

dr inż. Tomasz Rymarczyk

Centrum Badawczo-Rozwojowe Nowoczesnych Technologii, Netrix S.A.
ul. Związkowa 26, 20-148 Lublin
Wyższa Szkoła Ekonomii i Innowacji w Lublinie
ul. Projektowa 4, 20-209 Lublin
E-mail: tomasz@rymarczyk.com

dr inż. Grzegorz Kłosowski

Politechnika Lubelska
Katedra Organizacji Przedsiębiorstwa na Wydziale Zarządzania
ul. Nadbystrzycka 38, 20-618 Lublin, Poland
E-mail: g.klosowski@pollub.pl

**Zastosowanie neuronowej rekonstrukcji obrazów tomograficznych
w problematyce niezawodności zabezpieczeń przeciwpowodziowych**

***Słowa kluczowe:** tomografia elektryczna, zapory i wały przeciwpowodziowe, eksploatacja budowli hydrotechnicznych, sieci neuronowe, metody numeryczne*

Streszczenie: W artykule zaprezentowano nowatorską koncepcję usprawnienia monitoringu wałów i zapór przeciwpowodziowych. Główną przewagą nowego rozwiązania nad znanymi metodami jest uzyskanie dokładniejszego rozkładu komponentów wnętrza zapory, co zasadniczo przyczynia się do wczesnego i niezawodnego wykrycia zagrożeń związanych z eksploatacją tego typu budowli. Dzięki temu, zastosowanie nowej metody spowoduje wzrost niezawodności zabezpieczeń przeciwpowodziowych. W opisywanej metodzie założono wytrenowanie systemu neuronowego, złożonego z wielu działających równolegle sieci neuronowych, z których każda generuje pojedynczy punkt obrazu wyjściowego. Powyższy sposób, uwzględniający jednoczesne zastosowanie wielu sieci neuronowych, umożliwia skuteczną realizację trudnych zagadnień rekonstrukcji obrazów dwu i trój-wymiarowych, w tym obrazowanie uszkodzeń i przecieków wnętrza zapór przeciwpowodziowych. Ważną zaletą prezentowanej metody jest możliwość zastąpienia obrazowaniem neuronowym wielu innych, obecnie stosowanych systemów, które monitorują budowle hydrotechniczne w sposób punktowy. Przeprowadzone badania umożliwiają rozwiązanie problemu niskiej rozdzielczości obrazów tomograficznych, co stanowi główną barierę rozwoju tych metod w odniesieniu do dużych budowli ziemnych. Poprawa rozdzielczości rekonstruowanych obrazów, a także możliwość ich uzyskiwania w różnych przekrojach w czasie rzeczywistym, są nowymi funkcjonalnościami, które wyróżniają obrazowanie neuronowe na tle obecnie stosowanych metod monitoringu wałów i zapór przeciwpowodziowych.

1. Wprowadzenie

Eksploatacja zabezpieczeń przeciwpowodziowych, takich jak wały przeciwpowodziowe i zapory wodne jest bardzo istotnym zagadnieniem wpływającym na

bezpieczeństwo ludzi, zwierząt i roślin znajdujących się w rejonie danego obiektu. Istnieją dwa podstawowe rodzaje problemów, jakie mogą wystąpić na skutek nieprawidłowej eksploatacji tam i zapór wodnych. Pierwszym, podstawowym zagrożeniem jest fizyczne uszkodzenie zapory, mogące doprowadzić do jej przerwania. Drugim rodzajem zagrożenia jest przesiąkanie zapory, co w przypadku zbiorników zawierających płynne odpady chemiczne może doprowadzić do różnego rodzaju skażeń. Przerwanie zapory może powodować następujące konsekwencje [25]:

- sprowadzenie zagrożenia dla życia ludzi i zwierząt oraz konieczność ewakuacji;
- zamknięcie urzędów administracji publicznej, szkół, szpitali;
- prawdopodobieństwo wystąpienia epidemii, epizootii lub epifitoz;
- możliwość wystąpienia plagi owadów i gryzoni;
- zniszczenie hodowli i zbiorów w gospodarstwach rolnych (osłabienie ekonomiczne przemysłu spożywczego, wzrost cen produktów żywnościowych, wypłata odszkodowań dla przedsiębiorców zajmujących się przetwarzaniem i sprzedażą żywności);
- zniszczenie i uszkodzenie budynków (mieszkalnych, gospodarczych, użyteczności publicznej);
- zniszczenia w infrastrukturze (m.in. drogi, mosty, wiadukty, tunele, wały przeciwpowodziowe, przepompownie, urządzenia hydrotechniczne, urządzenia i sieci kanalizacyjno-wodociągowe);
- zniszczenia w infrastrukturze wytwarzania, przesyłu lub dystrybucji energii elektrycznej i ciepłowniczej;
- zakłócenia funkcjonowania systemów łączności i systemów teleinformatycznych;
- zniszczenia lub uszkodzenia trakcji komunikacyjnych, awarie w zakładach przemysłowych;
- zakłócenia w funkcjonowaniu systemu dystrybucyjnego paliw;
- możliwy wzrost przestępczości o charakterze kryminalnym oraz zwiększona liczba przestępstw i wykroczeń pospolitych (kradzieże z włamaniem, rozboje, niszczenie mienia).

Przesiákanie odpadów chemicznych przez zapory stwarza z kolei takie zagrożenia, jak możliwość miejscowego skażenia środowiska naturalnego, a także uszkodzenia instalacji i urządzeń technicznych.

Powodzie zaliczane są do grupy katastrof naturalnych, które powodują wiele tragedii [3, 7]. Jednym ze sposobów zapewnienia bezpieczeństwa obszarów zalewowych w pobliżu składowisk odpadów flotacyjnych i rzek jest podnoszenie wysokości wałów przeciwpowodziowych [18]. Biorąc pod uwagę niewystarczającą zdolność filtracyjną nasypu, wysoki stan wody może powodować powstawanie przecieków, co skutkuje częściowym lub całkowitym zniszczeniem budowli hydrotechnicznej [19].

Z uwagi na poważne następstwa awarii, obiekty techniczne takie jak tamy, zapory wodne i inne zabezpieczenia przeciwpowodziowe wyposaża się w różnego rodzaju systemy, mające na celu zwiększenie stopnia ich niezawodności. Systemy eksploatacji tam i zapór obejmują zarówno odpowiednie środki obsługi jak również system działań eksploatacyjnych ujętych w formę ścisłych procedur i instrukcji. Instrukcje użytkowania budowli o przeznaczeniu hydrotechnicznym zawierają pewne treści, które można uznać za standardowe. Należą do nich między innymi zalecenia odnośnie częstości i sposobu dokonywania przeglądów, badań, pomiarów i kontroli stanu technicznego obiektu oraz wykaz elementów budowli hydrotechnicznej podlegających obserwacji wraz z listą parametrów, które powinny być

mierzone. Powyższe zapisy są dowodem na to, że stała obserwacja, monitoring i pomiary są kluczowymi elementami procesów eksploatacji tam i zapór przeciwpowodziowych.

W większości przypadków zabezpieczenia przeciwpowodziowe są rozległymi i złożonymi systemami. Składają się z wielu podsystemów, których prawidłowe funkcjonowanie wpływa na niezawodność tych obiektów. Do typowych podsystemów wchodzących w skład tam i zapór przeciwpowodziowych zaliczyć można systemy osłony hydrologicznej, systemy alarmowe, systemy energetyczne, mechaniczne systemy regulacji i przepływów wody oraz informatyczne systemy wspomaganie decyzji.

