dr hab. inż. Tomasz Dysarz, prof. UPP Poznań, 21.09.2026 r.

Wydział Inżynierii Środowiska i Inżynierii Mechanicznej
Uniwersytet Przyrodniczy w Poznaniu
e-mail: tomasz.dysarz@up.poznan.pl

Recenzja

rozprawy doktorskiej Pani Khansy Gulshad

Od dynamiki powodzi do rozwiązań opartych na przyrodzie: geoprzestrzenne ramy sztucznej inteligencji dla odporności miast

From Flood Dynamics to Nature-Based Solutions:
A Geospatial AI Framework for Urban Resilience

1. Podstawa formalna i prawna

Podstawą formalną przygotowanej recenzji jest pismo przewodnie prof. dr hab. inż. Ewy Wojciechowskiej, Dziekana Wydziału Inżynierii Lądowej i Środowiska Politechniki Gdańskiej (l.dz. 605/WILiŚ/2026). Ocena została przeprowadzona na podstawie rozprawy doktorskiej przygotowanej w języku angielskim przez doktorantkę, panią Khansę Gulshad. Promotorem pracy jest prof. dr hab. inż. Michał Szydłowski, z Katedry Geotechniki i Inżynierii Wodnej Politechniki Gdańskiej. Rozprawa została złożona w formie papierowej oraz cyfrowej do Rady Dyscypliny Naukowej Inżynieria Lądowa, Geodezja i Transport Politechniki Gdańskiej. Recenzję przeprowadzono zgodnie z wymogami określonymi w artykule 187 ustawy o szkolnictwie wyższym i nauce z dnia 20 lipca 2018 r. (POL-2018-R-109017), znowelizowanej przez późniejsze rozporządzenia (POL-2018-R-109019).

2. Przegląd prowadzonych badań

Głównym przedmiotem badań jest modelowanie zagrożenia powodziowego ze szczególnym uwzględnieniem powodzi miejskich. Badania koncentrują się na wdrażaniu nowoczesnych technologii, takich jak geoprzetwarzanie, modelowanie hydrologiczne, a zwłaszcza metody uczenia maszynowego i głębokiego uczenia (ang. *machine learning/deep learning*, ML/DL). Doktorantka, w swojej pracy, trafnie wskazała największą lukę do wypełnienia w tej dziedzinie, tzn. wdrażanie metod ML/DL do generowania map podatności na zalewy powodziowe bez odpowiedniego uwzględnienia zasad fizycznych rządzących przepływem wody w środowisku naturalnym. Drugim obszarem zainteresowań jest rozwój rozwiązań opartych na naturze (NbS) oraz

planowanie zielonej infrastruktury (GI) w miastach. W tym obszarze badania koncentrują się na połączeniu istniejących metod cyfrowego przetwarzania obrazów ze skutecznymi strategiami nasadzeń drzew, co stanowi również jedno z aktualnych wyzwań. Główną koncepcją pracy doktorskiej jest integracja metod obecnie stosowanych w analizach zagrożenia powodziowego i gospodarki wodnej miast i utworzenie spójnej metodyki umożliwiającej sprawne zarządzanie infrastrukturą miast. Koncepcja ta wykracza poza samodzielne zastosowanie metod ML/DL, które obecnie jest najczęstszą praktyką, ale próbuje je wdrażać z odpowiednim uwzględnieniem procesów hydrologicznych oraz powiązań hydraulicznych w badanym systemie.

Aby zilustrować znaczenie zintegrowanego podejścia jako studium przypadku, w pracy wykorzystano miasto Gdańsk. Biorąc pod uwagę historyczne doświadczenia Gdańska związane z powodziami, wybór ten jest uzasadniony. Jak wskazano w pracy, zagrożenie powodziowe w mieście wynika z trzech różnych czynników: (1) spływu powierzchniowego z polodowcowych wzgórz morenowych, (2) wezbrań rzek podczas intensywnych opadów oraz (3) podnoszenia się poziomu morza w Zatoce Gdańskiej. Doktorantka zauważyła również, że *„[...] żadne badanie dotyczące miasta nadmorskiego nie uwzględniło dotychczas w sposób zintegrowany tych [wspomnianych wcześniej] elementów [...]*".

