowej sieci neuronowej LSTM+CNN opisanej algorytmem 6.1. Tego typu sieć neuronowa o skomplikowanej, wielogałęziowej architekturze ma wiele potencjalnych zalet, które mogą przyczynić się do lepszej wydajności podczas realizacji zadań związanych z przetwarzaniem danych sekwencyjnych i szeregów czasowych. Wielogałęziowa architektura pozwala na równoczesne przetwarzanie danych przez różne typy warstw, takich jak warstwy LSTM, konwolucyjne oraz w pełni połączone. Każda z gałęzi sieci może identyfikować inne aspekty danych wejściowych, co pozwala jej skuteczniej identyfikować złożone wzorce i zależności ukryte w danych. Integracja warstw konwolucyjnych i LSTM umożliwia synergiczne wykorzystanie mocnych stron obu typów warstw. Warstwy LSTM są skuteczne w modelowaniu zależności czasowych i sekwencyjnych, podczas gdy warstwy konwolucyjne potrafią efektywnie wykrywać

lokalne wzorce i cechy w danych sekwencyjnych. Wykorzystanie warstw typu Dropout w różnych miejscach struktury modelu zmniejsza ryzyko przetrenowania, co jest kluczowe dla uzyskania systemu, który dobrze generalizuje zarówno dane testowe, jak i nowe, nieznanne dane. Warstwy normalizacji wsadowej przyczyniają się do stabilizacji procesu uczenia, przyspieszając konwergencję i poprawiając wydajność sieci.

Normalizacja pozwala na utrzymanie danych w odpowiednim zakresie, co zmniejsza ryzyko problemów związanych z zanikającym gradientem [101]. Wielogałęziowa struktura umożliwia łatwiejszą modyfikację i skalowanie sieci. Można dodawać lub usuwać gałęzie w zależności od potrzeb konkretnego zadania, co daje dużą elastyczność w projektowaniu sieci. Warstwa konkatenacji umożliwia połączenie informacji z różnych gałęzi, zachowując bogactwo cech wyekstrahowanych przez każdą z nich. Dzięki temu końcowe warstwy sieci mogą operować na bardziej złożonym i wszechstronnym zbiorze cech, co zwykle prowadzi do dokładniejszych przewidywań. Dwukierunkowe warstwy LSTM (BiLSTM) mogą efektywnie identyfikować odległe zależności w danych wektorowych. Warstwy BiLSTM analizują sekwencje zarówno w przód, jak i w tył. Jest to szczególnie ważne w zadaniach, gdzie do poprawnego zrozumienia danych istotny jest kontekst całej sekwencji, a nie tylko jej fragment.

Warstwa globalnego max-pooling oraz warstwy w pełni połączone pomagają w redukcji wymiarowości danych, jednocześnie koncentrując się na najważniejszych cechach. Zwiększa to efektywność obliczeniową i redukuje złożoność obliczeniową modelu. Tego rodzaju architektura sieci neuronowej jest szczególnie przydatna w trudnych zadaniach transformacji danych, takich jak tomograficzne problemy odwrotne, analizy sekwencji czasowych, rozpoznawanie wzorców, predykcja szeregów czasowych oraz w zadaniach związanych z przetwarzaniem języka naturalnego (NLP – ang. *natural language processing*). Złożoność i multimodalność tej struktury umożliwiają lepsze modelowanie skomplikowanych zjawisk i uzyskiwanie bardziej precyzyjnych wyników.

W tabeli 6.1 przedstawiono uzupełniające informacje na temat poszczególnych warstw wielogałęziowej sieci neuronowej LSTM+CNN, łączącej warstwy LSTM i konwolucyjne. Tabela jest podzielona na trzy kolumny: „Nazwa i opis warstwy”, „Aktywacje” oraz „Parametry uczące się”. Każda z kolumn pełni określoną rolę, a oznaczenia (C), (B) i (T) w kolumnie „Aktywacje” odnoszą się do poszczególnych wymiarów danych przetwarzanych przez sieć neuronową. Kolumna „Nazwa i opis warstwy” zawiera nazwy oraz opisy poszczególnych warstw sieci neuronowej. Warstwy te obejmują różne typy, takie jak warstwy wejściowe, dwukierunkowe LSTM, warstwy normalizacji wsadowej, warstwy

dropout, warstwy w pełni połączone, warstwy aktywacyjne, warstwy konwo-lucyjne, globalne warstwy max-pooling oraz warstwy konkatencji. Każda z wymienionych warstw pełni specyficzną rolę w przetwarzaniu danych wejściowych i ekstrakcji cech.

Kolumna „Aktywacje” tabeli 6.1 opisuje rozmiary aktywacji dla każdej warstwy w sieci. Litera (C), (B) i (T) oznaczają odpowiednio kanały (Channels), partie danych (Batch) oraz czas (Time). Na przykład zapis $896(C) \times 1(B) \times 1(T)$ oznacza, że dana warstwa przetwarza 896 kanałów, jedną partię danych oraz jeden krok czasowy. Podobnie zapis $2048(C) \times 1(B)$ oznacza, że warstwa przetwarza 2048 kanałów i jedną partię danych, bez specyfikacji kroku czasowego. Te oznaczenia pomagają zrozumieć sposób, w jaki dane są przekształcane i przepływają przez sieć.

Kolumna „Parametry uczące się” zawiera informacje o liczbie i typach parametrów, które są aktualizowane podczas procesu uczenia sieci (ang. *learnables*). Parametry te obejmują wagi wejściowe, wagi rekurencyjne, biasy, offsety oraz skale. Offsety i skale są parametrami stosowanymi w warstwach normalizacji wsadowej (Batch Normalization). Odgrywają one istotną rolę w stabilizacji i przyspieszaniu procesu uczenia się sieci neuronowych. Skala (ang. *scale*) jest parametrem uczącym się, przez który mnożone są znormalizowane wartości aktywacji. W połączeniu z offsetem skala umożliwia sieci neuronowej adaptację znormalizowanych aktywacji do różnych zakresów wartości, które mogą być bardziej optymalne dla danej warstwy lub problemu.

Z tabeli 6.1 wynika, że dla warstwy `bilstm_1`, parametry uczące się obejmują wagi wejściowe o wymiarach 8192×896 , wagi rekurencyjne o wymiarach 8192×1024 oraz biasy o wymiarach 8192×1 . W przypadku wag wejściowych liczba 896 odpowiada rozmiarowi wektora wejściowego dla tej warstwy. W BiLSTM każda jednostka LSTM posiada zestaw wag, które są stosowane do wejścia. Ponieważ są 1024 jednostki w każdym kierunku (do przodu i do tyłu), a każda jednostka LSTM ma cztery zestawy wag (dla bramki wejściowej, zapominania, wyjściowej oraz wewnętrznego stanu pamięci), liczba wag wynosi $4 \times 1024 \times 2 = 8192$. Stąd wymiar wag wejściowych wynosi 8192×896 .

Wymiary wag rekurencyjnych to 8192×1024 . W warstwie LSTM wagi rekurencyjne są stosowane do poprzedniego stanu ukrytego (hidden state). Każda jednostka LSTM ma również cztery zestawy wag rekurencyjnych, a ponieważ w omawianym przypadku są 1024 jednostki LSTM w każdym kierunku, liczba wag rekurencyjnych również wynosi $4 \times 1024 \times 2 = 8192$. Wymiar wag rekurencyjnych wynosi zatem 8192×1024 , gdzie 1024 to rozmiar wektora stanu ukrytego.

Ostatnim podanym parametrem uczącym się dla warstwy `bilstm_1` są biasy o wymiarach 8192×1 . Biasy są dodatkowymi parametrami, które pozwalają modelowi na lepsze dopasowanie funkcji aktywacji do danych. W warstwie typu BiLSTM każda jednostka posiada zestaw biasów odpowiedni dla bramki wejściowej, bramki zapominania, bramki wyjściowej oraz stanu pamięci, co daje $4 \times 1024 \times 2 = 8192$, dlatego wymiar biasów wynosi 8192×1 . Powyższe parametry są kluczowe dla dostosowania sieci do danych uczących i optymalizacji jej wydajności.

Tabela. 6.1. Szczegółowe informacje o strukturze wielogłęziowej sieci neuronowej LSTM+CNN

Nazwa i opis warstwy	Aktywacje	Parametry uczące się
<i>sequence</i> Sekwencja wejściowa, 448 wymiarów	$896(C) \times 1(B) \times 1(T)$	—
<i>bilstm_1</i> BiLSTM z 1024 jednostkami ukrytymi	$2048(C) \times 1(B)$	Wagi wejściowe: 8192×896 Wagi rekurencyjne: 8192×1024 Biasy: 8192×1
<i>batchnorm_1</i> Normalizacja partii 2048 kanałów	$2048(C) \times 1(B)$	Ofset: 2048×1 Skala: 2048×1
<i>dropout_1</i> 50% dropout	$2048(C) \times 1(B)$	—
<i>fc_1</i> 256 warstwa w pełni połączona	$256(C) \times 1(B)$	Wagi: 256×2048 Biasy: 256×1
<i>tanh_1</i> Hyperbolic tangens	$256(C) \times 1(B)$	—
<i>batchnorm_2</i> Normalizacja partii 256 kanałów	$256(C) \times 1(B)$	Ofset: 256×1 Skala: 256×1
<i>dropout_2</i> 50% dropout	$256(C) \times 1(B)$	—
<i>fc_2</i> 256 warstwa w pełni połączona	$256(C) \times 1(B)$	Wagi: 256×2048 Biasy: 256×1
<i>tanh_2</i> Tangens hiperboliczny	$256(C) \times 1(B)$	—
<i>batchnorm_3</i> Normalizacja partii 256 kanałów	$256(C) \times 1(B)$	Ofset: 256×1 Skala: 256×1
<i>dropout_3</i> 50% dropout	$256(C) \times 1(B)$	—
<i>fc_3</i> 256 warstwa w pełni połączona	$256(C) \times 1(B)$	Wagi: 256×2048 Biasy: 256×1
<i>tanh_3</i> Tangens hiperboliczny	$256(C) \times 1(B)$	—

Tabela. 6.1. Szczegółowe informacje o strukturze wielogłęziowej sieci neuronowej LSTM+CNN

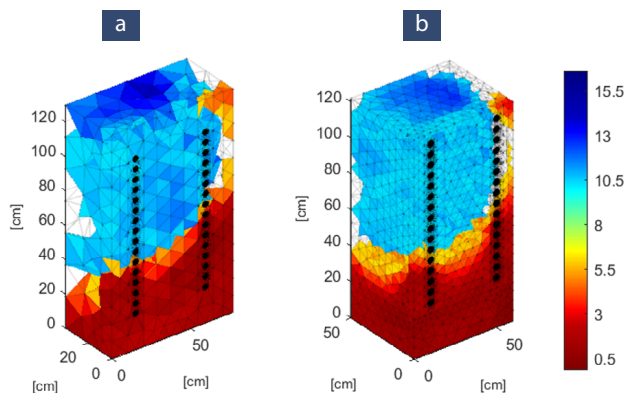
Nazwa i opis warstwy	Aktywacje	Parametry uczące się
<i>batchnorm_4</i> Normalizacja partii 256 kanałów	256(C)×1(B)	Ofset: 256×1 Skala: 256×1
<i>dropout_4</i> 50% dropout	256(C)×1(B)	—
<i>conv1d_1</i> 112 4×896 konwolucja z krokiem 1 i dopełnieniem [4 4]	112(C)×1(B)×6(T)	Wagi: 4×896×112 Biasy: 1×112
<i>batchnorm_1_1</i> Normalizacja partii 112 kanałów	112(C)×1(B)×6(T)	Ofset: 112×1 Skala: 112×1
<i>relu_1</i> ReLU	112(C)×1(B)×6(T)	—
<i>dropout_5</i> 30% dropout	112(C)×1(B)×6(T)	—
<i>conv1d_2</i> 112 4×112 konwolucja z krokiem 1 i dopełnieniem [4 4]	112(C)×1(B)×11(T)	Wagi: 4×112×112 Biasy: 1×112
<i>batchnorm_1_2</i> Normalizacja partii 112 kanałów	112(C)×1(B)×11(T)	Ofset: 112×1 Skala: 112×1
<i>relu_2</i> ReLU	112(C)×1(B)×11(T)	—
<i>dropout_6</i> 3096 dropout	112(C)×1(B)×11(T)	—
<i>conv1d_3</i> 112 4×112 konwolucja z krokiem 1 i dopełnieniem [4 4]	112(C)×1(B)×16(T)	Wagi: 4×112×112 Biasy: 1×112
<i>batchnorm_1_3</i> Normalizacja partii 112 kanałów	112(C)×1(B)×16(T)	Ofset: 112×1 Skala: 112×1
<i>relu_3</i> ReLU	112(C)×1(B)×16(T)	—
<i>dropout_7</i> 3096 dropout	112(C)×1(B)×16(T)	—
<i>gmpool1d</i> 1-D global maxpooling	112(C)×1(B)	—
<i>fc_4</i> 512 warstwa w pełni połączona	512(C)×1(B)	Wagi: 512×112 Biasy: 512×1
<i>concat</i> Połączenie 4 wejść jednowymiarowych	1280(C)×1(B)	—
<i>bilstm</i> BiLSTM z 1280 jednostkami ukrytymi	2560(C)×1(B)	Wagi wejściowe: 10240×1280 Wagi rekurencyjne: 10240×1280 Biasy: 10240×1

Tabela. 6.1. Szczegółowe informacje o strukturze wielogłęziowej sieci neuronowej LSTM+CNN

Nazwa i opis warstwy	Aktywacje	Parametry uczące się
<i>batchnorm_5</i> Normalizacja partii 2560 kanałów	2560(C)×1(B)	Ofset: 2560×1 Skala: 2560×1
<i>fc_5</i> 11458 warstwa w pełni połączona	11458(C)×1(B)	Wagi: 11458×2560 Biasy: 11458×1

W tabeli 6.1 znajdują się także szczegółowe informacje dotyczące warstw konwolucyjnych, takich jak *conv1d_1*, które mają wagi o wymiarach $4 \times 896 \times 112$ i biasy o wymiarach 1×112 . Warstwy te są kluczowe dla przetwarzania sekwencji danych poprzez ekstrakcję lokalnych cech i wzorców. Dodatkowo informacje o normalizacji wsadowej, takie jak offsety i skale, są podane dla warstw batchnorm, co wskazuje na stosowanie tej techniki w celu stabilizacji i przyspieszenia procesu uczenia. Tak więc tabela 6.1 daje szczegółowy wgląd w strukturę i parametry sieci neuronowej, umożliwiając zrozumienie mechanizmów współpracy między warstwami modelu. Celem jest maksymalizacja efektywności procesów przetwarzania danych i uczenia się złożonych zależności ukrytych w zbiorach danych wejściowych, a także w ich reprezentacjach (współczynnikach) generowanych przez kolejne warstwy modelu. Dzięki zastosowaniu różnych typów warstw i technik, takich jak LSTM, konwolucje, normalizacja wsadowa i dropout, sieć jest w stanie skutecznie modelować złożone, nieliniowe zależności głęboko ukryte w danych sekwencyjnych.