W celu zapewnienia skutecznego monitoringu wymienionych systemów należy użyć odpowiednich metod. Informatyczne systemy wspomaganie decyzji pełnią szczególną rolę, polegającą na integracji pozostałych systemów i automatyzacji procesu decyzyjnego. Automatyzacja polega na identyfikacji i prognozowaniu określonych zagrożeń wraz z podaniem prawdopodobieństwa ich wystąpienia. Ostateczne decyzje odnośnie reagowania na rezultaty monitoringu zawsze podejmuje człowiek. Poniżej wymieniono aktualnie stosowane metody monitoringu w odniesieniu do Obiektu Unieszkodliwiania Odpadów Wydobywczych (OUOW) Żelazny Most KGHM POLSKA MIEDŹ S.A., będącego największym obiektem hydrotechnicznym w kraju i jednym z największych tego typu obiektów na świecie. Stosowane tam metody monitoringu można podzielić na dwie grupy: metody związane z aktualnym zachowaniem się konstrukcji i jej niezawodnością oraz metody związane z oddziaływaniem obiektu na otaczające go środowisko naturalne.

Do pierwszej grupy zaliczyć można następujące metody monitoringu: wizualna ocena stanu technicznego (obserwacja bezpośrednia prowadzona przez pracowników), monitoring geodezyjny (wykrywanie deformacji konstrukcji poprzez pomiary ręczne za pomocą reperów i automatyczne za pomocą mikroluster), monitoring geotechniczny (wykrywanie anomalii w budowie geologicznej podłoża rodzimego zapory i zbiornika poprzez głębokie wiercenia i sondy wciskane), monitoring hydrogeologiczny (wykrywanie anomalii spowodowanych nasiąkaniem zapory poprzez obserwację ciśnień piezometrycznych w piezometrach zainstalowanych w masywie odpadów, na zaporach oraz bliskim i dalekim przedpołu), monitoring sejsmiczny (wykrywanie zaburzeń stateczności budowli za pomocą czujników akcelerometrycznych, które są wzbudzane każdorazowo, gdy zidentyfikują drgania o określonym poziomie), systemy informatyczne do analizy dużych zbiorów danych (Big Data).

Do grupy metod związanych z zapobieganiem niekorzystnemu wpływowi obiektu na otaczające go środowisko naturalne zaliczyć można monitoring hydrologiczny (wykrywanie przecieków) oraz monitoring chemiczny (wykrywanie skażenia okolicznych wód gruntowych).

Ogólnoświatowy trend jakim jest rozwój technik informacyjnych i komunikacyjnych znajduje odzwierciedlenie we wzroście znaczenia systemów informatycznych w obrębie systemów eksploatacyjnych zabezpieczeń przeciwpowodziowych. Rozbudowane układy pomiarowe dostarczają wielu danych pobranych z różnych punktów zapory. Jednym z głównych zadań systemów informatycznych instalowanych w obiektach hydrotechnicznych jest tworzenie modeli matematycznych w oparciu o dostarczane informacje. W obecnie stosowanych systemach informatycznych wykorzystuje się algorytmy realizujące różnorodne metody. Do metod deterministycznych zaliczyć można metodę Felleniusa, która umożliwia ocenę stopnia stabilności zapory, wykorzystując podział potencjalnej bryły osuwiskowej na bloki (pasy) pionowe. Metoda ta znana jest również pod nazwą metody Pettersona-Felleniusa lub metody szwedzkiej [4]. Przykładem metody ilościowej o charakterze statystycznym jest model HST (Hydrostatic-Season-Time – Hydrostatyczny-Sezonowy-Czasowy). Empiryczny model HST jest szeroko stosowany do analizy różnych typów danych pomiarowych na temat wałów przeciwpowodziowych, tam i zapór [6]. Kolejną grupą metod wykorzystywanych w celu poprawy niezawodności procesów eksploatacyjnych zapór przeciwpowodziowych są metody probabilistyczne. Przykładem jest metoda niezawodności pierwszego rzędu (FORM), za

pomocą której można zbadać tryb uszkodzenia wzdłużnego długiego nasypu składającego się z gleb homogenicznych [9]. W celu zwiększenia niezawodności budowli ziemnych można zastosować indeks niezawodności Hasofera-Linda, który może być wykorzystany także w połączeniu z metodą FORM [13]. Do metod stosowanych w procesach eksploatacyjnych należy również analiza harmoniczna [11].

Częstym problemem w przypadku zapór wodnych jest niedostateczna filtracja wody powodująca tzw. podciekanie. W literaturze można odnaleźć propozycje metod kalkulacji prawdopodobieństwa wystąpienia tego rodzaju zjawisk [15].

Kolejną grupą inteligentnych metod stochastycznych, wykorzystywanych przez systemy informatyczne w celu podniesienia poziomu niezawodności procesów eksploatacyjnych, w tym także w odniesieniu do tam i zapór wodnych, są metody heurystyczne oparte na logice rozmytej [14, 22, 24]. Do rzadziej stosowanych metod zwiększających poziom niezawodności i usprawniających procesy eksploatacyjne zapór wodnych należą: programowanie liniowe całkowitoliczbowe [10], Support Vector Machine [17], nieliniowe kryterium wytrzymałości na ścinanie [23], a także sztuczne sieci neuronowe [1, 8]. Obecnie głównym obszarem zastosowań ANN (sztuczne sieci neuronowe = Artificial Neural Networks) są zagadnienia predykcyjne, usprawniające procesy eksploatacyjne poprzez identyfikację [16] lub klasyfikację usterek [26].

Jak wcześniej wspomniano, zabezpieczenia przeciwpowodziowe należą do kategorii budowli hydrotechnicznych. Analiza procedur i zasad eksploatacji w odniesieniu do tego rodzaju obiektów pozwala zauważyć, że jednym z głównych procesów zapewniających prawidłową eksploatację jest obserwacja bieżącego zachowania i detekcja zjawisk, które z uwagi na swoją specyfikę, mogą wskazywać na nieprawidłowości zagrażające bezpieczeństwu budowli. Obecne metody monitoringu obiektów technicznych typu wały przeciwpowodziowe i zapory wodne mają jednak liczne wady. Pierwszą z nich są dość wysokie koszty użytkowania. Większość obecnie stosowanych metod wymaga bowiem zaangażowania specjalistów, przez co istotnym elementem kosztów jest robocizna. Prócz tego, wykorzystywane systemy pomiarowe wymagają nakładów na remonty, konserwacje, części zamienne i materiały, które się zużywają. Istotną wadą jest też zwykle zbyt późna informacja o zagrożeniu. W przypadku systemów, które nie są częścią zintegrowanych systemów informatycznych, informacja o zagrożeniu dociera do odpowiednich służb z kilkugodzinnym opóźnieniem. Opóźnienie jest zależne od częstotliwości, z jaką odbywają się ujęte w procedurach odczyty urządzeń pomiarowych. Niewystarczający jest też poziom skuteczności znanych metod monitoringu [4, 5]. Z powodu punktowego charakteru pomiarów istnieje duża niepewność formułowanych na ich podstawie wniosków. Sondy i czujniki umieszczane w różnych miejscach bryły zapory nie dają możliwości uzyskania pełnej wiedzy odnośnie aktualnego jej stanu. Istnieje poważne ryzyko, że pojawiające się wewnątrz zapory usterki (pęknięcia, zmiany struktury wewnętrznej, zmiany składu i gęstości ziemi itp.) nie zostaną wykryte na tyle wcześnie, by umożliwić ich skorygowanie. W celu uzyskania jak najpełniejszej wiedzy na temat stanu technicznego obiektu zachodzi konieczność jednoczesnego stosowania wielu metod monitoringu. W celu uproszczenia sposobu monitorowania obiektu oraz procedury wnioskowania istnieje wyraźna potrzeba opracowania jednej skutecznej metody, zapewniającej szybkość i niezawodność rejestracji, przesyłania i przetwarzania informacji o występujących zagrożeniach. Większość wymienionych wad zostałaby wyeliminowana, gdyby możliwe było opracowanie nowej metody umożliwiającej ocenę stanu technicznego budowli hydrotechnicznej, w sposób umożliwiający bieżącą detekcję różnic w strukturze wewnętrznej obiektu. Jedną z potencjalnych metod umożliwiających osiągnięcie tego celu jest tomografia elektryczna [2, 12]. Tomografia umożliwia wgląd we wnętrze badanego obiektu poprzez wygenerowanie jego obrazu. Metoda ta znajduje zastosowanie głównie w medycynie i inżynierii materiałowej. Podstawową barierą na drodze rozwoju metod tomograficznych w monitoringu wałów i zapór

przeciwpowodziowych jest brak odpowiedniej technologii, która zapewniłaby istotną poprawę rozdzielczości obrazu.