W związku z tym znaczenie przedstawionych badań nie budzi wątpliwości. Cele zostały właściwie określone, a nowatorski charakter pracy został jasno wykazany. Zastosowane metody są zaawansowane i zgodne z aktualnymi praktykami oraz stanem badań. Procedura gwarantuje, że wyniki będą miarodajne, a wyznaczone cele będą właściwie osiągnięte.

3. Analiza rozprawy doktorskiej

Przedłożona rozprawa składa się z 9 rozdziałów, 3 załączników, wykazu skrótów (82 pozycje), streszczenia oraz bibliografii. Na początku rozprawy znajdują się również: streszczenie graficzne oraz podziękowania, wraz z oświadczeniem o braku znaczącego finansowania ze źródeł zewnętrznych. Oświadczenia formalne umieszczono przed stroną tytułową. Praca zawiera 51 rysunków, 30 tabel i 57 równań, z których większość pojawia się w rozdziałach głównych. Dodanie spisu rysunków i spisu tabel poprawiłoby czytelność tekstu. Liczba pozycji bibliograficznych wynosi 288, w tym 218 artykułów opublikowanych w czasopismach naukowych. Wykryto pewne powtórzenia w spisie bibliograficznym. Problem ten został opisany w szczegółowych uwagach.

Rozdział 1, zatytułowany „*Wprowadzenie*" ("*Introduction*"), przedstawia problem i naświetla jego różne elementy. Doktorantka rozpoczyna od ogólnego przeglądu współczesnych wyzwań związanych ze zmianami klimatu i rosnącym ryzykiem powodziowym, który jest poparty przykładami powodzi miejskich, jakie miały miejsce w przeszłości w Gdańsku. Następnie opis skupia się na pierwszym głównym zagadnieniu niniejszych badań: zróżnicowaniu metod modelowania zagrożeń hydrologicznych. Doktorantka prowadzi dyskusję od modeli o charakterze bardziej fizycznym, takich jak HEC-HMS, do nowoczesnych metod opartych na danych, w tym algorytmów Sztucznej

Inteligencji. Drugim zagadnieniem jest planowanie przestrzenne rozwiązań opartych na naturze (ang. *Nature-based Solutions*, NbS) oraz zielonej infrastruktury (ang. *Green Infrastructure*, GI) w mieście. Autorka precyzyjnie identyfikuje główne luki do wypełnienia w tych dwóch obszarach i pokrótce wyjaśnia podejście zastosowane w przedstawionych badaniach. W następnym kroku sformułowany jest cel badań:

> *„[…] wykazanie, że GeoAI, […], może bezpośrednio wspierać przejrzystą, zrównoważoną i opartą na faktach adaptację miejską".*

Ponadto doktorantka wskazuje, że nie jest to jedynie postęp metodologiczny w hydrologii miejskiej i planowaniu zielonej infrastruktury, a kluczem do sukcesu jest zastosowanie GeoAI w ramach uporządkowanego, zintegrowanego procesu, a nie jako zbioru narzędzi. Zadania naukowe zdefiniowano w następujący sposób:

1. *„Ocena ilościowa historycznego i prognozowanego wpływu dynamiki zmian w użytkowaniu gruntów i pokryciu terenu (LULC) oraz zmian klimatu na spływ powierzchniowy w skali zlewni i miasta, […]."*
2. *„Opracowanie zrozumiałej, opartej na uczeniu maszynowym pełnej struktury […], służącej do mapowania podatności obszarów miejskich na powodzie oraz identyfikacji głównych czynników przestrzennych powodujących zalewy."*
3. *„Zdiagnozowanie nierównomierności w przestrzennym rozmieszczeniu zielonej infrastruktury w Gdańsku […]."*
4. *„Ocena potencjału wprowadzenia zieleni miejskiej na poziomie dachów i ulic […], oraz oszacowanie skumulowanych korzyści w zakresie retencji wód opadowych wynikających ze zintegrowanych działań w zakresie zielonej infrastruktury w różnych scenariuszach opadowych."*

Powyższe punkty wystarczają precyzyjnego zdefiniowania problemu naukowego. Jednakże, aby zachować zgodność z metodologią naukową, można by również sformułować hipotezę badawczą.