W celu wygenerowania rekonstruowanych obrazów tomograficznych wykorzystano siatkę FEM o dużej gęstości zawierającą 11458 elementów skończonych. Dla porównania, rekonstrukcje muru opisane w rozdziale 5.11. zostały wykonane na siatce FEM o rozdzielczości 3050 wokseli, czyli niespełna czterokrotnie mniejszej. W celu lepszego zobrazowania różnic w dokładności pomiędzy siatkami o tak odmiennych rozdzielczościach na rysunku 6.4. przedstawiono porównanie obrazu rekonstrukcyjnego wykonanego przy użyciu siatek FEM o różnej gęstości. W obu przypadkach wektor pomiarowy był ten sam, jednak z uwagi na różne wektory wyjściowe obrazy zostały wykonane przy użyciu różnych sieci neuronowych. Stąd dostrzegalne są subtelne różnice w rozkładach zawilgoceń, jednak rysunki dobrze prezentują korzyści, jakie niesie ze sobą wyższa rozdzielczość obrazu przestrzennego.



Rys. 6.4. Porównanie obrazów rekonstrukcyjnych dla tego samego rozkładu zawilgocenia, wykonane przy użyciu siatek FEM o różnej gęstości:
 (a) siatka o gęstości 3050 wokseli, (b) siatka o gęstości 11458 wokseli

Wymiary gęstej siatki FEM ($x \times y \times z$) podane w centymetrach wynosiły odpowiednio $60 \times 50 \times 122$, natomiast wymiary siatki rzadkiej to $77 \times 38 \times 130$. Różne wymiary siatek nie mają istotnego znaczenia na jakość rekonstrukcji. W tomografii ETI natężenie pola elektrycznego zmienia się w zależności od odległości od elektrod, zgodnie z prawem Coulomba i zasadami elektrostatyki. W bliskiej odległości od elektrod natężenie pola jest najwyższe, a następnie maleje wraz z odległością. W związku z powyższym wraz z odległością od elektrod maleje również rozdzielczość rekonstrukcji. Nie sposób jednoznacznie odpowiedzieć na pytanie, jaka jest maksymalna głębokość obrazowania muru w tomografii ETI. Jest to uzależnione od wielu czynników, które można podzielić na niezależne i zależne. Do czynników niezależnych należą własności struktury materiałowej badanej ściany i stopień zawilgocenia muru. Do parametrów zależnych zaliczamy liczbę elektrod w zestawie pomiarowym, zastosowany protokół pomiarowy, parametry prądowo napięciowe oraz częstotliwość prądu elektrycznego. W przybliżeniu można oszacować, że skuteczna głębokość obrazowania systemu tomograficznego wykorzystanego w badaniach opisanych w niniejszym opracowaniu oscylowała w granicach 50 cm.

6.2. Pomiary wilgotności zrealizowane na stanowisku nr 1

Rysunek 6.5 przedstawia zdjęcie prototypowego tomografu ETI, który został wykorzystany do badania wilgotności murów metodą elektrycznej tomografii impedancyjnej. Na zdjęciu, w głębi, widać ceglana strukturę ściany, która


pojawia się w miejscach uszkodzonej elewacji. Szczegółowa konstrukcja tomografu została opisana w rozdziale 5.2. Prócz tomografu w skład systemu tomograficznego wchodzi zestaw 32 elektrod przyłożonych do ściany Złotej Bramy w Gdańsku. Na zdjęciu widoczny jest także laptop, który służy do kontrolowania procesu pomiarowego i rejestrowania danych. Pomiarzy wychodzące z tomografu są przetwarzane za pomocą wytrenowanych modeli opartych na uczeniu maszynowym. Dzięki temu można łatwo zmieniać modele transformujące pomiary na obrazy. 32 elektrody są rozmieszczone w dwóch pionowych rzędach po 16 elektrod każda, przytwierdzonych bezpośrednio do ściany. Specjalnie zaprojektowane elektrody zapewniają styczność z murem, absorbując nierówności. Aparatura pomiarowa jest umieszczona na wózku, co ułatwia jej transport i ustawienie w odpowiedniej pozycji.

Na rysunku 6.6 przedstawiono fotografie porównawcze punktu pomiarowego nr 1. Zdjęcie 6.6 (b) przedstawia widok badanej ściany w podczerwieni. Na skutek parowania obszary zawilgocone mają niższą temperaturę, co powoduje, że ich kolor staje się niebieski. Jest to zgodne z paskiem kolorów widocznym po prawej stronie termogramu. Zdjęcie termograficzne zostało wykonane w celu porównania go z rekonstrukcją tomograficzną. Jest to jeden ze sposobów walidacji tomogramów ETI.



Rys. 6.5. Stanowisko pomiarowe nr 1 – tomograf z elektrodami


Źródło: materiały Netrix S.A.



Rys. 6.6. Stanowisko pomiarowe nr 1:
 (a) fotografia porównawcza ściany, (b) obraz termowizyjny

Źródło: materiały Netrix S.A.


Na rysunku 6.7 przedstawiono zwymiarowane miejsca usytuowania elektrod na ścianie stanowiska pomiarowego nr 1. Numery elektrod są zgodne z tabelą 6.2. Z rysunku wynika, że punkty pomiarów dielektrycznych są tożsame z miejscami styku elektrod ETI. Pionowe listwy z elektrodami są od siebie oddalone o 45 cm. Dolna krawędź elektrod znajduje się na wysokości 24 cm, a górna 118 cm nad poziomem posadzki. Odległość między filarem a prawą listwą elektrod wynosi 16,5 cm.



Rys. 6.7. Zwymiarowane miejsca usytuowania elektrod na ścianie stanowiska pomiarowego nr 1
 Opracowanie własne na podstawie materiałów Netrix S.A. autorstwa A. Hoła

Do weryfikacji rzeczywistych pomiarów ETI, tj. do celów walidacji, została wykorzystana metoda dielektryczna. Stosując metodę dielektryczną, uzyskujemy

pomiary punktowe. Metoda grawimetryczna zapewniłaby dokładniejsze pomiary uwzględniające bezwzględną (procentową) zawartość wody w badanych próbkach muru, jednak jest to metoda niszcząca, której nie można było zastosować z uwagi na historyczną wartość badanego obiektu. Za pomocą zależności korelacyjnej przekształcono bezwymiarowe wartości pomiarów dielektrycznych X_D na procentowe wartości zawilgocenia U_m [%]. Na rysunku 6.8 przedstawiono fotografie miernika dielektrycznego GANN UNI 2 (GANN Mess- u. Regeltechnik GmbH, Stuttgart, Germany), którym wykonano pomiary walidacyjne dla stanowisk o numerach 1, 2 i 3. Miernik dielektryczny GANN UNI 2 służy do pomiaru wilgotności materiałów budowlanych, takich jak mur, beton, drewno czy gips. Jest on szeroko stosowany w budownictwie, konserwacji zabytków i inżynierii lądowej do monitorowania stanu wilgotności obiektów. GANN UNI 2 działa na zasadzie pomiaru stałej dielektrycznej materiału, która zmienia się w zależności od zawartości wody. Urządzenie generuje pole elektryczne i mierzy jego oddziaływanie z materiałem. Na podstawie tych pomiarów miernik jest w stanie określić zawartość wilgoci w badanym materiale. Pojedyncza sonda stykowa miernika GANN UNI 2 jest wystarczająca do uzyskania pomiaru, ponieważ działa ona na zasadzie zmiany pojemności elektrycznej w polu generowanym przez sondę. Kiedy sonda zostaje przyłożona do powierzchni muru, pole elektryczne wnika w ścianę na określoną głębokość, a miernik rejestruje zmianę pojemności w zależności od wilgotności materiału. Sonda jest w stanie wychwycić te zmiany i na tej podstawie miernik oblicza wilgotność. Proces ten jest szybki i pozwala na uzyskanie precyzyjnych wyników bez potrzeby stosowania wielu sond stykowych.



Rys. 6.8. Miernik dielektryczny GANN UNI 2: (a) miernik z sondą, (b) sposób wykonywania pomiaru

Źródło: materiały Netrix S.A.

Głębokość pomiaru za pomocą miernika GANN UNI 2 zależy od właściwości badanej powierzchni oraz specyfiki urządzenia. Standardowo głębokość pomiaru w przypadku materiałów budowlanych może wynosić od kilku milimetrów do kilku centymetrów. Jest to wystarczające do uzyskania wiarygodnych wyników w kontekście powierzchniowych badań wilgotności materiałów budowlanych.

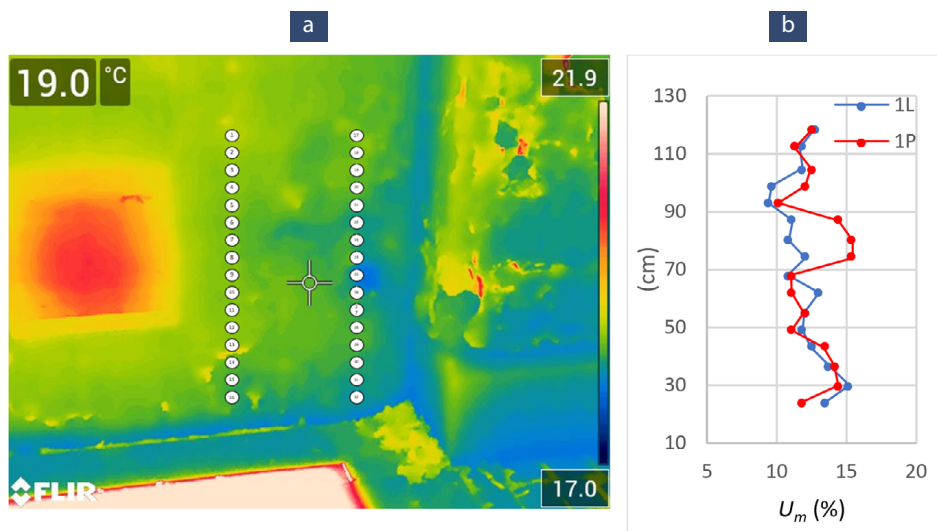
W tabeli 6.2 zaprezentowano zestawienie rezultatów badań wilgotności muru ceglanego ściany zewnętrznej w przyziemiu budynku Złotej Bramy na stanowisku pomiarowym nr 1. Oznaczenia 1L i 1P korespondują z rysunkiem 6.7 i oznaczają odpowiednio lewą i prawą pionową serię pomiarów punktowych, które wykonano w miejscach przylegania elektrod ETI. W następnej kolumnie podano odległości punktów pomiarowych od poziomu gruntu. W kolumnie zatytułowanej „ X_D – wskazanie miernika dielektrycznego Gann Uni 2” znajdują się bezwymiarowe wartości pomiarów walidacyjnych. W ostatniej kolumnie zamieszczono procentowe wartości zawilgocień uzyskane za pomocą funkcji transformującej zamieszczonej pod tabelą $y = 0,4309e^{0,0238x}$. Formuła przekształca pomiary dielektryczne na procentową wilgotność muru, co pozwala na lepsze zrozumienie i ocenę stanu zawilgocenia. W celu dopasowania powyższej formuły do danych została wykorzystana metoda najmniejszych kwadratów, zapewniając, że model dokładnie odzwierciedla zależność między odczytami dielektrycznymi a rzeczywistą wilgotnością. Wartość współczynnika determinacji $R^2 = 0,7755$ wskazuje na dobrą jakość dopasowania, co czyni tę metodę wiarygodną i użyteczną w praktyce.