Niniejszy artykuł prezentuje nowe podejście do problemu eksploatacyjnego, związanego z monitorowaniem obiektów przy użyciu obrazowania neuronowego. Dotychczasowe próby użycia sztucznych sieci neuronowych w tomografii elektrycznej koncentrowały się na wykorzystaniu pojedynczych sieci neuronowych do przetwarzania sygnałów wejściowych na obrazy. W trakcie badań opracowano udoskonaloną metodę neuronowej rekonstrukcji tomograficznej, której cechą charakterystyczną jest zastosowanie systemu sieci neuronowych, w którym każda z sieci generuje kolor pojedynczego piksela na siatce obrazu. Dzięki oryginalnej architekturze inteligentnego systemu obrazowania uzyskano nową funkcjonalność w odniesieniu do znanych metod tomograficznych, polegającą na zwiększeniu rozdzielczości obrazów przekrojów skanowanych obiektów hydrotechnicznych.

2. Neuronowa rekonstrukcja obrazów tomograficznych

Prezentowana w niniejszym artykule neuronowa rekonstrukcja obrazów tomograficznych jest nową metodą mającą na celu zwiększenie rozdzielczości obrazów, a przez to podniesienie skuteczności monitoringu zabezpieczeń przeciwpowodziowych. Algorytm umożliwia wyeliminowanie głównych problemów eksploatacyjnych budowli hydrotechnicznych związanych z ich monitorowaniem. Tomografia wsparta systemem neuronowym daje nowe możliwości prowadzenia obserwacji. Zaprezentowana koncepcja, umożliwia uzyskanie dokładnego, trójwymiarowego obrazu wnętrza budowli hydrotechnicznej w czasie rzeczywistym. Jest to kluczowa funkcjonalność, dzięki której nie ma potrzeby utrzymywania większości dotychczasowych podsystemów monitoringu zabezpieczeń przeciwpowodziowych. Obecnie wykorzystywane systemy monitorujące (geodezyjny, geotechniczny, hydrologiczny itd.) umożliwiają zaledwie otrzymywanie danych punktowych dotyczących wybranych parametrów obiektu. Uzyskane w ten sposób niepełne informacje podlegają analizie, zarówno przez systemy informatyczne jak i przez specjalistów, którzy dokonują ostatecznej oceny stanu zapory. Taki proces oceny ma zasadnicze wady wynikające z punktowości pomiarów, błędów pomiarowych, braku monitoringu w czasie rzeczywistym oraz subiektywizmu w ocenach stanu przedmiotowego obiektu technicznego. Prezentowana w niniejszym artykule metoda jest wolna od powyższych ograniczeń, ponieważ umożliwia uzyskiwanie ostrych, kolorowych, trójwymiarowych obrazów wnętrza bryły zapory w wysokiej rozdzielczości w czasie rzeczywistym. Otrzymane obrazy są łatwe do analizy, ponieważ wiernie odwzorowują wszelkie zmiany zachodzące wewnątrz wałów przeciwpowodziowych i zapór wodnych. Zjawiska takie jak: pęknięcia, zmiany struktury warstw wewnętrznych, zawilgocenia, zmiany gęstości są natychmiast widoczne. Porównanie obrazów zarejestrowanych w równych odstępach czasu umożliwia dodatkowo skuteczne określenie tempa zachodzących zmian. Jest to bardzo cenna funkcjonalność, ponieważ daje solidne podstawy dokonywania dokładnych i wiarygodnych prognoz odnośnie źródeł, kierunków rozwoju, rodzaju i obszaru uszkodzeń rozwijających się wewnątrz budowli.


3. Modelowanie neuronowego systemu rekonstrukcji obrazów tomograficznych

Prezentowane rozwiązanie stanowi udoskonalenie znanej metody tomografii elektrycznej. W bryle wału przeciwpowodziowego umieszcza się pewną liczbę elektrod.

Następnie, do różnych elektrod podłączane jest źródło prądu elektrycznego o określonych parametrach (napięcie, natężenie, częstotliwość, amplituda). Wartości napięć pomiędzy odpowiednimi elektrodami są odczytywane i rejestrowane. Powyższe wartości napięć stanowią wektor wejściowy, na podstawie którego system neuronowy generuje obrazy wnętrza zapory wodnej. Zakłada się, że wartości odczytanych z elektrod parametrów elektrycznych są ściśle uzależnione od materiału, z którego składa się analizowane zabezpieczenie przeciwpowodziowe. Wszelkie zmiany struktury wewnętrznej zapory spowodowane zawilgoceniem, przeciekami, pęknięciem struktury, obsunięciem ziemi i wszelkimi innymi anomaliami, znajdują swoje odzwierciedlenie w wartościach parametrów prądowo-napięciowych odczytywanych z elektrod. Aby potwierdzić powyższe przypuszczenia opracowano mechanizm konwersji sygnałów elektrycznych na kolorowe obrazy o dużej rozdzielczości.

3.1. Sposób pozyskania danych

Rzeczywistym obiektem badań była zaporą Zbiornika Unieszkodliwiania Odpadów Wydobywczych Żelazny Most położonego w południowo-zachodniej części Polski pomiędzy Lubinem, a Głogowem. Zbiornik jest zlokalizowany w naturalnej dolinie między wzgórzami morenowymi w górnej partii zlewni rzeki Rudna. Zarządzającym obiektem unieszkodliwiania jest KGHM „Polska Miedź” S.A. Oddział Zakład Hydrotechniczny w Rudnej [21]. Obiekt Żelazny Most jest przeznaczony do składowania odpadów flotacyjnych z Zakładów Wzbogacania Rudy rejonu: Polkowice, Lubin i Rudna. Obecnie jest to jedyne miejsce deponowania odpadów z flotacji ze wszystkich kopalń. Ze względu na zajmowany teren, składowisko Żelazny Most jest jednym z największych tego typu obiektów na świecie [20]. Łączna długość zapór otaczających zbiornik wynosi ponad 14 km. Powierzchnia całkowita składowiska to 1410 ha. Wysokość zapór ograniczających w najwyższym miejscu sięga 55 m. Model topograficzny zbiornika Żelazny Most przedstawia rys.1.



Rys. 1. Model topologiczny Obiektu Unieszkodliwiania Odpadów Wydobywczych Żelazny Most


Obiekt wyposażono w różnorodne systemy diagnostyczne i kontrolno-pomiarowe, których zadaniem jest zapewnienie wysokiego stopnia niezawodności zbiornika Żelazny Most. Należą do nich: drenaże, układy do szybkiego i awaryjnego odwadniania akwenu, nasypy i studnie odciążające, których zadaniem jest obniżenie ciśnienia wody w gruntach podłoża. Wokół obiektu Żelazny Most na bieżąco prowadzone są obserwacje i badania monitorujące w odniesieniu do wód powierzchniowych i podziemnych. Niedoskonałością obecnie stosowanych metod monitoringu jest ich punktowość. Przy ich pomocy nie można uzyskać przekrojowych obrazów wnętrza zapory. Rys. 2 przedstawia zdjęcie ziemnego wału ochronnego zbiornika z

widocznymi elementami różnorodnych systemów pomiarowych, które dostarczają danych punktowych umożliwiającymi bieżący monitoring budowli.