W kolejnym rozdziale, zatytułowanym „*Stan wiedzy*" ("*State of the art*"), opisano aktualny stan badań w czterech wydzielonych dziedzinach istotnych dla niniejszej rozprawy. Po omówieniu skutków zmian klimatu, zmian w użytkowaniu oraz pokryciu terenu (ang. *Land Use/Land Cover*, LULC) oraz zastosowań modelowania hydrologicznego następuje omówienie metod oceny podatności na zalewy powodziowe. Przegląd ten zawiera również swoiste refleksje sformułowane przez doktoranta. Chociaż argumenty dotyczące czasochłonności i problemów z kalibracją modeli hydrologicznych i hydraulicznych są powtarzane zgodnie z literaturą naukową, przedstawiono również krytykę dotyczącą charakteru modeli sztucznej inteligencji jako modeli typu „czarna skrzynka" (ang. *black-box*). Ta ostatnia uwaga jest całkowicie słuszna, ale nie jest zbyt często przywoływana w publikacjach dotyczących map podatności na zalewy. Kolejne sekcje ilustrują koncepcję zielonej infrastruktury w miastach oraz czynniki ją determinujące wraz z przykładami. W następnej części omawiane jest wdrażanie rozwiązań opartych na naturze (NbS) oraz narzędzi GeoAI w planowaniu urbanistycznym.

Rozdział 3 nosi tytuł „*Obszar badań i ramy danych*" ("*Study area and data framework*"). W pierwszych fragmentach autorka precyzyjnie wyjaśnia powody wyboru Gdańska,

największego portu nad Morzem Bałtyckim jako studium przypadku. Rozdział zawiera szczegółowe informacje na temat tego obszaru oraz interesującą dyskusję na temat wdrażania systemów informacji geograficznej (GIS) w polskich miastach. W tabeli 3.1 wymieniono dane źródłowe wraz z odniesieniami do kolejnych rozdziałów, w których zostały one wykorzystane. Krótka dyskusja połączona z klasyfikacją różnych typów informacji mogłaby uwypuklić różnice między danymi rozłożonymi przestrzennie a danymi punktowymi, a także między danymi statycznymi a danymi opisującymi zmiany zachodzące w pewnym czasie. Pomocne byłoby sprecyzowanie, które dane pochodzą ze źródeł polskich, które z serwisów europejskich, a które mają charakter globalny.

W rozdziałach od 4 do 7 omówiono poszczególne metody zastosowane w badaniach. Struktura wewnętrzna każdego z tych rozdziałów jest podobna. Najpierw w każdym rozdziale przedstawiono wprowadzenie do zagadnienia, następnie opisano metodologię, zaprezentowano uzyskane wyniki, przedstawiono dyskusję i sformułowano krótkie wnioski. Pierwsze dwa rozdziały (rozdziały 4 i 5) poświęcone są modelowaniu powodzi przy użyciu dwóch podejść: standardowego modelowania hydrologicznego oraz mapowania podatności na zalewy z wykorzystaniem sztucznej inteligencji. Kolejne dwa rozdziały (rozdziały 6 i 7) poświęcone są zielonej infrastrukturze i rozwiązaniom opartym na naturze. W kolejnych akapitach bardziej szczegółowo opisano część poświęconą metodologii.