Tabela. 6.2. Zestawienie rezultatów badań wilgotności muru ceglanego ściany zewnętrznej w przyziemiu budynku Złotej Bramy na stanowisku pomiarowym nr 1. Opracowanie własne na podstawie materiałów Netrix S.A. autorstwa A. Hoła

Oznaczenie elektrod i położenia punktów pomiarowych. Odległości zostały zmierzone od poziomu gruntu.	X_D – wskazanie miernika dielektrycznego Gann Uni 2	U_m [%] – wilgotność masowa określona na podstawie zależności korelacyjnej*	
1L	118 cm (elektroda 1)	141,8	12,59
	112 cm (elektroda 2)	138,5	11,64
	105 cm (elektroda 3)	139,3	11,86
	99 cm (elektroda 4)	130,6	9,64
	93 cm (elektroda 5)	129,5	9,40
	87 cm (elektroda 6)	136,6	11,13
	80 cm (elektroda 7)	135,6	10,86
	74 cm (elektroda 8)	140,0	12,06
	68 cm (elektroda 9)	135,3	10,79
	62 cm (elektroda 10)	143,2	13,02
	55 cm (elektroda 11)	139,7	11,98
	49 cm (elektroda 12)	139,3	11,86
	43 cm (elektroda 13)	141,3	12,44
	37 cm (elektroda 14)	145,4	13,72
	30 cm (elektroda 15)	149,7	15,20
	24 cm (elektroda 16)	144,6	13,46
1P	118 cm (elektroda 32)	145,3	12,45
	112 cm (elektroda 31)	137,3	11,31
	105 cm (elektroda 30)	141,3	12,44
	99 cm (elektroda 29)	140,0	12,05
	93 cm (elektroda 28)	132,6	10,11
	87 cm (elektroda 27)	147,5	14,42
	80 cm (elektroda 26)	150,4	15,45
	74 cm (elektroda 25)	150,4	15,45
	68 cm (elektroda 24)	136,2	11,02
	62 cm (elektroda 23)	136,4	11,07
	55 cm (elektroda 22)	139,5	11,92
	49 cm (elektroda 21)	136,4	11,07
	43 cm (elektroda 20)	144,2	13,34
	37 cm (elektroda 19)	146,6	14,11
	30 cm (elektroda 18)	147,5	14,42
	24 cm (elektroda 17)	139,0	11,78

*Równanie dla metody dielektrycznej: $y = 0,4309e^{0,0238x}$, $R^2 = 0,7755$

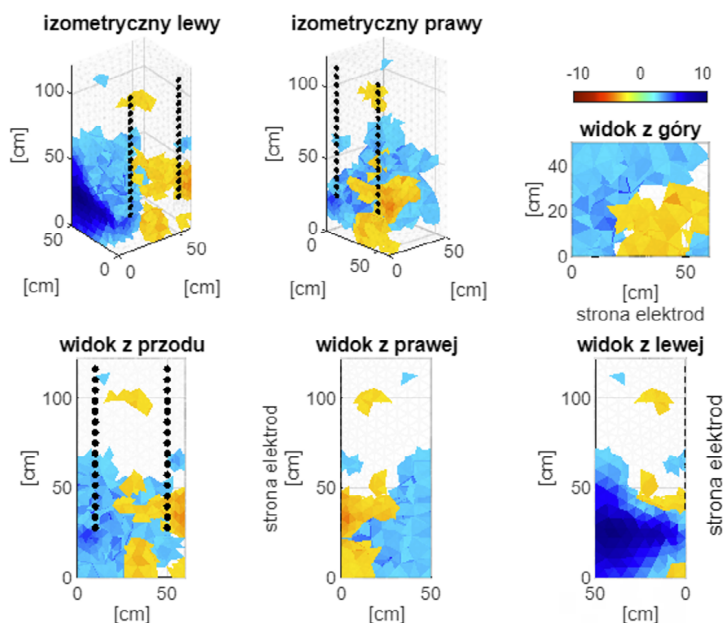
Na rysunku 6.9 przedstawiono wykresy zawilgocenia U_m [%] dla stanowiska nr 1 w funkcji odległości od poziomu gruntu z podziałem na strony lewą (1L) i prawą (1P). Rysunek 6.9 (b) jest de facto graficzną prezentacją prawej kolumny tabeli 6.2. i powinien być traktowany jako rezultat dielektrycznych pomiarów walidacyjnych dla ETI. Rysunek 6.9 (a) przedstawia punkty pomiarów dielektrycznych na tle termogramu badanego stanowiska.



Rys. 6.9. Wykres wilgotności dla poszczególnych punktów pomiarowych stanowiska nr 1:
 (a) termogram z naniesionymi punktami pomiarów,
 (b) wartości wilgoci w poszczególnych punktach

Źródło: opracowanie własne na podstawie materiałów Netrix S.A.

Z tego powodu analiza rysunku 6.9 bazuje na konfrontacji z rysunkiem 6.10, na którym przedstawiono tomograficzną rekonstrukcję rozkładu zawilgoczeń dla stanowiska nr 1. Porównując oba rysunki, należy mieć na uwadze, że pomiar dielektryczny, podobnie jak obraz termowizyjny, przedstawia jedynie poziom zawilgoczenia powierzchni badanego fragmentu murów. Nie odzwierciedla on obszarów zawilgoczeń ulokowanych w substancji ściany, głębiej niż kilka centymetrów od jej powierzchni.




Rys. 6.10. Rekonstrukcja rozkładu zawilgoceń dla stanowiska nr 1

Analizując oba rysunki, widzimy pewną zgodność. Na rysunku 6.9 istnieje anomalia dla pomiarów 1P, ponieważ w okolicy 80 cm od poziomu gruntu wilgotność niespodziewanie wzrasta. Znajduje to potwierdzenie na tomogramie widocznym na rysunku 6.10. Wynika z niego, że prawa strona badanego fragmentu muru jest mniej wilgotna od strony lewej, jednak na wysokości około 80 cm nad poziomem gruntu, po prawej stronie, blisko powierzchni ściany, do której przylegają elektrody, znajduje się zawilgocony obszar oznaczony kolorem niebieskim. Obszary po lewej stronie są bardziej wilgotne niż po prawej, jednak są zlokalizowane w głębi badanego fragmentu muru, przez co nie zostały uchwycone miernikiem dielektrycznym. Warto zwrócić uwagę, że analiza przestrzennej rekonstrukcji tomograficznej jest w zasadzie niemożliwa przy pomocy pojedynczego obrazu. Dopiero widoki z wielu perspektyw umożliwiają prawidłowe zrozumienie rozkładu zawilgoceń rozlokowanych we wnętrzu badanego fragmentu muru.

6.3. Pomiary wilgotności zrealizowane na stanowisku nr 2

Na rysunku 6.11 przedstawiono fotografie stanowiska pomiarowego nr 2. Rysunek 6.11 (c) obrazuje termograficzny widok badanej ściany. Na podstawie

termogramu można wyciągnąć wniosek, że badany fragment ściany jest za-
wilgocony w sposób równomierny.

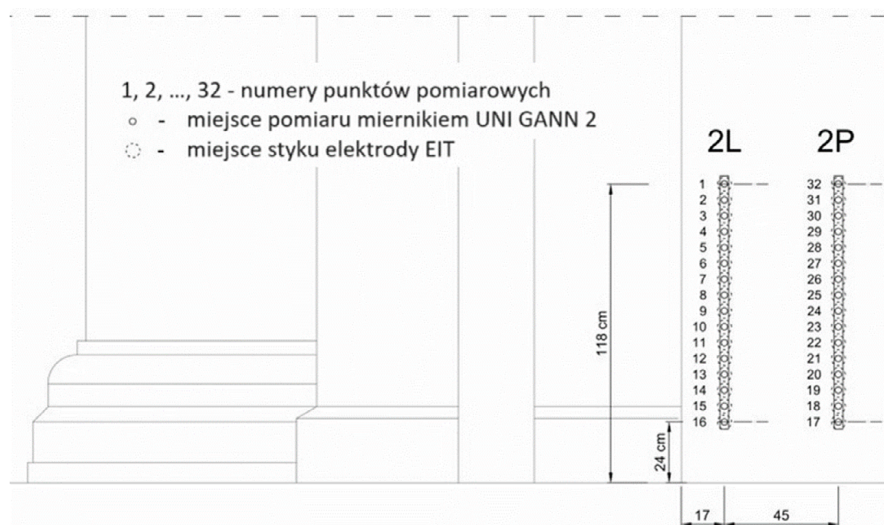


Rys. 6.11. Stanowisko pomiarowe nr 2:

(a) tomograf z elektrodami, (b) fotografia porównawcza ściany, (c) obraz termowizyjny

Źródło: materiały Netrix S.A.

Na rysunku 6.12 przedstawiono zwymiarowane miejsca usytuowania elektrod na ścianie stanowiska pomiarowego nr 2. Numery elektrod są zgodne z tabelą 6.3. Z rysunku wynika, że punkty pomiarów dielektrycznych są tożsame z miejscami styku elektrod ETI. Dolna krawędź listew z elektrodami została umieszczona na wysokości 24 cm, natomiast krawędź górna jest oddalona od posadzki o 118 cm. Rozstaw listew wynosi 45 cm. Lewa listwa jest oddalona od filaru o 17 cm.



Rys. 6.12. Zwymiarowane miejsca usytuowania elektrod na ścianie stanowiska pomiarowego nr 2.

Opracowanie własne na podstawie materiałów Netrix S.A. autorstwa A. Hoła

Tabela 6.3 zawiera pomiary wykonane metodą dielektryczną ze stanowiska nr 2. Struktura zamieszczonych informacji, w tym nagłówki kolumn, są analogiczne do tabeli 6.2. Równanie transformacji wskazań miernika X_D na bezwzględne wartości procentowe U_m [%] jest również takie samo jak w tabeli 6.2.

Tabela. 6.3. Zestawienie rezultatów badań wilgotności muru ceglanego ściany zewnętrznej w przyziemiu budynku Złotej Bramy na stanowisku pomiarowym nr 2. Opracowanie własne na podstawie materiałów Netrix S.A. autorstwa A. Hoła


Oznaczenie elektrod i położenia punktów pomiarowych. Odległości zostały zmierzone od poziomu gruntu.		X_D – wskazanie miernika dielektrycznego Gann Uni 2	U_m [%] – wilgotność masowa określona na podstawie zależności korelacyjnej*
2L	118 cm (elektroda 1)	94,4	4,07
	112 cm (elektroda 2)	91,9	3,84
	105 cm (elektroda 3)	86,3	3,36
	99 cm (elektroda 4)	104,2	5,15
	93 cm (elektroda 5)	121,9	7,84
	87 cm (elektroda 6)	139,3	11,86
	80 cm (elektroda 7)	145,7	13,82
	74 cm (elektroda 8)	141,8	12,59
	68 cm (elektroda 9)	143,8	13,20
	62 cm (elektroda 10)	144,1	13,30
	55 cm (elektroda 11)	146,2	13,98
	49 cm (elektroda 12)	142,2	12,71
	43 cm (elektroda 13)	136,3	11,05
	37 cm (elektroda 14)	120,1	7,51
	30 cm (elektroda 15)	127,0	8,85
	24 cm (elektroda 16)	127,7	9,00

Tabela. 6.3. Zestawienie rezultatów badań wilgotności muru ceglanego ściany zewnętrznej w przyziemiu budynku Złotej Bramy na stanowisku pomiarowym nr 2. Opracowanie własne na podstawie materiałów Netrix S.A. autorstwa A. Hoła

Oznaczenie elektrod i położenia punktów pomiarowych. Odległości zostały zmierzone od poziomu gruntu.	X_D – wskazanie miernika dielektrycznego Gann Uni 2	U_m [%] – wilgotność masowa określona na podstawie zależności korelacyjnej*	
2P	118 cm (elektroda 32)	57,5	1,69
	112 cm (elektroda 31)	54,4	1,57
	105 cm (elektroda 30)	62,7	1,92
	99 cm (elektroda 29)	72,7	2,43
	93 cm (elektroda 28)	68,4	2,19
	87 cm (elektroda 27)	74,2	2,52
	80 cm (elektroda 26)	89,3	3,61
	74 cm (elektroda 25)	82,6	3,08
	68 cm (elektroda 24)	98,2	4,46
	62 cm (elektroda 23)	103,3	5,04
	55 cm (elektroda 22)	82,2	3,05
	49 cm (elektroda 21)	81,1	2,97
	43 cm (elektroda 20)	97,0	4,33
	37 cm (elektroda 19)	97,6	4,40
	30 cm (elektroda 18)	126,9	8,84
24 cm (elektroda 17)	124,9	8,42	

*Równanie dla metody dielektrycznej: $y = 0,4309e^{0,0238x}$, $R^2 = 0,7755$

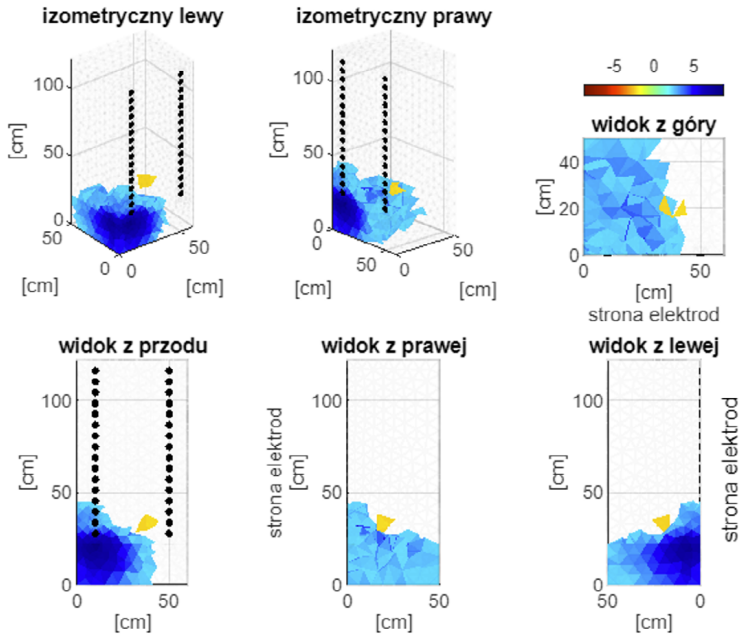
Rysunek 6.13 (b) przedstawia liniowe przebiegi zawilgocenia U_m [%] dla stanowiska nr 2 w relacji do odległości poszczególnych punktów pomiarowych od poziomu gruntu. Zachowano podział na strony lewą (2L) i prawą (2P). Omawiany rysunek reprezentuje prawą kolumnę tabeli 6.3 i, podobnie jak w przypadku stanowiska pomiarowego nr 1, celem jest walidacja pomiarów tomograficznych ETI. Na rysunku 6.13 (a) zobrazowano punkty pomiarów na tle termogramu.



Rys. 6.13. Wykres wilgotności dla poszczególnych punktów pomiarowych stanowiska nr 2:
 (a) termogram z naniesionymi punktami pomiarów,
 (b) wartości wilgoci w poszczególnych punktach

Źródło: opracowanie własne na podstawie materiałów Netrix S.A.