Rys. 2. Powierzchnia wału ziemnego wokół zbiornika Żelazny Most

Kluczowym elementem neuronowego systemu rekonstrukcji obrazów tomograficznych jest sterownik neuronowy, którego zadaniem jest konwersja sygnałów elektrycznych na obrazy. Do wytrenowania systemu neuronowego potrzebny był odpowiedni zbiór danych uczących. Ze względu na to, że pobranie tego rodzaju danych bezpośrednio z zapory zbiornika Żelazny Most nie było możliwe, w warunkach laboratoryjnych opracowano model fizyczny fragmentu zapory, który odtwarzał badane cechy obiektu rzeczywistego, takie jak: materiał zapory, geometria kształtu, proporcje wymiarów, poziom wody w zbiorniku. W ten sposób pozyskano dane badawcze pochodzące z wielu przypadków pomiarowych. Dane obejmowały zbiory (wektory) wartości prądowo-napięciowych oraz odpowiadające tym zbiorom obrazy poprzecznych przekrojów zapory. Na rys. 3 przedstawiono model ziemny fragmentu wału ochronnego wraz z systemem EIT (Electrical Impedance Tomography), w skład którego wchodzi: układ elektrod, elektroniczny moduł rozdziału napięć na poszczególne elektrody oraz moduł rejestracji wyników. Szklane szyby terrarium umożliwiły obserwację zmian zachodzących w bryle wału ziemnego spowodowanych przesiąkaniem. Dzięki możliwości obserwacji wnętrza zapory ziemnej możliwe było zgromadzenie dużego zbioru danych, zawierających wektory parametrów elektrycznych oraz przyporządkowane tym wektorom obrazy.



Rys. 3. Model fizyczny zapory zbiornika Żelazny Most

W modelu zapory w linii prostej umieszczono 16 elektrod w taki sposób, aby swoim zasięgiem obejmowały całą szerokość obwałowania. Dzięki temu, umieszczając rzędy elektrod oddalonych od siebie w równych odległościach, można objąć systemem EIT całą długość zapory. Sposób rozmieszczenia rzędów elektrod w zaporze został zaprezentowany na rys. 4.




Rys. 4. Schemat wału przeciwpowodziowego z umieszczonymi w nim elektrodami

3.2. Koncepcja systemu neuronowego


Neuronowy system rekonstrukcji obrazów tomograficznych jest oryginalną koncepcją układu wielu sieci neuronowych, które uruchomione równolegle, generują obraz składający się z pojedynczych punktów. Każdy z punktów obrazu wyjściowego jest efektem działania niezależnej, osobno wytrenowanej sieci neuronowej. Za pomocą tej metody można generować zarówno obrazy dwuwymiarowe (2D) jak i trójwymiarowe (3D). Z punktu widzenia mechanizmu tworzenia obrazu wyjściowego, różnica pomiędzy obrazami 2D i 3D polega na ilości punktów składających się na pojedynczy obraz. W przypadku obrazów 3D punktów tych jest wielokrotnie więcej niż w przypadku obrazów 2D.

Jak już wcześniej wspomniano, rozpatrywany system EIT składał się z układu 16 elektrod, które w trakcie każdego pomiaru generowały wektor 208 spadków napięć. Pomiar

odczytywane dzięki umieszczonym w bryle zapory wodnej elektrodom, umożliwiły określenie konduktywności badanego obiektu, która jest zmienna w zależności od takich czynników jak np. zawilgocenie, niejednorodności struktury czy rodzaj gruntu. Obrazowany przekrój obwałowania został podzielony na siatkę pikseli, wygenerowaną jako elementy trójkątne za pomocą metody elementów skończonych. W przypadku obrazowania 2D siatka pikseli obrazu wyjściowego liczyła 2012 punktów, natomiast w przypadku obrazu trójwymiarowego zastosowano siatkę przestrzenną liczącą 17869 punktów. Pierwszy przypadek został zaprezentowany na rys. 5. W górnej części rysunku zaznaczono miejsca umieszczenia elektrod. Przypadek 3D został przedstawiony na rys. 6. Zagęszczenie punktów siatki wokół elektrod służy dokładniejszemu odwzorowaniu zmian zachodzących we wnętrzu obrazowanej zapory.



Rys. 5. Siatka obrazu wyjściowego 2D przekroju zapory licząca 2012 punktów




Rys. 6. Siatka obrazu wyjściowego 3D przekroju zapory licząca 17869 punktów


Na rys. 7 i 8 zaprezentowano sposób działania systemu neuronowego zamieniającego sygnały elektryczne pochodzące z elektrod, na obrazy 2D i 3D. Wektor wejściowy zawiera 208 przypadków pomiarowych (1). Każdy pojedynczy przypadek pomiarowy odpowiada pewnej wielkości spadku napięcia dla danej pary elektrod.

$$U = [\alpha_1, \alpha_2, \alpha_3, \dots, \alpha_{208}]^T \quad (1)$$

Wektor U jest wektorem wejściowym dla wszystkich sztucznych sieci neuronowych (ANN) wchodzących w skład systemu neuronowego.



Rys. 7. Matematyczny model neuronowy do konwersji sygnałów elektrycznych na obrazy 2D



Rys. 8. Matematyczny model neuronowy do konwersji sygnałów elektrycznych na obrazy 3D

Podczas projektowania modelu neuronowego oparto się na następujących założeniach:

1. Każdy punkt obrazu wyjściowego jest generowany przez odrębną sztuczną sieć neuronową, mającą na wejściu 208 wartości spadków napięć. Wyjście każdej z sieci neuronowych jest pojedynczą liczbą rzeczywistą odpowiadającą wartości konduktywności pojedynczego elementu rekonstruowanego obrazu (w postaci wizualnej przedstawianą poprzez odpowiedni kolor zakładanej skali konduktywności).
2. Zakłada się, że istnieje wzajemna zależność pomiędzy poszczególnymi punktami obrazu wyjściowego. W związku z tym, każda sieć neuronowa generująca wartość pojedynczego elementu obrazu, może być trenowana niezależnie, z losowo wygenerowanymi wagami początkowymi i biasem.
3. Sieci neuronowe przypisane do elementów obrazu wyjściowego mogą rozwiązywać zarówno zagadnienie klasyfikacyjne jak i regresyjne. W przypadku zagadnienia klasyfikacyjnego generowany obraz może być monochromatyczny lub posiadać kilka barw/odcieni. Wtedy klasyfikator przypisuje dany punkt do określonej barwy. Jeżeli sieć realizuje zagadnienie regresyjne, na wyjściu generowana jest liczba rzeczywista, odpowiadająca wartości konduktywności danego elementu. Taki rodzaj obrazowania jest najbardziej pożądanym, jednak ten układ sieci jest najtrudniej wytrenować. Systemy neuronowe opisywane w niniejszym opracowaniu realizują zagadnienia regresyjne.