Rozdział 4, zatytułowany „*Dynamika użytkowania gruntów i reakcje hydrologiczne*" ("*Land Use Dynamics and Hydrological Response*"), poświęcony jest zmianom w użytkowaniu i pokryciu terenu w miastach, ze szczególnym uwzględnieniem Gdańska. W badaniach wykorzystano dane satelitarne z satelitów Landsat i Sentinel-2. Serwis internetowy Google Earth Engine (GEE) wykorzystano narzędzie do przetwarzania danych. Następnie za pomocą modelu HEC-HMS przeprowadzono modelowanie wpływu zmian w użytkowaniu i pokryciu terenu (LULC) na hydrologię miejską. Rysunek 4.1 ilustruje ogólną koncepcję, natomiast rysunek 4.2 przedstawia zlewnię. Znajdują się tam również dwa równania omawiające kluczowe elementy metody zastosowanej do obliczenia tzw. „strat opadu" (ang. *abstractions*[1]), a mianowicie NRCS-CN (wcześniej znanej jako SCS-CN). Zgodnie z tekstem model hydrogramu jednostkowego typu SCS-CN został użyty do transformacji opadu efektywnego w odpływ ze zlewni, a model Muskingum opisuje propagację fal wezbraniowych w kanałach. Ponieważ metody te nie są domyślnym wyborem w zastosowanym oprogramowaniu, dobrze byłoby uzasadnić ich wybór i krótko przedstawić ich parametry. Nie jest również jasne, jaki model dopływu wody podziemnej (ang. *baseflow*) został wybrany. W tabeli 4.1 podsumowano konfigurację symulacji, natomiast w tabeli 4.2 krótko scharakteryzowano przyjęte scenariusze zmian klimatu. Doktorantka skupiła się na prognozach związanych ze scenariuszami RCP4.5 i RCP8.5 zalecanymi przez IPCC (Międzyrządowy Zespół ds. Zmian Klimatu). Wyniki omówiono przy użyciu 3 tabel i 10 rysunków. Moim zdaniem mapy przedstawiające historyczne zmiany i trendy w użytkowaniu i pokryciu terenu (LULC) mają bardzo duże znaczenie

[1] Ilości wody opadowej, która infiltruje lub jest zatrzymywana jako lokalna retencja

praktyczne. Wyniki części hydrologicznej są głównie poświęcone zmianom współczynnika spływu, co mogłoby pomóc w projektowaniu obiektów infrastruktury wodnej.

W kolejnym rozdziale, „*Tworzenie map podatności na powodzie z wykorzystaniem interpretowalnego uczenia maszynowego*" ("*Flood Susceptibility Mapping with Interpretable ML*"), opisano metody uczenia maszynowego i głębokiego uczenia (ang. *Machine Learning/Deep Learning*, ML/DL) zastosowane do określenia obszarów miasta narażonych na zalewy powodziowe. Rysunek 5.1 przedstawia ogólną koncepcję. Autorka skalibrowała modele trzech różnych typów: maszyny wektorów nośnych (ang. *Support Vector Machine*, SVM), lasu losowego (ang. *Random Forest*, RF) oraz sztucznych sieci neuronowych (ang. *Artificial Neural Networks*, ANN). Podstawą procesu uczenia są dane z interwencji podczas powodzi w okresie 12 lat (2010–2022), uzyskane od Państwowej Straży Pożarnej oraz Gdańskiego Zakładu Wodociągów. Czynniki wywołujące podzielono na fizyczne i antropogeniczne. Do przeprowadzenia szczegółowej analizy wrażliwości zastosowano metodę klasyfikacji danych nazywaną *SHapley Additive exPlanations* (SHAP). W rozdziale znajduje się 21 równań wyjaśniających kluczowe elementy modeli oraz definiujących wskaźniki statystyczne. Tabela 5.1 zawiera podsumowanie parametrów modeli wybranych w niniejszym badaniu. Wyniki przedstawiono w 4 tabelach i na 9 rysunkach. Rysunek 5.9 przedstawia uzyskane mapy podatności na zalewy, natomiast rysunek 5.10 pokazuje obszary narażone wyłącznie na gwałtowne spływy powierzchniowe (ang. *flash floods*).