Analizując wykres widoczny na rysunku 6.13 z rysunkiem 6.14, przedstawiającym rekonstrukcje ETI, można zauważyć wyraźną analogię. Z obu rysunków wynika, że wilgoć jest skoncentrowana po lewej stronie badanego fragmentu muru. Według wykresu dielektrycznego wzrost zawilgocenia pod lewą listwą zaczyna się około 40 cm nad poziomem gruntu i kończy około 90 cm nad posadzką. Z kolei rekonstrukcje ETI wskazują na wilgoć skoncentrowaną po lewej stronie, nieprzerwanie od poziomu posadzki do wysokości prawie 50 cm. Z widoków izometrycznych i bocznych można wywnioskować, że wraz z odległością od elektrod w głąb ściany poziom zawilgocenia maleje. Koncentrację wilgoci po lewej stronie badanego fragmentu widać wyraźnie na widoku z góry (rysunek 6.14). Potwierdza to zgodność obu metod – tomograficznej i dielektrycznej. Dodatkowym pomiarem walidacyjnym był obraz termowizyjny widoczny na rysunku 6.11 (c). Analizując go, należy wziąć pod uwagę, że obraz termograficzny obrazuje temperaturę powierzchni muru. W przypadku bardzo dużego kontrastu między nagrzaną słońcem posadzką a zacienioną, zimną ścianą, co widać na rysunkach 6.11 (b) i (c), różnice w tonacji odcieni mogą zostać zatarte. Przy bardziej wnikliwej analizie termogramu można zauważyć, że lewy dolny róg na prawo od filaru jest ciemniejszy, co jest zgodne z rekonstrukcją tomograficzną.



Rys. 6.14. Rekonstrukcja rozkładu zawilgoceń dla stanowiska nr 2


6.4. Pomiary wilgotności zrealizowane na stanowisku nr 3

Ostatnim badanym miejscem pomiarowym było stanowisko nr 3. Na rysunku 6.15 widać, że jest to filar przylegający do ściany. Rysunek 6.16 (b) przedstawia obraz termowizyjny badanego stanowiska, z którego wynika, że powierzchnia prawej strony filaru ma wyższą temperaturę od innych elementów badanego fragmentu muru. Sugeruje to, że strona lewa, znajdująca się w cieniu i schowana we wnęce obok sąsiadującego filaru, jest bardziej wilgotna niż strona prawa.



Rys. 6.15. Stanowisko pomiarowe nr 3 – tomograf z elektrodami

Źródło: materiały Netrix S.A.

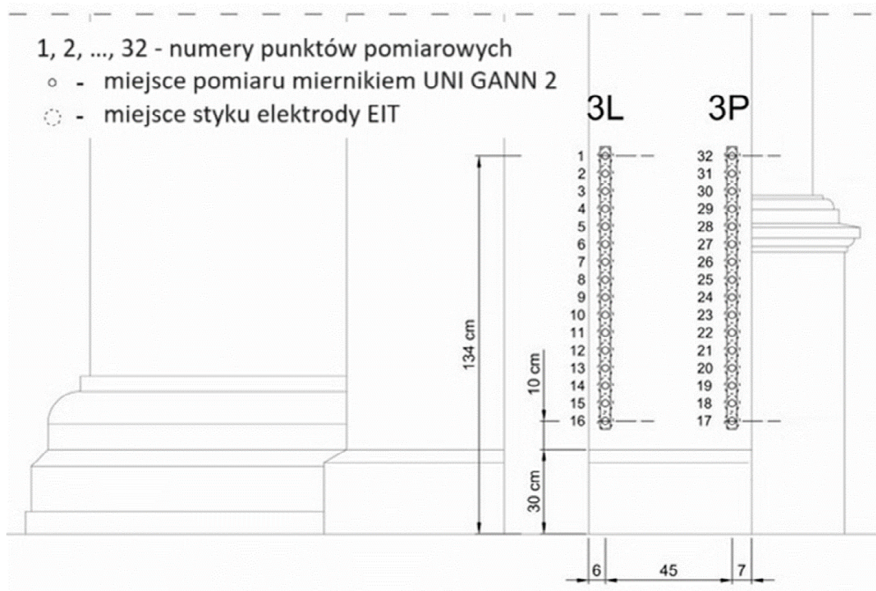


Rys. 6.16. Stanowisko pomiarowe nr 3:

(a) – fotografia porównawcza badanego filaru, (b) – obraz termowizyjny filaru

Źródło: materiały Netrix S.A.

Na rysunku 6.17 zamieszczono schemat filaru będącego jednocześnie obiektem pomiarów w ramach stanowiska pomiarowego nr 3. Zarówno numery elektrod, jak i odległości między listwami są identyczne jak w przypadku poprzednich dwóch miejsc pomiarowych. Odległości dielektrycznych punktów pomiarowych i zarazem elektrod są zgodne z informacjami zawartymi w tabeli 6.4. Punkty pomiarów dielektrycznych są tożsame z miejscami styku elektrod ETI. Dolna krawędź listew z elektrodami została umieszczona na wysokości 40 cm od posadzki. Krawędź górna jest oddalona od posadzki o 134 cm. Szerokość badanego filaru wynosi $6 + 45 + 7 = 58$ cm.



Rys. 6.17. Zwymiarowane miejsce usytuowania elektrod na ścianie stanowiska pomiarowego nr 3
Opracowanie własne na podstawie materiałów Netrix S.A. autorstwa A. Hoła

Tabela 6.4 zawiera zestawienie pomiarów wykonanych metodą dielektryczną na stanowisku nr 3. Struktura zawartych w tabeli informacji, w tym nagłówki kolumn, są analogiczne do tabel 6.2 i 6.3. Równanie transformacji wskazań miernika X_D na bezwzględne wartości procentowe U_m [%] jest również takie samo jak dla pomiarów na stanowiskach 1 i 2.


Tabela. 6.4. Zestawienie rezultatów badań wilgotności filaru z piaskowca i z wtrąceniami cegły w przyziemiu budynku Złotej Bramy na stanowisku pomiarowym nr 3. Opracowanie własne na podstawie materiałów Netrix S.A. autorstwa A. Hoła

Oznaczenie elektrod i położenia punktów pomiarowych. Odległości zostały zmierzone od poziomu gruntu.	X_D – wskazanie miernika dielektrycznego Gann Uni 2	U_m [%] – wilgotność masowa określona na podstawie zależności korelacyjnej*	
3L	134 cm (elektroda 1)	157,7	18,38
	128 cm (elektroda 2)	148,7	14,84
	121 cm (elektroda 3)	157,2	18,16
	115 cm (elektroda 4)	157,5	18,29
	109 cm (elektroda 5)	155,6	17,49
	103 cm (elektroda 6)	154,6	17,07
	96 cm (elektroda 7)	132,0	9,97
	90 cm (elektroda 8)	147,3	14,36
	84 cm (elektroda 9)	147,4	14,39
	78 cm (elektroda 10)	150,6	15,52
	71 cm (elektroda 11)	143,2	13,02
	65 cm (elektroda 12)	141,6	12,53
	59 cm (elektroda 13)	124,0	8,24
	53 cm (elektroda 14)	100,3	4,69
	46 cm (elektroda 15)	114,8	6,62
	40 cm (elektroda 16)	129,6	9,42
3P	134 cm (elektroda 32)	139,9	12,03
	128 cm (elektroda 31)	143,1	12,99
	121 cm (elektroda 30)	142,1	12,68
	115 cm (elektroda 29)	132,4	10,07
	109 cm (elektroda 28)	143,0	12,96
	103 cm (elektroda 27)	138,3	11,58
	96 cm (elektroda 26)	147,2	14,32
	90 cm (elektroda 25)	146,0	13,91
	84 cm (elektroda 24)	142,8	12,89
	78 cm (elektroda 23)	138,0	11,50
	71 cm (elektroda 22)	142,9	12,92
	65 cm (elektroda 21)	140,2	12,12
	59 cm (elektroda 20)	132,3	10,04
	53 cm (elektroda 19)	139,9	12,03
46 cm (elektroda 18)	141,3	12,44	
40 cm (elektroda 17)	150,5	15,49	

*Równanie dla metody dielektrycznej: $y = 0,4309e^{0,0238x}$, $R^2 = 0,7755$

Rysunek 6.18 (b) przedstawia wykresy wilgotności U_m [%] wszystkich punktów pomiarowych stanowiska nr 3, które zostały wymienione w tabeli 6.4. Analogicznie do wykresów dla dwóch poprzednich punktów pomiarowych 1 i 2, tu również widoczne są dwie linie odpowiadające lewej i prawej linii punktów pomiarowych zgodnych z punktami styku elektrod rozmieszczonych na metalowych listwach wchodzących w skład systemu tomograficznego ETI. Na rysunku 6.18 (a) zwizualizowano punkty pomiarów na tle termogramu badanej powierzchni muru.

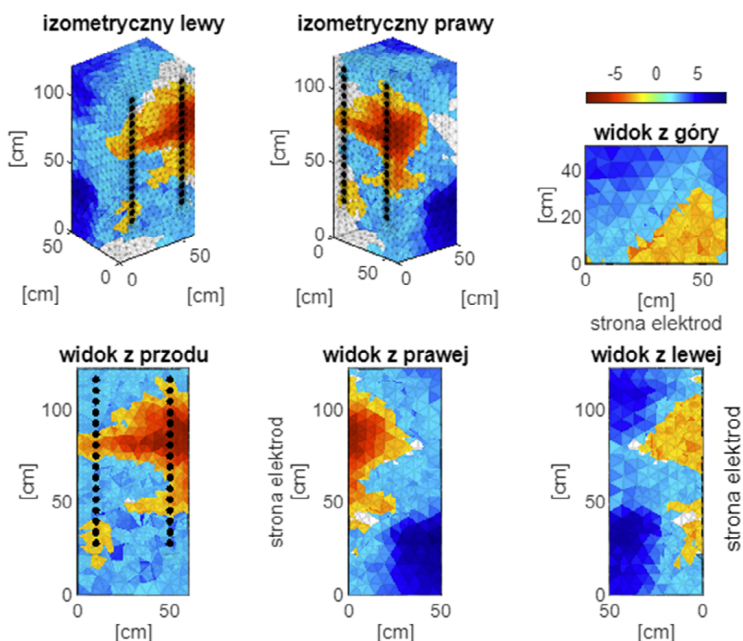
Analiza przebiegu obu linii widocznych na wykresie 6.18 (b) nie pozwala wyciągnąć jednoznacznych wniosków. Pomiary dielektryczne wskazują, że dla najniższej położonych punktów prawa strona zawiera więcej wilgoci niż lewa. W miarę oddalania się od posadzki różnica w zawilgoceniu pomiędzy stroną lewą i prawą spada, aby w okolicy 100 cm od poziomu gruntu zrównać się, a dla punktów położonych wyżej – więcej wilgoci zawiera strona lewa. Nie potwierdza tego zdjęcie termowizyjne (rysunek 6.16 (b)), co dodatkowo komplikuje analizę.



Rys. 6.18. Wykres wilgotności dla poszczególnych punktów pomiarowych stanowiska nr 3:
 (a) termogram z naniesionymi punktami pomiarowymi,
 (b) wartości wilgoci w poszczególnych punktach

Źródło: opracowanie własne na podstawie materiałów Netrix S.A.

W sytuacji niepewności spowodowanej sprzecznymi lub niejednoznacznymi wynikami pomiarów walidacyjnych wykonanych metodą termowizyjną i dielektryczną rysunek 6.19 przedstawia interesujący obraz tomograficzny rekonstruujący rozkład wilgoci wewnątrz badanego filaru.



Rys. 6.19. Rekonstrukcja rozkładu zawilgoceń dla stanowiska nr 3

Analiza tomogramu przestrzennego z różnych perspektyw pozwala zauważyć, że najbardziej zawilgocone obszary są zlokalizowane w dolnych, stykających się ze ścianą, rogach filaru. Kolejną obserwacją jest fakt, że strona filaru przylegająca do ściany jest bardziej zawilgocona niż strona, do której przyłożono elektrody. Widać również, że prawa strona filaru zawiera więcej obszarów suchych niż strona lewa. Zwłaszcza między 50 cm a 100 cm po prawej stronie badanego fragmentu muru widać żółtopomarańczowe zabarwienia, świadczące o mniejszym zawilgoceniu. Zrekonstruowany rozkład zawilgoceń jest w dużej mierze zgodny z pomiarami walidacyjnymi. Prócz tego wydaje się logiczny i prawdopodobny. Filar przyległy do ściany budowli ma trzy odkryte ściany boczne, co sprawia, że woda może łatwiej parować. Lewa ściana filaru jest schowana we wnęce, obok sąsiedniego filaru, przez co znajduje się w cieniu i jest bardziej wilgotna. Potwierdza to fotografia termowizyjna. Uzasadnione jest także gromadzenie się wilgoci w dolnych partiach filaru od strony ściany budowli, skąd również woda odparowuje wolniej. Powyższe argumenty z dużym prawdopodobieństwem dowodzą, że uzyskane rekonstrukcje obrazów tomograficznych wiernie odzwierciedlają rzeczywisty rozkład wilgoci wewnątrz badanego fragmentu muru.

7. Uwagi końcowe i wnioski

W niniejszym opracowaniu zaprezentowano dwa projekty badawcze dotyczące obrazowania rozkładów wilgoci wewnątrz murów z wykorzystaniem elektrycznej tomografii impedancyjnej (ETI). Badania koncentrowały się na problematyce doboru optymalnego algorytmu transformującego pomiary na rekonstrukcyjne obrazy tomograficzne. Rozdział 1 porusza tematy opisujące znaczenie problemu, jakie stanowi wilgoć zawarta w ścianach budynków i budowli, zwłaszcza tych o znaczeniu historycznym. Kolejną omawianą kwestią są metody wykorzystywane do pomiarów zawilgoceń budynków, w tym także tomografii elektrycznej. Osobną część rozdziału 1 stanowi opis celu i zakresu niniejszej pracy badawczej. Rozdział 2 dotyczy teoretycznych aspektów elektrycznej tomografii impedancyjnej, w tym znaczenia problemu odwrotnego i protokołu pomiarowego w ETI. W rozdziale 3 opisano wybrane metody modelowania problemu odwrotnego, takie jak metoda Gaussa–Newtona, regularyzacja Tikhonova oraz metoda Total Variation, maszyna wektorów nośnych (SVM), Lasso i elastic net oraz regresja liniowa i regresja logistyczna. W rozdziale 4 opisano kilka wybranych nowoczesnych struktur sztucznych sieci neuronowych.