W trakcie badań przeprowadzono wiele prób, uwzględniających różnorodne konfiguracje neuronowego perceptronu wielowarstwowego. W szczególności analizowano warianty, uwzględniające zmiany następujących czynników, mających wpływ na skuteczność działania systemu neuronowego: dobór algorytmu uczenia sieci, liczba warstw ukrytych i liczba neuronów w każdej z warstw sieci, parametry perceptronu (współczynnik uczenia, maksymalna liczba błędnych walidacji, momentum i inne). Analizowano także możliwość zastosowania nowych rozwiązań w zakresie konwolucyjnych sieci neuronowych (CNN – Convolutional Neural Networks). Rezultaty badań wykazały, że sieci CNN są w tym przypadku nieskuteczne z uwagi na zbyt małą liczbę danych wejściowych w porównaniu z dużą rozdzielczością obrazu wyjściowego.

Z uwagi na dużą liczbę danych oraz konieczność wytrenowania kilkunastu tysięcy sieci neuronowych (dla modelu 3D), realizacja ww. koncepcji wymagała zastosowania szybkich algorytmów uwzględniających obliczenia równoległe oraz komputerów o dużych mocach obliczeniowych.

3.3. Przebieg procesu trenowania wybranej sieci neuronowej

Poniżej zaprezentowano analizę procesu uczenia wybranej sieci neuronowej wchodzącej w skład systemu neuronowego do rekonstrukcji obrazu 2D. W tym przypadku, kompletny system neuronowy liczył 2012 osobno wytrenowanych sieci neuronowych. Z uwagi na dużą liczbę sieci, w niniejszym opracowaniu nie sposób zaprezentować przebiegu procesu uczenia wszystkich ANN.

Na rys. 9 zaprezentowano schemat zastosowanego modelu sieci neuronowej. Sieć ma 208 wejść, 10 neuronów w warstwie ukrytej i 1 neuron w warstwie wyjściowej. Warstwa ukryta wykorzystuje logistyczną funkcję transferową. W warstwie wyjściowej funkcja transferowa ma charakter liniowy.



Rys. 9. Model sieci neuronowej generującej pojedynczy punkt obrazu wyjściowego

W tabeli 1 zaprezentowano rezultaty uczenia jednej sieci neuronowej, wybranej losowo spośród systemu integrującego 2012 sieci. Prezentowana sieć generuje na wyjściu pojedynczy punkt obrazu wyjściowego. Łączna ilość przypadków wykorzystanych w procesie uczenia sieci wynosiła 10442. Wszystkie przypadki zostały losowo podzielone na 3 zbiory: uczący, walidacyjny i testowy w proporcjach: 70%, 15%, 15%. Zbiór walidacyjny jest wykorzystywany do ustalenia momentu zatrzymania procesu uczenia. Zakończenie procesu uczenia następuje w sytuacji, gdy dynamika zmiany gradientu zbliża się do zera. Zbiór testowy znajduje zastosowanie po zakończeniu uczenia. Służy on do weryfikacji jakości uzyskanej sieci.

Błąd MSE (Mean Squared Error) odzwierciedla średniokwadratową różnicę między wyjściami, a wielkościami wzorcowymi. Im niższe wartości MSE tym lepiej. Zerowy MSE oznacza brak błędu. Zbiór uczący obciążony został najniższym błędem uczenia, co jest sytuacją najczęściej spotykaną i prawidłową. Niski błąd MSE zbioru uczącego wynika z faktu najlepszego dostosowania wag sieci do przypadków uczących. Najwyższy błąd średniokwadratowy (MSE) o wartości $6.88341 \cdot 10^{-3}$ wystąpił w odniesieniu do zbioru testowego. Nieco mniejszy błąd MSE wynoszący $5.84343 \cdot 10^{-3}$ odnotowano dla zbioru walidacyjnego. Najmniejszy błąd odnotowano w odniesieniu do zbioru uczącego.

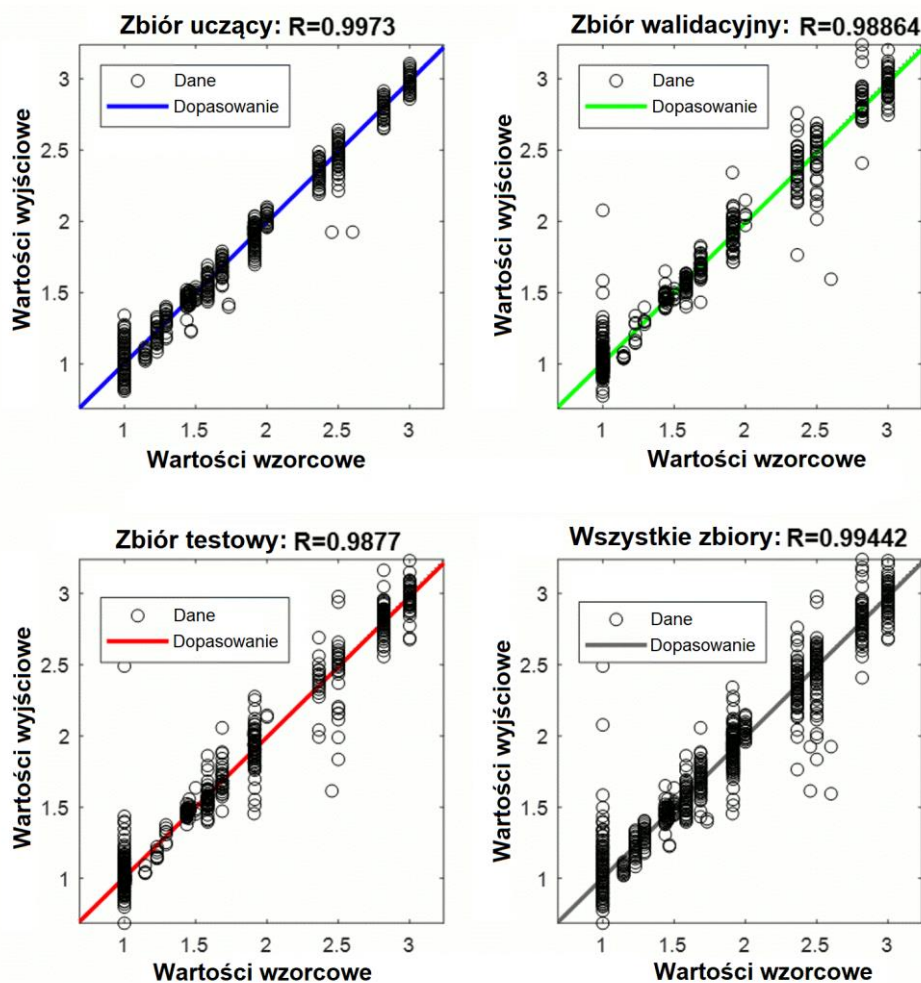
Innym badanym wskaźnikiem jakości sieci była regresja R. R=1 oznacza pełną zgodność wyjść z wzorcami, natomiast R=0 oznacza brak powiązań między nimi. Współczynnik regresji dla wszystkich trzech zbiorów był bardzo wysoki, bliski 1. Świadczy to o wysokiej zdolności sieci do generalizacji wiedzy (czyli prawidłowego przekształcania danych wejściowych na informacje wyjściowe nie tylko dla zbioru uczącego).