Omówienie zagadnienia zielonej infrastruktury i rozwiązań opartych na naturze rozpoczyna się w rozdziale 6, zatytułowanym „*Rozmieszczenie przestrzenne i czynniki determinujące zieloną infrastrukturę*" ("*Spatial Distribution and Determinants of Green Infrastructure*"). Rysunek 6.1 ilustruje elementy metodologii, a ich opis jest wsparty 9 kluczowymi równaniami. Ogólnie rzecz biorąc, etapy te obejmują gromadzenie danych, trzy etapy przetwarzania danych oraz analizę wyników przedstawioną na koniec. Trzyetapowe przetwarzanie danych obejmuje przetwarzanie wstępne, w tym wybór rozdzielczości, autokorelację przestrzenną oraz regresję między gęstością zielonej infrastruktury a „*czynnikami wyjaśniające*" (ang. *explanatory factors*). Siatka o rozdzielczości 1 km służy do przedstawienia przestrzennego rozkładu gęstości zielonej infrastruktury w całym mieście. Metody obliczania autokorelacji wykorzystano do sprawdzenia czy wartości gęstości zielonej infrastruktury są skupione przestrzennie, rozproszone czy rozmieszczone losowo. Regresję między gęstością zielonej infrastruktury a „*czynnikami wyjaśniającymi*" przeprowadzono w środowisku Python Colab. Zastosowana metodologia jest zaawansowana oraz zapewnia uzyskanie poprawnych wyników o znaczeniu praktycznym. Przykłady przedstawiono na 6 rysunkach oraz w 2 tabelach. Pozostałe wyniki zamieszczono w załączniku B. Warto podkreślić, że rozdział 6 zawiera wyniki o szczególnym znaczeniu teoretycznym, np. wykresy przedstawiające korelacje między „*czynnikami wyjaśniającymi*" (rysunek 6.4) oraz porównanie skuteczności modeli regresji (tabela 6.2). Znajdują się w nim jednak również wyniki o

dużej przydatności dla praktyków, np. mapa gęstości zielonej (rysunek 6.2) oraz mapa obszarów priorytetowych dla lokalizacji zielonej infrastruktury (rysunek 6.7).

Rozdział 7, „*Ramy GeoAI do oceny przydatności rozwiązań opartych na naturze (NBS) i analizy wód opadowych*" ("*GeoAI Framework for NBS Suitability & Stormwater Analysis*"), opisuje zastosowanie narzędzi GeoAI do sensownego planowania rozwiązań opartych na naturze, takich jak dachy błękitno-zielone (ang. *blue-green roofs*, BGR), zieleń uliczna i drzewa przyuliczne, a następnie przedstawia oszacowanie retencji i przechwytywania wód opadowych w mieście. Zastosowana metodologia łączy procedury geoprzetwarzania, przetwarzanie i rozpoznawanie obrazów oraz metody uczenia maszynowego (ang. *machine learning*, ML) i głębokiego uczenia (ang. *deep learning*, DL). Cała procedura została przedstawiona na schemacie na rysunku 7.1. Na tym etapie badań wdrożono różne rodzaje modeli, np. Mask2Former, XGBoost i RESILO. Opis metodologii uzupełnia 8 równań i jedna tabela (tabela 7.1), zawierającą krótką charakterystykę badanych scenariuszy opadów. Generalnie, metodologię zaimplementowaną w modelach można by opisać bardziej szczegółowo. Wyniki przedstawiono i zilustrowano za pomocą 5 rysunków i 2 tabel. Rysunki zawierają przykłady map i zdjęć miasta (zdjęcia z poziomu gruntu), które ilustrują zaimplementowane koncepcje. Więcej wyników znajduje się w załączniku C. Tabele przedstawiają charakterystyki redukcji retencji oraz wpływ przechwytywania opadu. Efektem analiz są również dwa publicznie dostępne serwisy internetowe o nazwach *GreenRoofs* oraz *GreenStreets*.

Omówienie powyższych koncepcji znajduje się w rozdziale 8, zatytułowanym „*Synteza, implikacje i możliwość przeniesienia*" ("*Synthesis, Implications & Transferability*"). Rozpoczyna się ono graficznym podsumowaniem omówionych wcześniej koncepcji (rysunek 8.1). Rozdział ma charakter szerokiej dyskusji, jednak wnioski przedstawiono w następnym rozdziale 9. Doktorantka prowadzi tę dyskusję wychodząc od syntezy rozdziałów poświęconych metodologii, poprzez refleksje na temat wkładu metodologicznego wniesionego przez narzędzia GeoAI, aż po rozważania dotyczące ich niepewności i stosowalności. Rekomendacje dla miasta Gdańska przedstawiono w trzech tabelach, obejmujących zalecenia dotyczące zasad postępowania, procesu wdrażania oraz zarządzania konfliktami przestrzennymi.