7.1. Badania laboratoryjne muru ceglanego

W rozdziale 5 opisano pierwszy projekt badawczy dotyczący pomiarów wilgotności muru ceglanego, sztucznie zawilgoconego w warunkach laboratoryjnych. W trakcie badań porównano i zweryfikowano wybrane metody transformacji pomiarów na obrazy tomograficzne, w tym metody deterministyczne oraz oparte na uczeniu maszynowym, co pozwoliło na dość dokładne odtworzenie rozkładu wilgoci w badanym fragmencie muru. Przedstawiono również analizę porównawczą uzyskanych wyników, co umożliwiło ocenę efektywności i wiarygodności zastosowanych technik logarytmicznych. W sensie użytkowym badania umożliwiły lepsze zrozumienie mechanizmów związanych z rozkładem wilgoci wewnątrz muru ceglanego, który jest tradycyjną strukturą budowlaną, często spotykaną w budynkach historycznych. W pierwszej części rozdziału 5 opisano fizyczny model zawilgoconego muru ceglanego, uwzględniając jego wymiary, strukturę wewnętrzną, użyte materiały oraz sposób sztucznego zawilgocenia. Mur został ustawiony w płytkiej wannie z nieprzemakalnej folii, co pozwoliło na zalanie dolnej części muru wodą. Dodatkowy zbiornik umieszczony na szczycie porowatego muru umożliwił wnikanie wody od góry.

Dalsza część rozdziału opisuje kluczowe urządzenie użyte w badaniach – tomograf ETI. Urządzenie to pozwala na wykonywanie pomiarów elektrycznych, na podstawie których generowane są obrazy wewnętrznej struktury muru. Opisano również konstrukcję systemu elektrod użytych podczas pomiarów. Z uwagi na konieczność zapewnienia styku z nierównym murem, elektrody są niewralgicznym elementem w procesie akwizycji danych. W dalszej części omówiono różne algorytmy i metody obliczeniowe zastosowane do rekonstrukcji obrazów. Zastosowano metody deterministyczne oraz oparte na uczeniu maszynowym. Przedstawiono również analizę porównawczą uzyskanych wyników, co umożliwiło ocenę efektywności i dokładności poszczególnych technik. Na zakończenie rozdziału przeanalizowano wyniki badań, które wykazały zróżnicowaną przydatność poszczególnych metod w ETI. Porównując wyniki poszczególnych metod, można zauważyć, że w porównaniu z innymi metodami metody Gaussa–Newtona i Tikhonova mają niższe wartości korelacji Pearsona i jakości rekonstrukcji. Regresja liniowa daje najgorsze rezultaty. Z powodu słabej zdolności do wychwytywania nieliniowych zależności ta metoda w zasadzie nie nadaje się do rekonstrukcji obrazów tomograficznych. Metody Total Variation i SVM lepiej zachowują szczegóły, ale są bardziej podatne na szumy. Elastic net, choć użyteczna w prostszych przypadkach, ujawnia problemy z bardziej złożonymi rozkładami zawilgoceń. Metody uczenia

maszynowego, zwłaszcza WSSN, LSTM oraz hybrydowe sieci LSTM+CNN, osiągają najwyższe wartości wskaźników jakości rekonstrukcji, takich jak SSIM i korelacja Pearsona. To pokazuje, że powyższe metody są niezawodne i skuteczne w odtwarzaniu struktury oryginalnych obrazów referencyjnych. Na podstawie powyższych obserwacji należy wnioskować, że metody oparte na uczeniu maszynowym, szczególnie hybrydowe sieci LSTM+CNN, są skuteczniejsze w rekonstrukcji rozkładu zawilgoceń muru ceglanego, oferując wysoką jakość rekonstrukcji, stabilność oraz zdolność do uchwycenia szczegółowych struktur. Metody deterministyczne, choć użyteczne, wykazują istotne ograniczenia w porównaniu z zaawansowanymi technikami uczenia maszynowego.

7.2. Badania terenowe obiektu Złota Brama w Gdańsku

Rozdział 6 niniejszego opracowania opisuje badania wilgotności murów Złotej Bramy w Gdańsku, przeprowadzone w celu weryfikacji prototypowego systemu elektrycznej tomografii impedancyjnej (ETI) oraz metody algorytmicznej wykorzystującej wielogałęziową, hybrydową sieć neuronową LSTM+CNN. Pomiarzy miały za zadanie ocenę stanu zawilgocenia murów, co jest szczególnie istotne ze względu na wiek budowli i jej znaczenie historyczne. Prócz tomografu ETI oraz algorytmu opartego na uczeniu maszynowym, transformującego pomiary elektryczne na obrazy, w badaniach wykorzystano również miernik dielektryczny do punktowych pomiarów wilgotności oraz kamerę termowizyjną. Dwie ostatnie metody pomiarowe zostały wykorzystane do walidacji pomiarów ETI.

Modelowanie wielogałęziowej sieci neuronowej LSTM+CNN (ang. *long short-term memory + convolutional neural network*) było istotnym elementem opisywanego zadania badawczego. Sieć neuronowa została opracowana w celu poprawy dokładności rekonstrukcji obrazów wilgotności. Dzięki zaawansowanej architekturze sieci możliwe było precyzyjne odwzorowanie złożonych zależności pomiędzy pomiarami elektrycznymi a rzeczywistym stanem wilgotności murów.

Badania były zrealizowane na trzech stanowiskach pomiarowych. Do wszystkich pomiarów wykorzystano zestaw 32 elektrod umieszczonych w dwóch pionowych rzędach po 16 elektrod każda, przytwierdzonych bezpośrednio do ściany Złotej Bramy. Aparatura pomiarowa umieszczona na wózku umożliwiała łatwe przemieszczenie i ustawienie w odpowiedniej pozycji. W trakcie badań wykonano zdjęcia termograficzne, które porównano z rekonstrukcjami tomograficznymi.

W przypadku porównania tomografów ETI z fotografiami termowizyjnymi dla stanowiska nr 1 zdjęcia wykazały, że obszary zawilgocone mają niższą temperaturę, co potwierdziło wyniki uzyskane za pomocą tomografii ETI. Pomiar walidacyjne przeprowadzone za pomocą miernika dielektrycznego GANN UNI 2 wykazały dobrą zgodność z rekonstrukcjami tomograficznymi, co potwierdziło dokładność i wiarygodność zastosowanej metody.

W badaniach zrealizowanych na stanowisku nr 2 wykorzystano podobną konfigurację elektrod i sprzętu pomiarowego jak na stanowisku nr 1. Podobnie jak poprzednio, wykonano zdjęcia termograficzne w celu walidacji wyników uzyskanych za pomocą tomografii ETI. Rekonstrukcje tomograficzne wykazały zróżnicowane poziomy wilgotności w różnych częściach muru, co było zgodne z obserwacjami termograficznymi. Dielektryczne, punktowe pomiary walidacyjne potwierdziły wiarygodność wyników, wykazując podobną zgodność rozkładu wilgotności co w przypadku stanowiska nr 1.

Stanowisko nr 3, podobnie jak dwa poprzednie, zostało wyposażone w zestaw 32 elektrod i sprzęt pomiarowy umieszczony na wózku. Pomiar przeprowadzono w różnych warunkach atmosferycznych, co pozwoliło na ocenę wpływu wilgotności zewnętrznej na stan murów. Rekonstrukcje tomograficzne były zgodne z wynikami termograficznymi, ukazując wyraźne różnice w zawilgoceniu muru. Pomiar walidacyjne, podobnie jak na innych stanowiskach, wykazały wysoką zgodność z wynikami tomograficznymi, potwierdzając skuteczność zastosowanych metod.

Badania wykazały, że zastosowanie modelu wielogłęziowej sieci neuronowej LSTM+CNN w połączeniu z techniką tomografii ETI cechuje wysoka skuteczność w diagnostyce wilgotnościowej murów zabytkowych. Pomiar walidacyjne potwierdziły dokładność i wiarygodność rekonstrukcji tomograficznych, co potwierdza wartość użyteczną opisywanych metod, szczególnie w kontekście monitorowania, konserwacji i ochrony zabytków.

7.3. Kierunki dalszych badań

Obecnie elektrycznej tomografii impedancyjnej (ETI) nie można zaliczyć do popularnych metod obrazowania rozkładów wilgoci w murach. Z drugiej strony, naukowo udowodniony potencjał tej metody determinuje szanse jej rozwoju jako techniki o szerokim zastosowaniu w przyszłości. ETI może stać się popularną metodą diagnostyczną wykorzystywaną w budownictwie pod warunkiem spełnienia określonych kryteriów.

Podstawowym warunkiem jest konieczność osiągnięcia wysokiej precyzji obrazowania, co wymaga opracowania zaawansowanych algorytmów rekonstrukcji obrazu oraz dokładnych metod pomiarów napięć na elektrodach. Wierne odwzorowanie rozkładu wilgoci w badanym fragmencie ściany jest kluczowe dla oceny stanu technicznego konstrukcji budowlanych oraz planowania działań naprawczych.

Drugim istotnym kryterium upowszechnienia tomografii elektrycznej jako metody pomiaru zawilgocenia jest uniwersalność. Ta cecha systemu tomograficznego umożliwia skuteczne obrazowanie obiektów o zróżnicowanej strukturze materiałowej. Różnorodność materiałów stosowanych w budownictwie, takich jak cegła, beton czy kamień, wymaga, aby systemy ETI miały zdolności adaptacyjne i skutecznie radziły sobie z różnorodnymi strukturami w terenowych warunkach pomiarowych.

Łatwa obsługa systemów tomograficznych jest kolejnym ważnym aspektem, który zadecyduje o ich powszechnym stosowaniu. Intuicyjne interfejsy użytkownika oraz automatyzacja procesu pomiarowego przyczynią się do zwiększenia dostępności tej technologii dla szerokiego grona użytkowników, w tym inżynierów budowlanych i konserwatorów zabytków.

Trwałość i niezawodność urządzeń wchodzących w skład systemu ETI to kolejne kryterium, które musi być spełnione, aby technologia ta mogła być stosowana w praktyce. Systemy tomograficzne muszą być odporne na warunki środowiskowe panujące na placach budowy oraz wykazywać niezawodność podczas długotrwałego użytkowania w trudnych warunkach pogodowych.

Innym wymogiem są niewielkie rozmiary i niska masa systemów tomograficznych. W tym wypadku chodzi o możliwość transportu tomografu za pomocą samochodu osobowego. Mobilność urządzeń sprawi, że przedsiębiorstwa wykorzystujące tomografy wilgotnościowe w celach komercyjnych będą w stanie świadczyć usługi ETI z dojazdem do klienta. Ta cecha ma zasadnicze znaczenie z uwagi na konkurencyjność i ekonomikę prowadzenia biznesu.

Ostatnim, lecz nie mniej ważnym, kryterium są niskie koszty zakupu i konserwacji systemów ETI. Niskie koszty, wysoka rentowność usług i opłacalność korzystania z tej technologii zadecyduje o jej upowszechnieniu, szczególnie w sektorze budowlanym, gdzie budżety przeznaczone na monitoring i diagnostykę są ściśle nadzorowane.

Aby spełnić powyższe warunki, konieczne są dalsze badania, które skoncentrują się na rozwoju technologii pomiarowej, algorytmów przetwarzania danych oraz optymalizacji kosztów produkcji i eksploatacji systemów ETI. Interdyscyplinarne podejście oraz ścisła współpraca naukowców, inżynierów i praktyków

umożliwi rozpowszechnienie elektrycznej tomografii impedancyjnej jako metody diagnostycznej wykorzystywanej do monitoringu i obrazowania rozkładów wilgoci w murach.

Zainteresowania naukowe autora koncentrują się na rozwoju algorytmów opartych na uczeniu maszynowym, umożliwiających efektywne przetwarzanie danych. Tego rodzaju algorytmy, mają szczególne znaczenie w poszukiwaniach optymalnych rozwiązań problemu odwrotnego, który ma fundamentalne znaczenie w tomografii. W związku z powyższym przyszłe badania będą skoncentrowane na poszukiwaniu nowych metod algorytmicznych opartych na uczeniu maszynowym i metodach sztucznej inteligencji, które umożliwią zwiększenie rozdzielczości i wierności obrazowania rekonstrukcji tomograficznych.

Literatura

- [1] Adler A, Lionheart WRB (2006) Uses and abuses of EIDORS: an extensible software base for EIT. *Physiol Meas* 27:S25–S42. doi: 10.1088/0967-3334/27/5/S03.
- [2] Andersen B, Frisvad JC, Dunn RR, Thrane U (2021) A pilot study on baseline fungi and moisture indicator fungi in danish homes. *Journal of Fungi* 7:1–20. doi: 10.3390/jof7020071.
- [3] Bera TK (2018) Applications of Electrical Impedance Tomography (EIT): A Short Review. *IOP Conf Ser Mater Sci Eng* 331:012004. doi: 10.1088/1757-899X/331/1/012004.
- [4] Bianchessi A, Akamine RH, Duran GC, Tanabi N, Sato AK, Martins TC, Tsuzuki MSG (2020) Electrical Impedance Tomography Image Reconstruction Based on Neural Networks. *IFAC-PapersOnLine* 53:15946–15951. doi: 10.1016/J. IFACOL.2020.12.360.
- [5] Borsoi RA, Aya JCC, Costa GH, Bermudez JCM (2018) Super-resolution reconstruction of electrical impedance tomography images. *Computers & Electrical Engineering* 69:1–13. doi: 10.1016/J.COMPELECENG.2018.05.013.
- [6] Burger M, Lucka F (2014) Maximum a posteriori estimates in linear inverse problems with log-concave priors are proper Bayes estimators. *Inverse Probl* 30. doi: 10.1088/0266-5611/30/11/114004.
- [7] Cacciotti R, Valach J, Wolf B (2018) Innovative and easy-to-implement moisture monitoring system for brick units. *Constr Build Mater* 186:598–614. doi: 10.1016/j.conbuildmat.2018.07.125.
- [8] Camino MS, León FJ, Llorente A, Olivar JM Evaluation of the behavior of brick tile masonry and mortar due to capillary rise of moisture. *Materiales De Construccion* 64:20. doi: 10.3989/mc.2014.02513.