Tabela 1. Podział danych na zbiory i rezultaty procesu uczenia

Podział zbioru danych	Liczba przypadków w danym zbiorze	Błąd średniokwadratowy (MSE)	Regresja (R)
Zbiór uczący (70%)	7310	$1.35760 \cdot 10^{-3}$	0.997303
Zbiór walidacyjny (15%)	1566	$5.84343 \cdot 10^{-3}$	0.988642
Zbiór testowy (15%)	1566	$6.88341 \cdot 10^{-3}$	0.987701

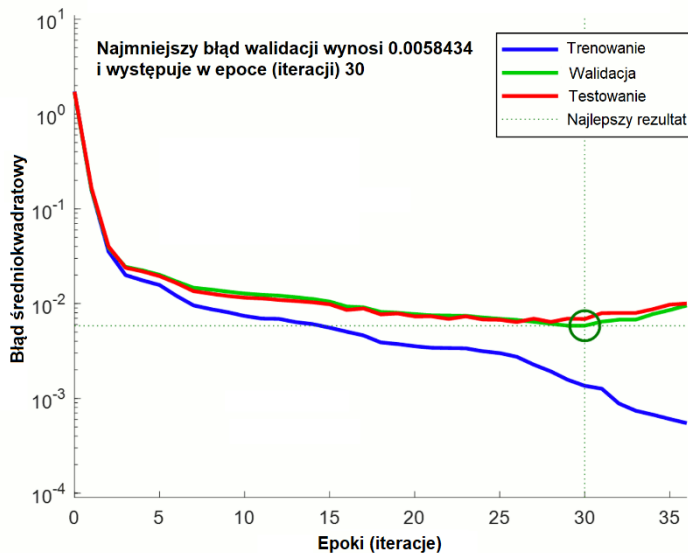
Rezultaty otrzymane w wyniku sprawdzenia sieci na zbiorze testowym są najbardziej miarodajnym wskaźnikiem świadczącym o efektywności danej sieci, ponieważ przypadki z tego zbioru nie uczestniczą w procesie uczenia. Dobre wskaźniki MSE i R dla zbioru testowego i walidacyjnego świadczą o braku przeuczenia.

Na rys. 10 zaprezentowano diagramy korelacyjne rozpatrywanej sieci. Jak widać rozrzut wyników wykraczających poza linie wzorcowe jest zauważalny, jednak ilość przypadków oddalonych od linii wzorcowej nie jest duża. Świadczą o tym nakładające się linie korelacji dla wszystkich badanych zbiorów: zbioru uczącego, walidacyjnego i testowego oraz łącznie (dla wszystkich trzech zbiorów).



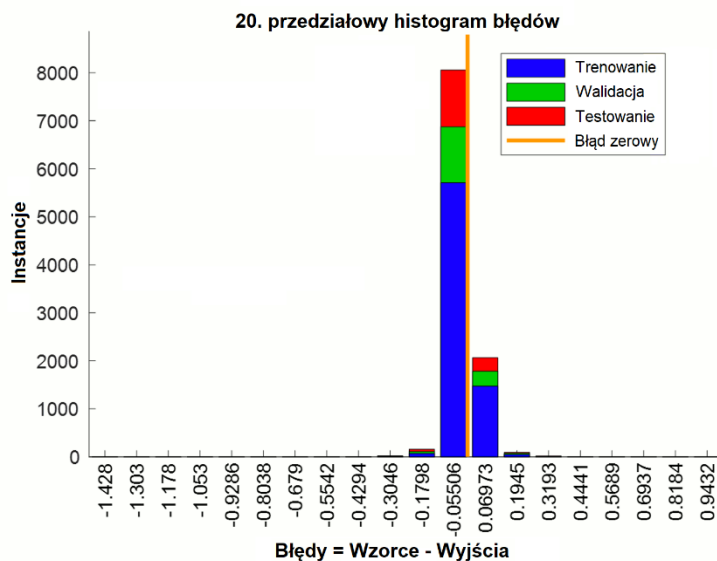
Rys. 10. Diagramy korelacyjne sieci neuronowej

Na rys. 11 zaprezentowano wykresy wartości błędu średniokwadratowego (MSE) zarejestrowane w trakcie procesu uczenia sieci. Wartości MSE są niskie. Stosunkowo regularne przebiegi linii wykresów (brak dużych fluktuacji) wskazują na brak przeuczenia, a tym samym na wysoką skuteczność opracowanego systemu tomograficznej rekonstrukcji obrazu. Hiperboliczny kształt krzywych wskazuje na wystarczającą liczbę przypadków uczących. Na wykresie zaznaczono trzydziestą epokę (iterację), na której zakończono uczenie sieci. Jest to epoka, w której błąd MSE zbioru walidacyjnego osiągnął swoje minimum.



Rys. 11. Wykresy błędów MSE dla zbiorów: uczącego, walidacyjnego i testowego

Na rys. 12 zaprezentowano histogram błędów (różnic) pomiędzy wartościami generowanymi przez sieć, a wzorcami. Każdy pionowy słupek wskazuje ilość odchyleń od wartości wzorcowej. Jak widać, największą liczbę odchyleń stanowią błędy bardzo małe, o wartościach zbliżonych do zera. Kształt histogramu przypomina krzywą rozkładu normalnego. Fakt ten również potwierdza wysoką jakość otrzymanego rozwiązania.



Rys. 12. Histogram błędów uczenia sieci

4. Rezultaty badań neuronowego systemu rekonstrukcji obrazów tomograficznych

W ramach prowadzonych prac badawczych opracowano dwa neuronowe modele systemów rekonstrukcji obrazów tomograficznych. Model pierwszy realizował zagadnienia obrazowania płaskiego (2D), natomiast model drugi generował obrazy 3D. W niniejszym rozdziale zaprezentowano efekty działania obu systemów neuronowych.

W tabeli 2a w dwóch kolumnach zestawiono wzorce i zrekonstruowane obrazy wygenerowane przez sterownik 2D. W tabeli 2b zaprezentowano graficzną reprezentację różnic wartości poszczególnych pikseli pomiędzy obrazami wzorcowymi i obrazami zrekonstruowanymi, przedstawionymi w tabeli 2a. Skala kolorystyczna na ilustracjach w tabeli 2b odzwierciedla różnice konduktywności pomiędzy elementami obrazów wzorcowych, a elementami obrazów zrekonstruowanych.