- [9] Chen X, Wang Z, Zhang X, Fu R, Wang D, Zhang M, Wang H (2021) Deep Auto-encoder Imaging Method for Electrical Impedance Tomography. *IEEE Trans Instrum Meas* 70:1–15. doi: 10.1109/TIM.2021.3094834.
- [10] Chen Y, Dong F, Tan C (2022) Space-constrained optimized Tikhonov regularization method for 3D hemorrhage reconstruction by open magnetic induction tomography. *Phys Med Biol* 67:225012. doi: 10.1088/1361-6560/AC9E42.
- [11] Chen Z, Yang Y, Jia J, Bagnaninchi P (2020) Deep learning based cell imaging with electrical impedance tomography. *I2MTC 2020 – International Instrumentation and Measurement Technology Conference, Proceedings*. doi: 10.1109/I2MTC43012.2020.9128764.
- [12] Coxson A, Mihov I, Wang Z, Avramov V, Barnes FB, Slizovskiy S, Mullan C, Timokhin I, Sanderson D, Kretinin A, Yang Q, Lionheart WRB, Mishchenko A (2022) Machine learning enhanced electrical impedance tomography for 2D materials. *Inverse Probl* 38:085007. doi: 10.1088/1361-6420/AC7743.
- [13] Csáji B (2001) Approximation with artificial neural networks. MSc thesis. doi: 10.1.1.101.2647.
- [14] Cuadra MB, Cammoun L, Butz T, Cuisenaire O, Thiran JP (2005) Comparison and validation of tissue modelization and statistical classification methods in T1-weighted MR brain images. *IEEE Trans Med Imaging* 24. doi: 10.1109/TMI.2005.857652.
- [15] Dai H, Penwarden M, Kirby RM, Joshi S (2023) Neural Operator Learning for Ultrasound Tomography Inversion.
- [16] D’Ayala D, Aktas YD (2016) Moisture dynamics in the masonry fabric of historic buildings subjected to wind-driven rain and flooding. *Build Environ* 104:208–220. doi: 10.1016/j.buildenv.2016.05.015.
- [17] Deabes WA, Abdelrahman MA (2009) Solution of the forward problem of Electric Capacitance Tomography of conductive materials. In: *WMSCI 2009 – The 13th World Multi-Conference on Systemics, Cybernetics and Informatics, Jointly with the 15th International Conference on Information Systems Analysis and Synthesis, ISAS 2009 – Proc*.
- [18] Demidenko E (2011) An analytic solution to the homogeneous EIT problem on the 2D disk and its application to estimation of electrode contact impedances. *Physiol Meas* 32:1453. doi: 10.1088/0967-3334/32/9/008.
- [19] Demidenko E, Hartov A, Paulsen K (2004) Statistical estimation of resistance/conductance by electrical impedance tomography measurements. *IEEE Trans Med Imaging* 23:829–838. doi: 10.1109/TMI.2004.827965.
- [20] Efron B, Hastie T, Johnstone I, Tibshirani R, Ishwaran H, Knight K, Loubes JM, Massart P, Madigan D, Ridgeway G, Rosset S, Zhu JI, Stine RA, Turlach BA, Weisberg S, Johnstone I (2004) Least angle regression. *Ann Stat* 32. doi: 10.1214/009053604000000067.
- [21] Faia PM, Silva R, Rasteiro MG, Garcia FAP, Ferreira AR, Santos MJ, Santos JB, Coimbra AP (2012) Imaging particulate two-phase flow in liquid suspensions with electric impedance tomography. *Particulate Science and Technology* 30:329–342. doi: 10.1080/02726351.2011.575444.
- [22] Fan Y, Ying L (2020) Solving electrical impedance tomography with deep learning. *J Comput Phys* 404:109119. doi: 10.1016/J.JCP.2019.109119.

- [23] Farha M, Endarko (2017) Combined algorithm of total variation and Gauss-Newton for image reconstruction in two-dimensional Electrical Impedance Tomography (EIT). In: Proceedings – 2017 International Seminar on Sensor, Instrumentation, Measurement and Metrology: Innovation for the Advancement and Competitiveness of the Nation, ISSIMM 2017. Institute of Electrical and Electronics Engineers Inc., pp 37–41.
- [24] Fernández-Fuentes X, Mera D, Gómez A, Vidal-Franco I (2018) Towards a Fast and Accurate EIT Inverse Problem Solver: A Machine Learning Approach. *Electronics (Basel)* 7:422. doi: 10.3390/electronics7120422.
- [25] Filipowicz F, Rymarczyk T (2003) Tomografia impedancyjna, 1st ed. BEL Studio, Warszawa.
- [26] Freimanis R, Vaiskunaite R, Bezrucko T, Blumberga A (2019) In-situ moisture assessment in external walls of historic building using non-destructive methods. *Environmental and Climate Technologies* 23:122–134. doi: 10.2478/rtuect-2019-0009.
- [27] Gagliardi F, Lepore L, Meschini L, Ciotoli A, Cherubini N, Falconi L, Formenton D, Gandolfo G, Gorello E, Marzo GA, Mauro E, Pagliuca M, Roberti A (2024) Novel Applications of State-of-the-Art Gamma-Ray Imaging Technique: From Nuclear Decommissioning and Radioprotection to Radiological Characterization and Safeguards. *IEEE Trans Nucl Sci* 71. doi: 10.1109/TNS.2024.3373603.
- [28] Garbaa H, Jackowska-Strumillo L, Grudzien K, Romanowski A (2014) Neural network approach to ECT inverse problem solving for estimation of gravitational solids flow. In: 2014 Federated Conference on Computer Science and Information Systems, FedCSIS 2014.
- [29] Garde H (2020) Reconstruction of piecewise constant layered conductivities in electrical impedance tomography. *Communications in Partial Differential Equations* 45:1118–1133. doi: 10.1080/03605302.2020.1760884.
- [30] Garrido I, Solla M, Lagüela S, Fernández N (2020) Irt and gpr techniques for moisture detection and characterisation in buildings. *Sensors (Switzerland)* 20. doi: 10.3390/s20226421.
- [31] Gehre M, Jin B, Lu X (2013) An Analysis of Finite Element Approximation in Electrical Impedance Tomography. *Inverse Probl* 30. doi: 10.1088/0266-5611/30/4/045013.
- [32] Gentilini C, Franzoni E, Bandini S, Nobile L (2012) Effect of salt crystallisation on the shear behaviour of masonry walls: An experimental study. *Constr Build Mater* 37:181–189. doi: 10.1016/j.conbuildmat.2012.07.086.
- [33] Gjörv OE, Øystein V, El-Busaidy AHS (1977) Electrical Resistivity Of Concrete In The Oceans. Proceedings of the Annual Offshore Technology Conference 1977-May:581–588. doi: 10.4043/2803-MS.
- [34] Goetzke-Pala A, Hoła A, Sadowski Ł (2018) A non-destructive method of the evaluation of the moisture in saline brick walls using artificial neural networks. *Archives of Civil and Mechanical Engineering* 18:1729–1742. doi: 10.1016/j.acme.2018.07.004.
- [35] Goetzke-Pala A, Hoła J (2016) Influence of burnt clay brick salinity on moisture content evaluated by non-destructive electric methods. *Archives of Civil and Mechanical Engineering* 16:101–111. doi: 10.1016/j.acme.2015.08.001.

- [36] Gomes JC, Barbosa VAF, Ribeiro DE, de Souza RE, dos Santos WP (2020) Electrical impedance tomography image reconstruction based on backprojection and extreme learning machines. *Research on Biomedical Engineering* 36:399–410. doi: 10.1007/S42600-020-00079-3.
- [37] Gomes JC, Pereira JMS, de Santana MA, da Silva WWA, de Souza RE, dos Santos WP (2020) Electrical impedance tomography image reconstruction based on autoencoders and extreme learning machines. *Deep Learning for Data Analytics* 155–171. doi: 10.1016/B978-0-12-819764-6.00009-0.
- [38] González G, Kolehmainen V, Seppänen A (2017) Isotropic and anisotropic total variation regularization in electrical impedance tomography. *Computers and Mathematics with Applications*. doi: 10.1016/j.camwa.2017.05.004.
- [39] Gonzalez J, Yu W (2018) Non-linear system modeling using LSTM neural networks. *IFAC-PapersOnLine* 51:485–489. doi: 10.1016/j.ifacol.2018.07.326.
- [40] Gradeci K, Labonnote N, Time B, Köhler J (2018) A probabilistic-based methodology for predicting mould growth in façade constructions. *Build Environ* 128:33–45. doi: 10.1016/j.buildenv.2017.11.021.
- [41] Hamilton SJ, Hauptmann A (2018) Deep D-Bar: Real-Time Electrical Impedance Tomography Imaging With Deep Neural Networks. *IEEE Trans Med Imaging* 37:2367–2377. doi: 10.1109/TMI.2018.2828303.
- [42] Harriman L (2020) *Damp Buildings, Human Health and Ventilation Design*. Atlanta.
- [43] Hasan NI, Bhattacharjee A (2019) Deep Learning Approach to Cardiovascular Disease Classification Employing Modified ECG Signal from Empirical Mode Decomposition. *Biomed Signal Process Control* 52:128–140. doi: 10.1016/j.bspc.2019.04.005.
- [44] Hayman S (1999) The McCulloch-Pitts model. In: *IJCNN'99. International Joint Conference on Neural Networks. Proceedings (Cat. No.99CH36339)*. 6:4438–4439.
- [45] Hetmaniok E, Słota D, Zielonka A (2012) Application of swarm intelligence algorithms in solving the inverse heat conduction problem. In: *Computer Assisted Methods in Engineering and Science*.
- [46] Hochreiter S, Schmidhuber J (1997) Long Short-Term Memory. *Neural Comput* 9:1735–1780. doi: 10.1162/neco.1997.9.8.1735.
- [47] Hoła A (2015) Tests of the damp timber-framed construction of a historic church building. *International Review of Civil Engineering* 6:39–42. doi: 10.15866/irece.v6i2.6322.
- [48] Hoła A (2018) The moisture condition of the brick walls in the basements of a medieval monastery. In: *MATEC Web of Conferences*. EDP Sciences.
- [49] Hoła A (2020) Methodology for the in situ testing of the moisture content of brick walls: an example of application. *Archives of Civil and Mechanical Engineering* 20:3. doi: 10.1007/s43452-020-00120-3.
- [50] Hoła A, Matkowski Z, Hoła J (2017) Analysis of the Moisture Content of Masonry Walls in Historical Buildings Using the Basement of a Medieval Town Hall as an Example. *Procedia Eng* 172:363–368. doi: 10.1016/j.proeng.2017.02.041.
- [51] Hoła A, Sadowski Ł (2019) A method of the neural identification of the moisture content in brick walls of historic buildings on the basis of non-destructive tests. *Autom Constr* 106:102850. doi: 10.1016/J.AUTCON.2019.102850.

- [52] Hoła A, Sadowski Ł (2019) Non-destructive in situ identification of the moisture content in saline brick walls using artificial neural networks. In: Creative Construction Conference 2019. pp 77–82.
- [53] Hoła A, Sadowski Ł (2020) Verification of a Nondestructive Method for Assessing the Humidity of Saline Brick Walls in Historical Buildings. *Applied Sciences* 10:6926. doi: 10.3390/app10196926.
- [54] Hoła J, Matkowski Z, Schabowicz K, Sikora J, Nita K, Wójtowicz S (2012) Identification of moisture content in brick walls by means of impedance tomography. *COMPEL - The International Journal for Computation and Mathematics in Electrical and Electronic Engineering* 31:1774–1792. doi: 10.1108/03321641211267119.
- [55] Hrabuska R, Prauzek M, Venclikova M, Konecny J (2018) Image Reconstruction for Electrical Impedance Tomography: Experimental Comparison of Radial Basis Neural Network and Gauss – Newton Method. *IFAC-PapersOnLine* 51:438–443. doi: 10.1016/J.IFACOL.2018.07.114.
- [56] Hsieh CJ, Chang KW, Lin CJ, Keerthi SS, Sundararajan S (2008) A dual coordinate descent method for large-scale linear SVM. In: *Proceedings of the 25th International Conference on Machine Learning*.
- [57] Hyvönen N, Mustonen L (2018) Generalized linearization techniques in electrical impedance tomography. *Numer Math (Heidelb)* 140. doi: 10.1007/s00211-018-0959-1.
- [58] Jauhiainen J, Kuusela P, Seppanen A, Valkonen T (2020) Relaxed Gauss-Newton Methods with Applications to Electrical Impedance Tomography. *SIAM J Imaging Sci* 13:1415–1445. doi: 10.1137/20M1321711.
- [59] Jauhiainen J, Kuusela P, Seppanen A, Valkonen T (2020) Relaxed gauss-newton methods with applications to electrical impedance tomography. *SIAM J Imaging Sci* 13:1415–1445. doi: 10.1137/20M1321711.
- [60] Javaherian A, Lucka F, Cox BT (2020) Refraction-corrected ray-based inversion for three-dimensional ultrasound tomography of the breast. *Inverse Probl* 36:125010. doi: 10.1088/1361-6420/ABC0FC.
- [61] Jeon J, Chung W, Son H (2019) Magnetic Induction Tomography Using Magnetic Dipole and Lumped Parameter Model. *IEEE Access* 7. doi: 10.1109/ACCESS.2019.2919140.
- [62] Jin B, Maass P (2012) An analysis of electrical impedance tomography with applications to Tikhonov regularization. *ESAIM: Control, Optimisation and Calculus of Variations* 18:1027–1048. doi: 10.1051/cocv/2011193.
- [63] Kabanikhin SI (2008) Definitions and examples of inverse and ill-posed problems. *J Inverse Ill Posed Probl* 16:317–357. doi: 10.1515/JIIP.2008.019.
- [64] Klibanov M V., Li J, Zhang W (2019) Convexification of electrical impedance tomography with restricted Dirichlet-to-Neumann map data. *Inverse Probl* 35. doi: 10.1088/1361-6420/aafecd.
- [65] Kłosowski G, Hoła A, Rymarczyk T, Mazurek M, Niderla K, Rzemieniak M (2023) Using Machine Learning in Electrical Tomography for Building Energy Efficiency through Moisture Detection. *Energies (Basel)* 16. doi: 10.3390/en16041818.