Tabela 2a. Rezultaty obrazowania w 2D

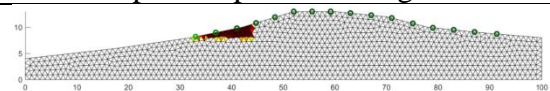
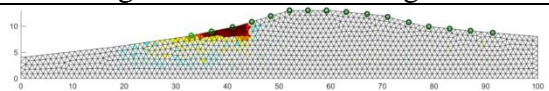
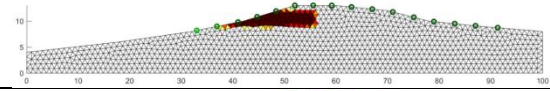
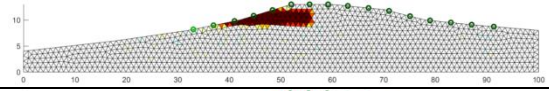
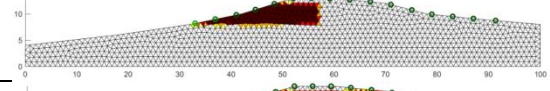
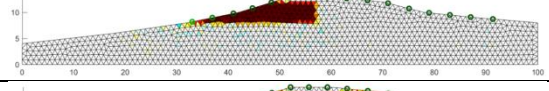
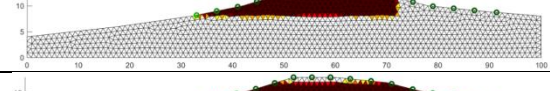
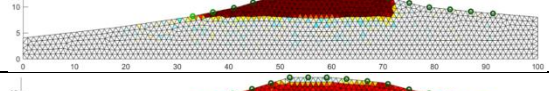
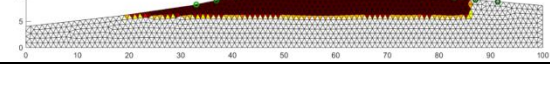
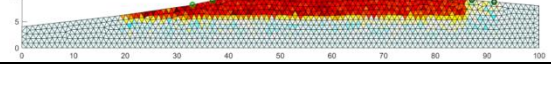
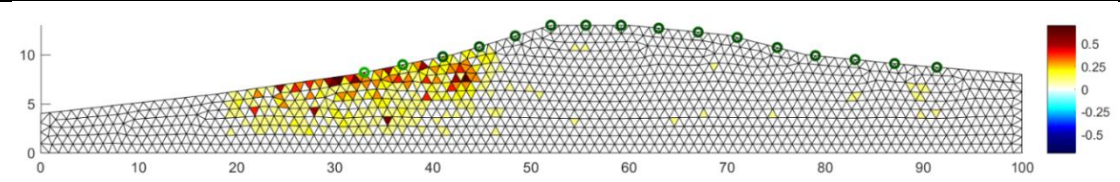
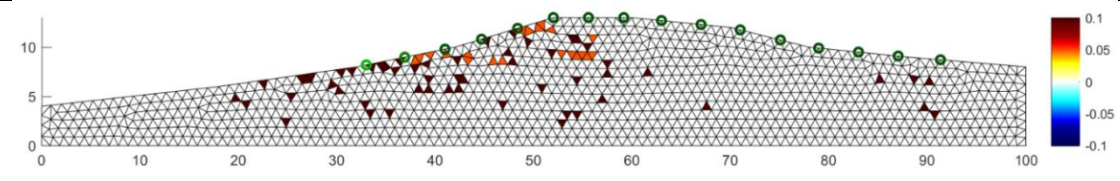
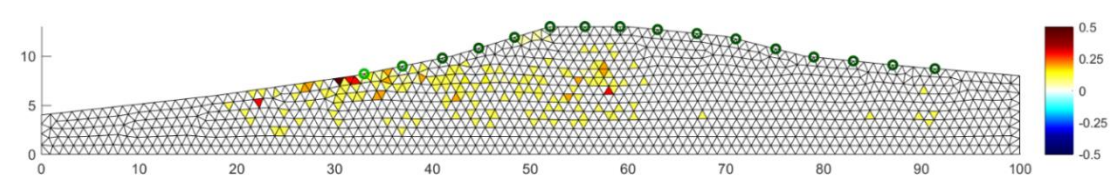

Lp	Wzorec przekroju wału przeciwpowodziowego	Obraz zrekonstruowany za pomocą generatora neuronowego
1		
2		
3		
4		
5		

Tabela 2b. Różnice wyników obrazowania w 2D

Lp	Różnice pomiędzy obrazem wzorca a obrazem zrekonstruowanym
1	
2	
3	



W tabeli 3a w podobny sposób zestawiono wzorce i zrekonstruowane obrazy wygenerowane przez sterownik 3D. W tabeli 3b zaprezentowano graficzną reprezentację różnic wartości poszczególnych pikseli pomiędzy przestrzennymi obrazami wzorcowymi i obrazami zrekonstruowanymi, przedstawionymi w tabeli 3a.

Tabela 3a. Rezultaty obrazowania w 3D

Lp	Wzorec przekroju wału przeciwpowodziowego	Obraz zrekonstruowany za pomocą generatora neuronowego
1		
2		
3		

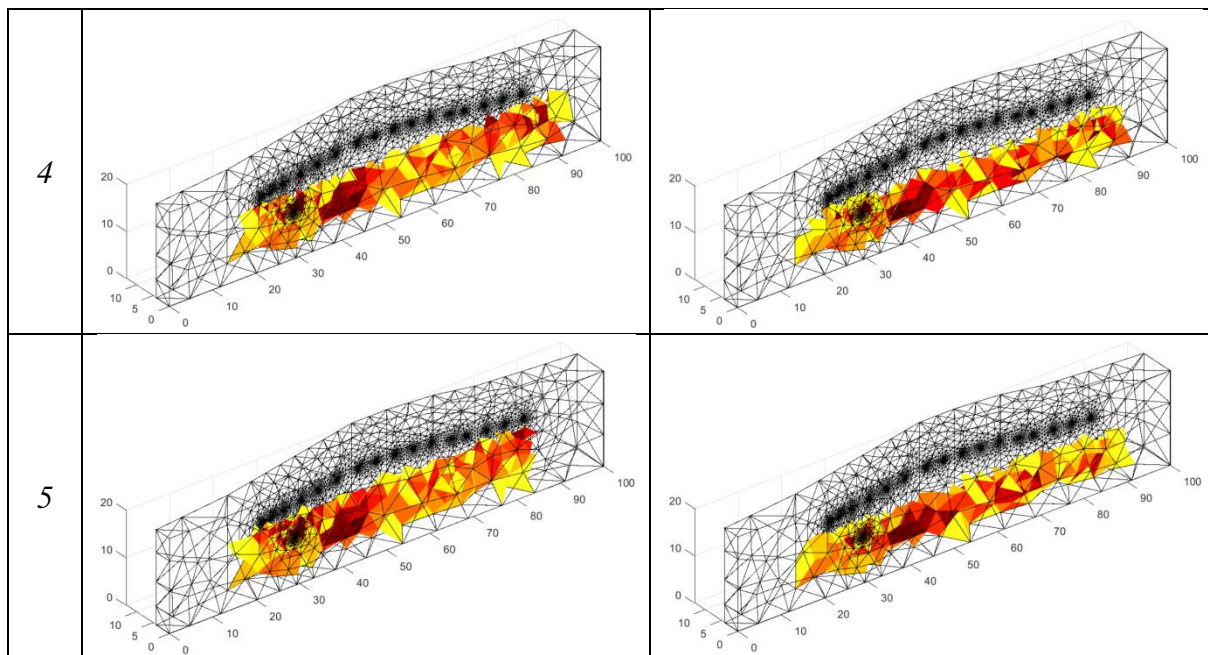




Tabela 3b. Różnice wyników obrazowania w 3D





Analogicznie jak w tabeli 2b, skala kolorystyczna na ilustracjach w tabeli 3b odzwierciedla różnice konduktywności pomiędzy elementami obrazów wzorcowych, a elementami obrazów rekonstruowanych.

Analizując tabelę 2a można zauważyć, że obrazy wynikowe z dużą dokładnością odwzorowują kształty i barwy obrazów wzorcowych. W przypadku modelu 2D wartości liczbowe pikseli obrazu wzorcowego były liczbami rzeczywistymi należącymi do przedziału od 1 do 3. Z tabeli 2b można odczytać wartości błędów obrazów rekonstruowanych względem ich wzorców. Widać, że większość pikseli na siatce nie zawiera błędów (brak koloru). W przypadku odchyłeń większych od zera, większość błędów nie przekracza wartości 0.2.

W tabeli 3a przedstawiono analizę porównawczą rekonstruowanych obrazów 3D. Tu również widoczna jest wysoka dokładność odwzorowań dla wszystkich pięciu prezentowanych przypadków. Siatka przestrzenna modelu 3D liczy aż 17869 punktów. Wartości liczbowe pikseli obrazu wzorcowego były liczbami rzeczywistymi należącymi do przedziału od 1 do 2. Z tabeli 3b można odczytać wartości błędów obrazów rekonstruowanych względem ich wzorców. Większość pikseli na siatce nie zawiera błędów (brak koloru). Podobnie jak w modelu 2D odchylenia niezerowe w większości przypadków nie przekraczają wartości 0.2.