- [66] Kłosowski G, Hoła A, Rymarczyk T, Mazurek M, Niderla K, Rzemieniak M (2023) Use of the double-stage LSTM network in electrical tomography for 3D wall moisture imaging. *Measurement (Lond)* 213. doi: 10.1016/j.measurement.2023.112741.
- [67] Kłosowski G, Hoła A, Rymarczyk T, Skowron Ł, Wołowicz T, Kowalski M (2021) The concept of using LSTM to detect moisture in brick walls by means of electrical impedance tomography. *Energies* 2021, 14:7617. doi: 10.3390/EN14227617.
- [68] Kłosowski G, Kulisz M (2022) Identification of surface defects using deep and transfer learning. *J Phys Conf Ser* 2408:012028. doi: 10.1088/1742-6596/2408/1/012028.
- [69] Kłosowski G, Maj M, Oleszek M (2023) Comparison of CNN and LSTM algorithms for solving the EIT inverse problem. *Przegląd Elektrotechniczny* 99:230–233. doi: 10.15199/48.2023.01.46.
- [70] Kłosowski G, Rymarczyk T (2017) Using neural networks and deep learning algorithms in electrical impedance tomography. *Informatyka Automatyka Pomiary w Gospodarce i Ochronie Środowiska* 7:99–102. doi: 10.5604/01.3001.0010.5226.
- [71] Kłosowski G, Rymarczyk T (2022) Ensemble learning for monitoring process in electrical impedance tomography. *International Journal of Applied Electromagnetics and Mechanics* 69:169–178. doi: 10.3233/JAE-210160.
- [72] Kłosowski G, Rymarczyk T (2022) Application of convolutional neural networks in wall moisture identification by EIT method. *Informatyka, Automatyka, Pomiary w Gospodarce i Ochronie Środowiska* 12:20–23. doi: 10.35784/IAPGOS.2883.
- [73] Kłosowski G, Rymarczyk T, Cieplak T, Niderla K, Skowron Ł (2020) Quality assessment of the neural algorithms on the example of EIT-UST hybrid tomography. *Sensors (Switzerland)* 20. doi: 10.3390/s20113324.
- [74] Kłosowski G, Rymarczyk T, Kowalski M (2021) Cyber-Physical System for Collecting Data on Moisture Inside the Walls of Buildings. In: *SenSys 2021 – Proceedings of the 2021 19th ACM Conference on Embedded Networked Sensor Systems*.
- [75] Kłosowski G, Rymarczyk T, Kozłowski E (2019) Tomographic image correction with noise reduction algorithms. *MATEC Web of Conferences* 252:09001. doi: 10.1051/mateconf/201925209001.
- [76] Kłosowski G, Rymarczyk T, Niderla K (2022) Use of the Two-Stage Neural System in Electrical Impedance Tomography for Imaging Moisture inside Walls. *SenSys 2022 – Proceedings of the 20th ACM Conference on Embedded Networked Sensor Systems* 861–862. doi: 10.1145/3560905.3568059.
- [77] Kłosowski G, Rymarczyk T, Niderla K, Kulisz M, Skowron Ł, Soleimani M (2023) Using an LSTM network to monitor industrial reactors using electrical capacitance and impedance tomography – a hybrid approach. *Eksploatacja i Niezawodność – Maintenance and Reliability* 25:2023. doi: 10.17531/EIN.2023.1.11.
- [78] Kłosowski G, Rymarczyk T, Niderla K, Rzemieniak M, Dmowski A, Maj M (2021) Comparison of Machine Learning Methods for Image Reconstruction Using the LSTM Classifier in Industrial Electrical Tomography. *Energies* 2021, 14:7269. doi: 10.3390/EN14217269.

- [79] Kłosowski G, Rymarczyk T, Wójcik D (2023) The use of an LSTM-based autoencoder for measurement denoising in process tomography. *International Journal of Applied Electromagnetics and Mechanics* 73. doi: 10.3233/JAE-230013.
- [80] Kłosowski G, Rymarczyk T, Wójcik D, Skowron S, Cieplak T, Adamkiewicz P (2020) The Use of Time-Frequency Moments as Inputs of LSTM Network for ECG Signal Classification. *Electronics (Basel)* 9:1452. doi: 10.3390/electronics9091452.
- [81] Kłosowski G, Rymarczyk T, Niderla K (2023) Improvement of Electrical Tomographic Imaging of Moisture by Mixing Machine Learning Models. In: 2023 International Interdisciplinary PhD Workshop, IIPhDW 2023.
- [82] Kotevski Z, Mitrevski P (2010) Experimental Comparison of PSNR and SSIM Metrics for Video Quality Estimation. *ICT Innovations 2009* 357–366. doi: 10.1007/978-3-642-10781-8_37.
- [83] Kozłowski E, Król K, Rymarczyk T (2022) Application of PCA with logistic regression in embankment drainage. *Przegląd Elektrotechniczny* 4:127–130. doi: 10.15199/48.2022.04.27.
- [84] Kozłowski E, Rymarczyk T, Cieplak T, Kłosowski G, Tchorzewski P (2019) Application of logistic regression to image reconstruction in EIT. In: 2019 International Interdisciplinary PhD Workshop (IIPhDW 2019). pp 80–83.
- [85] Kozłowski E, Rymarczyk T, Kłosowski G, Cieplak T (2020) Logistic regression in image reconstruction in electrical impedance tomography. *Przegląd Elektrotechniczny* 5:96. doi: 10.15199/48.2020.05.19.
- [86] Kulisz M, Kłosowski G, Rymarczyk T, Hoła A, Niderla K, Sikora J (2024) The use of the multi-sequential LSTM in electrical tomography for masonry wall moisture detection. *Measurement* 234:114860. doi: 10.1016/J.MEASUREMENT.2024.114860.
- [87] Kulisz M, Kujawska J, Aubakirova Z, Zhairbaeva G, Warowny T (2022) Prediction of the Compressive Strength of Environmentally Friendly Concrete Using Artificial Neural Network. *Applied Computer Science* 18. doi: 10.35784/acs-2022-29.
- [88] Langford J, Li L, Zhang T (2009) Sparse online learning via truncated gradient. In: *Advances in Neural Information Processing Systems 21 – Proceedings of the 2008 Conference*.
- [89] Lee Y, Nguyen V, Wang D (2016) On variable and grouped selections of the Elastic Net.
- [90] Li JB, Tang C, Dai M, Liu G, Shi XT, Yang B, Xu CH, Fu F, You FS, Tang MX, Dong XZ (2014) A new head phantom with realistic shape and spatially varying skull resistivity distribution. *IEEE Trans Biomed Eng* 61:254–263. doi: 10.1109/TBME.2013.2288133.
- [91] Li S, Zhang Q, Zheng G (2021) Image Reconstruction of Electrical Impedance Tomography Based on Deep Learning. 2021 International Applied Computational Electromagnetics Society Symposium, ACES-China 2021, Proceedings. doi: 10.23919/ACES-CHINA52398.2021.9581706.
- [92] Li T, Kao TJ, Isaacson D, Newell JC, Saulnier GJ (2013) Adaptive Kaczmarz method for image reconstruction in electrical impedance tomography. *Physiol Meas* 34:595–608. doi: 10.1088/0967-3334/34/6/595.

- [93] Liu D, Khambampati AK, Kim S, Kim KY (2015) Multi-phase flow monitoring with electrical impedance tomography using level set based method. *Nuclear Engineering and Design* 289:108–116. doi: 10.1016/J.NUCENGDDES.2015.04.023.
- [94] Liu H, Zhou J, Zheng Y, Jiang W, Zhang Y (2018) Fault diagnosis of rolling bearings with recurrent neural network-based autoencoders. *ISA Trans* 77:167–178. doi: 10.1016/J.ISATRA.2018.04.005.
- [95] Liu S, Jia J, Zhang YD, Yang Y (2018) Image Reconstruction in Electrical Impedance Tomography Based on Structure-Aware Sparse Bayesian Learning. In: *IEEE Transactions on Medical Imaging*. Institute of Electrical and Electronics Engineers Inc., pp 2090–2102.
- [96] Liu S, Wang H, Zhang X (2021) Video Decolorization Based on the CNN and LSTM Neural Network. *ACM Transactions on Multimedia Computing, Communications and Applications* 17. doi: 10.1145/3446619.
- [97] Liu S, Wu H, Huang Y, Yang Y, Jia J (2019) Accelerated Structure-Aware Sparse Bayesian Learning for Three-Dimensional Electrical Impedance Tomography. *IEEE Trans Industr Inform* 15:5033–5041. doi: 10.1109/tii.2019.2895469.
- [98] Liu X, Yao J, Zhao T, Obara H, Cui Y, Takei M (2018) Image Reconstruction under Contact Impedance Effect in Micro Electrical Impedance Tomography Sensors. *IEEE Trans Biomed Circuits Syst* 12:623–631. doi: 10.1109/TBCAS.2018.2816946.
- [99] Lopez-Arce P, Altamirano-Medina H, Berry J, Rovas D, Sarce F, Hodgson S (2020) Building moisture diagnosis: Processing, assessing and representation of environmental data for root cause analysis of mould growth. *Build Simul* 13:999–1008. doi: 10.1007/s12273-020-0680-8.
- [100] Lukić T, Lindblad J, Sladoje N (2011) Regularized image denoising based on spectral gradient optimization. *Inverse Probl* 27:085010. doi: 10.1088/0266-5611/27/8/085010.
- [101] MacDonald G, Godbout A, Gillcash B, Cairns S (2021) Volume-preserving Neural Networks. In: *Proceedings of the International Joint Conference on Neural Networks*.
- [102] Marashdeh Q, Warsito W, Fan LS, Teixeira FL (2006) Nonlinear forward problem solution for electrical capacitance tomography using feed-forward neural network. *IEEE Sens J* 6:441–448. doi: 10.1109/JSEN.2005.860316.
- [103] da Mata AMM, de Moura BF, Martins MF, Palma FHS, Ramos R (2021) Electrical conductivity effect on the performance evaluation of EIT systems: A review. *Measurement* 178:109401. doi: 10.1016/J.MEASUREMENT.2021.109401.
- [104] Mendell MJ, Macher | J M, Kumagai | K (2018) Measured moisture in buildings and adverse health effects: A review. *Indoor Air* 28:488–499. doi: 10.1111/ina.12464.
- [105] Mishra A, Sahoo UK, Maiti S (2022) Sparsity-enabled radio tomographic imaging using quantized received signal strength observations. *Digit Signal Process* 127:103576. doi: 10.1016/J.DSP.2022.103576.
- [106] Mueller JL, Siltanen S (2012) *Linear and Nonlinear Inverse Problems with Practical Applications*. SIAM, Philadelphia.
- [107] Mueller JL, Siltanen S (2020) The D-bar method for electrical impedance tomography-demystified. *Inverse Probl* 36.

- [108] Nagafune K, Watanabe S, Shioya H (2014) An evolutionary multi-criterion optimization approach utilizing the characteristics of strength distribution for sparse CT image reconstruction. 2014 Joint 7th International Conference on Soft Computing and Intelligent Systems, SCIS 2014 and 15th International Symposium on Advanced Intelligent Systems, ISIS 2014 353–358. doi: 10.1109/SCIS-ISIS.2014.7044771.
- [109] Porzuczek J (2019) Assessment of the Spatial Distribution of Moisture Content in Granular Material Using Electrical Impedance Tomography. *Sensors* 19:2807. doi: 10.3390/s19122807.
- [110] Poudel J, Lou Y, Anastasio MA (2019) A survey of computational frameworks for solving the acoustic inverse problem in three-dimensional photoacoustic computed tomography. *Phys Med Biol* 64:14TR01. doi: 10.1088/1361-6560/ab2017.
- [111] Qayyum A, Anwar SM, Awais M, Majid M (2017) Medical image retrieval using deep convolutional neural network. *Neurocomputing* 266:8–20. doi: 10.1016/J.NEUCOM.2017.05.025.
- [112] Raimondo M, Dondi M, Gardini D, Guarini G, Mazzanti F (2009) Predicting the initial rate of water absorption in clay bricks. *Constr Build Mater* 23:2623–2630. doi: 10.1016/j.conbuildmat.2009.01.009.
- [113] Ramirez A, Daily W, Binley A, LaBrecque D (1999) Electrical impedance tomography of known targets. *J Environ Eng Geophys* 4:11–26. doi: 10.4133/JEEG4.1.11.
- [114] Raskutti G, Wainwright MJ, Yu B (2014) Early stopping and non-parametric regression: An optimal data-dependent stopping rule. *Journal of Machine Learning Research* 15:335–366.
- [115] Romanowski A, Łuczak P, Grudzień K (2019) X-ray imaging analysis of silo flow parameters based on trace particles using targeted crowdsourcing. *Sensors (Switzerland)* 19. doi: 10.3390/s19153317.
- [116] Rumelhart DE, Hinton GE, Williams RJ (1986) Learning internal representations by error propagation. *Readings in Cognitive Science: A Perspective from Psychology and Artificial Intelligence* 399–421. doi: 10.1016/B978-1-4832-1446-7.50035-2.
- [117] Rymarczyk T (2012) Characterization of the shape of unknown objects by inverse numerical methods. *Przegląd Elektrotechniczny* 88:138–140.
- [118] Rymarczyk T (2017) TOPOLOGICAL ALGORITHMS TO SOLVE INVERSE PROBLEM IN ELECTRICAL TOMOGRAPHY. *Informatics, Control, Measurement in Economy and Environment Protection* 7:55–58. doi: 10.5604/01.3001.0010.4583.
- [119] Rymarczyk T (2019) *Tomographic imaging in environmental, industrial and medical applications*, 1st ed. Wydawnictwo Naukowe Innovatio Press, Lublin.
- [120] Rymarczyk T, Kłosowski G (2018) The use of a neural controller in masonry tomography. In: 2018 International Interdisciplinary PhD Workshop (IIPhDW). IEEE, pp 172–176.
- [121] Rymarczyk T, Kłosowski G (2019) EIT detection methods of damage in landfills and flood embankments. *Przegląd Elektrotechniczny* 95. doi: 10.15199/48.2019.05.13.
- [122] Rymarczyk T, Kłosowski G (2019) The use of elastic net and neural networks in industrial process tomography. *Przegląd Elektrotechniczny* 95:59–62. doi: 10.15199/48.2019.05.15.