5. Podsumowanie

W artykule zaprezentowano oryginalną koncepcję neuronowego systemu rekonstrukcji obrazów tomograficznych. Skuteczność metody została zweryfikowana w oparciu o uwarunkowania zapory Zbiornika Unieszkodliwiania Odpadów Wydobywczych Żelazny Most. Uwzględniając kluczowe cechy konstrukcyjne obiektu technicznego Żelazny Most, opracowano model fizyczny fragmentu zapory. Powyższy model wyposażono w układ elektrod oraz niezbędne urządzenia tomograficzne (EIT), które umożliwiły wykonanie wielu pomiarów wielkości elektrycznych oraz przyporządkowanie tym wielkościom obrazów przekrojów badanego modelu zapory. Uzyskane tą drogą dane zostały wykorzystane do wytrenowania systemu sieci neuronowych. Innowacyjną cechą przedmiotowego rozwiązania jest osobne wytrenowanie dużej liczby sieci neuronowych w ilości odpowiadającej rozdzielczości siatki obrazu rekonstruowanego. W trakcie badań laboratoryjnych opracowano dwa modele rekonstrukcji obrazów tomograficznych – płaski (2D) i przestrzenny (3D). Rezultaty wskazują, że prezentowana metoda obrazowania neuronowego może być skuteczna zarówno w przypadku rekonstrukcji dwu jak i trójwymiarowych. Zastosowanie układu wielu odrębnych sieci neuronowych działających jednocześnie w celu zobrazowania przekroju zapory przeciwpowodziowej umożliwiło wygenerowanie dokładnych odwzorowań zadanych wzorców. Jakość tych odwzorowań jest wystarczająca, aby prawidłowo zidentyfikować charakter zagrożeń, a także ocenić szybkość zmian zachodzących wewnątrz zapory.

Biorąc pod uwagę możliwość wykonywania pomiarów w stałych odstępach czasu, w prosty sposób można określić prędkość rozprzestrzeniania się przecieku. Powyższa informacja umożliwi nie tylko precyzyjną diagnozę przydatną do określania stopnia niezawodności zapory, lecz także skuteczną prognozę momentu nadchodzącej katastrofy. Dzięki informacjom uzyskanym za pomocą systemu obrazowania neuronowego, można odpowiednio zaplanować działania zapobiegające uszkodzeniom zabezpieczeń przeciwpowodziowych.

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

Literatura

1. Adedigba S A, Khan F, Yang M. Dynamic failure analysis of process systems using neural networks. *Process Safety and Environmental Protection* 2017; 111: 529-543.
2. Banasiak R, Wajman R, Sankowski D, Soleimani M. Three-Dimensional Nonlinear Inversion of Electrical Capacitance Tomography Data Using a Complete Sensor Model. *Progress In Electromagnetics Research (PIER)* 2010; 100: 219-234.
3. Beckers B, Schütt B. The elaborate floodwater harvesting system of ancient Resafa in Syria–Construction and reliability. *Journal of arid environments* 2013; 96: 31-47.
4. Bouzelha K, Hammoum H, Amirouche C, Chaouadi T. Reliability analysis of stability to sliding of earthen embankment under seismic effect. *Procedia Structural Integrity* 2017, 5: 77-84.
5. Curt C, Talon A. Assessment and control of the quality of data used during dam reviews by using expert knowledge and the ELECTRE TRI method. *Journal of Computing in Civil Engineering* 2011; 27.1: 10-17.
6. Gamse S, Zhou W H, Tan F, Yuen K V, Oberguggenberger M. Hydrostatic-season-time model updating using Bayesian model class selection. *Reliability Engineering & System Safety* 2018; 169: 40-50.

7. Gottardi G, Gragnano C G, Rocchi I, Bittelli M. Assessing River Embankment Stability Under Transient Seepage Conditions. *Procedia Engineering* 2016; 158: 350-355.
8. Hawryluk M, Mrzygłód B. A durability analysis of forging tools for different operating conditions with application of a decision support system based on artificial neural networks (ANN). *Eksploracja i Niezawodność – Maintenance and Reliability* 2017; 19 (3): 338–348, <http://dx.doi.org/10.17531/ein.2017.3.4>.
9. Ji J, Chan C L. Long embankment failure accounting for longitudinal spatial variation—A probabilistic study. *Computers and Geotechnics* 2014; 61: 50-56.
10. Kłosowski G, Kozłowski E, Gola A. Integer linear programming in optimization of waste after cutting in the furniture manufacturing. *Advances in Intelligent Systems and Computing* 2018; 637: 260-270.
11. Kozłowski E, Kowalska B, Kowalski D, Mazurkiewicz D. Water demand forecasting by trend and harmonic analysis. *Archives of Civil and Mechanical Engineering* 2018; 18(1): 140-148.
12. Kryszyn J, Smolik W, Radzik B, Olszewski T, Szabatin R. Switchless Charge-Discharge Circuit for Electrical Capacitance Tomography. *Measurement Science and Technology* 2014; 25(11): 115009.
13. Low B K. FORM, SORM, and spatial modeling in geotechnical engineering. *Structural Safety* 2014; 49: 56-64.
14. Mazurkiewicz D. Maintenance of belt conveyors using an expert system based on fuzzy logic. *Archives of Civil and Mechanical Engineering*, 2015; 15.2: 412-418.
15. Nishimura S, Shimizu H. Reliability-based design of ground improvement for liquefaction mitigation. *Structural Safety* 2008; 30.3: 200-216.
16. Prajapati A, Ganesan S. Application of Statistical Techniques and Neural Networks in Condition-Based Maintenance. *Quality and Reliability Engineering International* 2013; 29(3): 439-461.
17. Rusek J. Application of Support Vector Machine in the analysis of the technical state of development in the LGOM mining area. *Eksploracja i Niezawodność – Maintenance and Reliability* 2017; 19 (1): 54–61, <http://dx.doi.org/10.17531/ein.2017.1.8>.
18. Rymarczyk T, Tchórzewski P, Adamkiewicz P, Duda K, Szumowski J, Sikora J. Practical Implementation of Electrical Tomography in a Distributed System to Examine the Condition of Objects. *IEEE Sensors Journal* 2017; 17(24): 8166-8186.
19. Rymarczyk T. New Methods to Determine Moisture Areas by Electrical Impedance Tomography. *International Journal of Applied Electromagnetics and Mechanics* 2016; 52:79-87.
20. Stefanek P, Romaniuk D. Zastosowanie monitoringu geotechnicznego i środowiskowego na obiekcie unieszkodliwiania odpadów wydobywczych Żelazny Most. *Inżynieria Morska i Geotechnika*; 2015, 3: 376--381.
21. Stefanek P, Serwicki A. Ograniczenie oddziaływania OUOW Żelazny Most na środowisko poprzez zmianę technologii składowania odpadów. *Bezpieczeństwo Pracy i Ochrona Środowiska w Górnictwie*; 2014, 6: 36--42.
22. Ung S T, Williams V, Bonsall S, Wang J. Test case based risk predictions using artificial neural network. *Journal of Safety Research* 2006; 37.3: 245-260.
23. Wu Z Y, Li Y L, Chen J K, Zhang H, Pei L. A reliability-based approach to evaluating the stability of high rockfill dams using a nonlinear shear strength criterion. *Computers and Geotechnics* 2013; 51: 42-49.
24. Yajun W, Wohua Z, Weiliang J, Changyu W, Dachun R. Fuzzy stochastic generalized reliability studies on embankment systems based on first-order approximation theorem. *Water Science and Engineering* 2008; 1.4: 36-47.

25. Zagrożenia okresowe występujące w Polsce, Wydział Analiz Rządowego Centrum Bezpieczeństwa, styczeń 2013
26. Zuber N, Bajrić R. Application of artificial neural networks and principal component analysis on vibration signals for automated fault classification of roller element bearings. *Eksploatacja i Niezawodność – Maintenance and Reliability* 2016; 18 (2): 299–306, <http://dx.doi.org/10.17531/ein.2016.2.19>.