- [123] Rymarczyk T, Kłosowski G, Cieplak T, Kozłowski E (2018) Application of a neural EIT system to control the processes. In: 2018 Applications of Electromagnetics in Modern Techniques and Medicine, PTZE 2018.
- [124] Rymarczyk T, Kłosowski G, Cieplak T, Kozłowski E (2019) Industrial processes control with the use of a neural tomographic algorithm. *Przegląd Elektrotechniczny* 95. doi: 10.15199/48.2019.02.22.
- [125] Rymarczyk T, Kłosowski G, Cieplak T, Kozłowski E, Kania K (2019) Application of a regressive neural network with autoencoder for monochromatic images in ultrasound tomography. In: 2019 Applications of Electromagnetics in Modern Engineering and Medicine, PTZE 2019. Janow Podlaski, Poland, pp 156–160.
- [126] Rymarczyk T, Kłosowski G, Hoła A, Hoła J, Sikora J, Tchórzewski P, Skowron Ł (2021) Historical buildings dampness analysis using electrical tomography and machine learning algorithms. *Energies (Basel)* 14. doi: 10.3390/EN14051307.
- [127] Rymarczyk T, Kłosowski G, Hoła A, Sikora J, Tchórzewski P, Skowron Ł (2022) Optimising the use of machine learning algorithms in electrical tomography of building walls: pixel oriented ensemble approach. *Measurement* 188:110581. doi: 10.1016/J.MEASUREMENT.2021.110581.
- [128] Rymarczyk T, Kłosowski G, Hoła A, Sikora J, Wołowicz T, Tchórzewski P, Skowron S (2021) Comparison of Machine Learning Methods in Electrical Tomography for Detecting Moisture in Building Walls. *Energies (Basel)* 14:2777. doi: 10.3390/en14102777.
- [129] Rymarczyk T, Kłosowski G, Kozłowski E (2018) A Non-Destructive System Based on Electrical Tomography and Machine Learning to Analyze the Moisture of Buildings. *Sensors* 2018, 18:2285. doi: 10.3390/S18072285.
- [130] Rymarczyk T, Kłosowski G, Kozłowski E (2018) A Non-Destructive System Based on Electrical Tomography and Machine Learning to Analyze the Moisture of Buildings. *Sensors* 18:2285. doi: 10.3390/s18072285.
- [131] Rymarczyk T, Kłosowski G, Gola A (2019) The use of artificial neural networks in tomographic reconstruction of soil embankments. *Advances in Intelligent Systems and Computing* 801:104–112.
- [132] Rymarczyk T, Kozłowski E, Kłosowski G (2020) Electrical impedance tomography in 3D flood embankments testing – elastic net approach. *Transactions of the Institute of Measurement and Control* 42:680–690. doi: 10.1177/0142331219857374.
- [133] Rymarczyk T, Kozłowski E, Kłosowski G, Adamkiewicz P (2018) Implementation of the LARS method to solve the inverse problem in electrical tomography. *Przegląd Elektrotechniczny* 94:146–149. doi: 10.15199/48.2018.12.31.
- [134] Rymarczyk T, Kozłowski E, Kłosowski G, Niderla K (2019) Logistic Regression for Machine Learning in Process Tomography. *Sensors* 19:3400. doi: 10.3390/S19153400.
- [135] Rymarczyk T, Kozłowski E, Kłosowski G, Rymarczyk P, Adamkiewicz P, Sikora J (2018) Elastic net method in the image reconstruction infiltration of water in the embankment. In: *Applications of Electromagnetics in Modern Techniques and Medicine (PTZE)*, pp 212–215.
- [136] Rymarczyk T, Oleszek M, Szumowski J, Tchórzewski P, Adamkiewicz P, Sikora J (2018) A hybrid tomography system for the analysis of wall dampness. In: 2018

- Applications of Electromagnetics in Modern Techniques and Medicine, PTZE 2018. Institute of Electrical and Electronics Engineers Inc., pp 220–223.
- [137] Rymarczyk T, Sikora J, Tchórzewski P (2018) Implementation of electrical impedance tomography for analysis of building moisture conditions. *COMPEL – The international journal for computation and mathematics in electrical and electronic engineering* 37:1837–1861. doi: 10.1108/COMPEL-01-2018-0034.
- [138] Rymarczyk T, Szulc K (2017) Reconstruction of conductivity distribution in electrical impedance tomography by topological derivative. 2017 18th International Symposium on Electromagnetic Fields in Mechatronics, Electrical and Electronic Engineering (ISEF) Book of Abstracts 1–2. doi: 10.1109/ISEF.2017.8090755.
- [139] Rymarczyk T, Tchórzewski P (2019) Analysis of historical wall dampness using electrical tomography measuring system. *International Journal of Applied Electromagnetics and Mechanics* 59:1257–1265. doi: 10.3233/JAE-171151.
- [140] Rząsa M (2022) Zastosowanie pojemnościowych metod pomiarowych w badaniu przepływów dwufazowych. Cz. 2, Metody pomiarowe. Oficyna Wydawnicza Politechnika Opolska, Opole.
- [141] Rząsa MR (2014) Selection of optical tomography parameters for gas bubble shape analysis. *Chemical and Process Engineering – Inżynieria Chemiczna i Procesowa* 35:19–33. doi: 10.2478/CPE-2014-0002.
- [142] Schmidhuber J (2015) Deep Learning in neural networks: An overview. *Neural Networks* 61:85–117. doi: 10.1016/j.neunet.2014.09.003.
- [143] Shaaban AM (2022) A review article: isogeometric boundary element analysis in engineering applications. *International Journal of Hydromechanics* 5. doi: 10.1504/ijhm.2022.127039.
- [144] Shahdoosti HR, Rahemi Z (2019) Edge-preserving image denoising using a deep convolutional neural network. *Signal Processing* 159:20–32. doi: 10.1016/j.sigpro.2019.01.017.
- [145] Shalev-Shwartz S, Singer Y, Srebro N, Cotter A (2011) Pegasos: Primal estimated sub-gradient solver for SVM. *Math Program* 127. doi: 10.1007/s10107-010-0420-4.
- [146] Shan H, Wiedeman C, Wang G, Yang Y (2019) Simultaneous reconstruction of the initial pressure and sound speed in photoacoustic tomography using a deep-learning approach. 4. doi: 10.1117/12.2529984.
- [147] Shi Y, Zhang Y, Wang M, Lou Y, Zheng S (2023) Reconstruction of conductivity distribution variation with Tikhonov and wavelet frame combined method for electrical impedance tomography. *Transactions of the Institute of Measurement and Control* 45:014233122311592–014233122311592. doi: 10.1177/01423312231159216.
- [148] Smyl D, Hallaji M, Seppänen A, Pour-Ghaz M (2016) Quantitative electrical imaging of three-dimensional moisture flow in cement-based materials. *Int J Heat Mass Transf* 103:1348–1358. doi: 10.1016/J.IJHEATMASSTRANSFER.2016.08.039.
- [149] Soleimani M, Rymarczyk T (2023) Ultrasound Tomography for Lung Imaging: An Experimental Phantom Study. *IEEE Sens J* 23. doi: 10.1109/JSEN.2023.3252340.

- [150] Strobel GS, Mu Z, Wexler A (2017) Remote sensing water content in a clay / sand mixture using Impedance Computed Tomography. 1992 Symposium on Antenna Technology and Applied Electromagnetics 689–695. doi: 10.1109/ANTEM.1992.7854304.
- [151] Styła M, Kiczek B, Kłosowski G, Rymarczyk T, Adamkiewicz P, Wójcik D, Cieplak T (2023) Machine Learning-Enhanced Radio Tomographic Device for Energy Optimization in Smart Buildings. *Energies (Basel)* 16. doi: 10.3390/en16010275.
- [152] Tan J, Guo X, Wang G (2019) Link selection in radio tomographic imaging with backprojection transformation. *Lecture Notes in Electrical Engineering* 529:487–496. doi: 10.1007/978-981-13-2291-4_48/COVER/.
- [153] Tang H, Xu C, Han X (2022) Electrical resistance tomography image reconstruction based on one-dimensional multi-branch convolutional neural network combined with attention mechanism. *Flow Measurement and Instrumentation* 84:102140. doi: 10.1016/J.FLOWMEASINST.2022.102140.
- [154] Tibshirani R (1996) Regression Shrinkage and Selection via the Lasso. *Journal of the Royal Statistical Society Series B (Methodological)* 58:267–288.
- [155] Viswanath M, Seetharaman R, Nedumaran D (2019) Electrical Impedance Tomography – Differential Solutions. 2019 IEEE 5th Global Electromagnetic Compatibility Conference (GEMCCON) 1–5. doi: 10.1109/GEMCCON48223.2019.9132819.
- [156] Wang M, Zheng S, Shi Y, Lou Y (2022) Hybrid method for improving Tikhonov-based reconstruction quality in electrical impedance tomography. *Journal of medical imaging* 9. doi: 10.1117/1.JMI.9.5.054503.
- [157] Wang Q, Zhang H, Li X, Duan X, Wang J, Zhang R, Zhang H, Ma Y, Wang H, Jia J (2022) Error-Constraint Deep Learning Scheme for Electrical Impedance Tomography (EIT). *IEEE Trans Instrum Meas* 71. doi: 10.1109/TIM.2021.3135327.
- [158] Wang R, Miao L, Ma Y (2013) A gradient method used to identify object boundary in EIT image. IST 2013 – 2013 IEEE International Conference on Imaging Systems and Techniques, Proceedings 381–385. doi: 10.1109/IST.2013.6729726.
- [159] Wang W, Zhang P, Yang D, Xue S (2023) Imaging of unsaturated moisture flow inside cracked porous brick using electrical capacitance volume tomography. *Journal of Building Engineering* 64:105626. doi: 10.1016/J.JOBE.2022.105626.
- [160] Wang W, Zhao K, Zhang P, Bao J, Xue S (2021) Application of three self-developed ECT sensors for monitoring the moisture content in sand and mortar. *Constr Build Mater* 267. doi: 10.1016/j.conbuildmat.2020.121008.
- [161] Wang Z, Bovik AC (2009) Mean squared error: Lot it or leave it? A new look at signal fidelity measures. *IEEE Signal Process Mag* 26:98–117. doi: 10.1109/MSP.2008.930649.
- [162] Wu XJ, Xu M Da, Li C Di, Ju C, Zhao Q, Liu SX (2021) Research on image reconstruction algorithms based on autoencoder neural network of Restricted Boltzmann Machine (RBM). *Flow Measurement and Instrumentation* 80:102009. doi: 10.1016/J.FLOWMEASINST.2021.102009.

- [163] Yang Y, Wu S (2024) Industrial CT Truncated Projection Data Reconstruction System Based on Artificial Intelligence. In: 2024 2nd International Conference on Signal Processing and Intelligent Computing (SPIC). pp 1151–1157.
- [164] You S, Li W, Ye T, Hu F, Zheng W (2017) Study on moisture condensation on the interior surface of buildings in high humidity climate. *Build Environ* 125:39–48. doi: 10.1016/j.buildenv.2017.08.041.
- [165] Zeng X, Leung MR, Zeev-Ben-Mordehai T, Xu M (2018) A convolutional autoencoder approach for mining features in cellular electron cryo-tomograms and weakly supervised coarse segmentation. *J Struct Biol* 202:150–160. doi: 10.1016/J.JSB.2017.12.015.
- [166] Zhang M, Ma Y, Huang N, Ge H (2022) Survey of EIT Image Reconstruction Algorithms. *J Shanghai Jiaotong Univ Sci* 27:211–218. doi: 10.1007/S12204-021-2333-1/METRICS.
- [167] Zhang Y, Wang X, Jin X, Wang A, Shi X, Zhou X, Fu X (2021) Moisture transfer characteristics of the wall with phase change material. *J Therm Anal Calorim* 1–10. doi: 10.1007/s10973-021-10598-5.
- [168] hao G, Hu J, He J, Wang SX (2020) A Novel Current Reconstruction Method Based on Elastic Net Regularization. *IEEE Trans Instrum Meas* 69:7484–7493. doi: 10.1109/TIM.2020.2984819.
- [169] Zihlmann M, Perekrestenko D, Tschannen M (2017) Convolutional recurrent neural networks for electrocardiogram classification. In: *Computing in Cardiology*. pp 1–4.
- [170] (2022) Electrical Impedance Tomography – Image Reconstruction using Population-based Optimisation Algorithms. doi: 10.21203/RS.3.RS-2343798/V1
- [171] (2023) Experimental Exploration of Evolutionary Algorithms and their Applications in Complex Problems: Genetic Algorithm and Particle Swarm Optimization Algorithm. *J Biomed Eng Med Imaging* 10. doi: 10.14738/BJHMR.102.14427.