W rozdziale 9, zatytułowanym „*Wnioski i dalsze badania*" ("*Conclusion and Future Research*"), w pierwszej kolejności wykazano, że cel badań został osiągnięty, oraz wyjaśniono w jaki sposób. Następnie skupiono się na zadaniach naukowych określonych we Wstępie ("*Introduction*"). Rozdział 4 przedstawia pierwsze ilościowe ujęcie dynamiki zmian w użytkowaniu i pokryciu terenu (LULC) oraz wpływu zmian klimatu na spływ powierzchniowy, co jest głównym celem zadania nr 1. Kolejny rozdział ilustruje ocenę podatności na zalewy powodziowe w środowisku miejskim, co stanowi zadanie nr 2. Rozdział 6 poświęcony jest zadaniu nr 3, tj. rozmieszczeniu zielonej infrastruktury w Gdańsku i jej powiązaniom z charakterystykami hydrologicznymi. Wreszcie w rozdziale 7 określono potencjał na wprowadzenie zieleni miejskiej, uwzględniając korzyści wynikające ze skumulowanego zatrzymywania wód opadowych, co stanowi zadanie nr 4. Ponadto autorka podkreśla szczególne innowacje osiągnięte podczas badań, np.

zastosowanie „*opartego na scenariuszach modelu oceny potencjału dla wprowadzenie zieleni miejskiej (ang. greening potential score, GPS), który łączy techniczną wykonalność zielonych dachów z ograniczeniami planistycznymi*". Następnie podsumowano i w skrócie omówiono ograniczenia badań. Autorka przedstawia spostrzeżenia i sugestie wykraczające poza obecną praktykę i stan wiedzy, np. sugeruje, że w mapowaniu podatności na zalewy powodziowe nie uwzględnia się rodzaju powodzi, podczas gdy uzyskane wyniki wskazują na znaczenie tego czynnika. Na koniec autorka przedstawia wnioski i podkreśla „*najważniejszy wynik badań*": połączenie czterech, mniej lub bardziej odrębnych metod w jedną procedurę. Zgodnie z wiedzą recenzenta jest to jak najbardziej aktualny przedmiot badań i cel wielu naukowców pracujących w dziedzinie zarządzania ryzykiem powodziowym. Dlatego innowacyjność proponowanej metodyki jest oczywista.

Warto podkreślić, że przedstawienie metodologii w czterech odrębnych rozdziałach daje zdecydowanie lepszy efekt niż zastosowanie typowego schematu: *materiały* – *metody* – *wyniki* – *dyskusja*. Przedstawiony opis jest jasny i zrozumiały. Powiązania między poszczególnymi elementami są dobrze zdefiniowane i podsumowane w rozdziale 8.

4. Uwagi i pytania

Główne uwagi i pytania

A. Elementy hydrologiczne są aktualnie obecne w modelach hydrodynamicznych. Oprogramowanie takie jak HEC-RAS czy Iber pozwala symulować przepływ 2D na określonych obszarach, uwzględniając opady deszczu i infiltrację. Czy możliwe jest, że model, którego podstawą są pełne równaniach bilansu masy i pędu, np. równania płytkiej wody (ang. *shallow water equations*), dałby bardziej interesujące wyniki? W jaki sposób taki model można by zweryfikować na danych wykorzystanych w obecnych badaniach?

B. Podwójne maksima wykresu przedstawiającego zależność częstotliwości od odległości od koryta rzeki (rysunek 5.2) sugerują, że w zbiorze danych występują zarówno powodzie rzeczne, jak i innego typu. Przypuszczalnie zalania w dużych odległościach od rzeki były spowodowane opadami deszczu i spływem powierzchniowym lub awarią kolektorów. W rozdziale „*Wnioski*" ("*Conclusions*") znajduje się uwaga dotycząca roli rodzaju powodzi (w sekcji „*9.1. Ograniczenia i przyszłe badania*", tzn. "*9.1. Limitations and future research*"). W jaki sposób ten aspekt mógłby wpłynąć na prezentowane mapy podatności na zalewy powodziowe? Czy możliwe jest, że rozkład obszarów podatnych na zalewy powodziowe w mieście wyglądałby inaczej, gdyby uwzględniono rodzaj powodzi?

C. Czy możliwe jest wykorzystanie zdjęć satelitarnych historycznych powodzi do kalibracji modeli uczenia maszynowego (ang. *machine learning*, ML) i głębokiego uczenia (ang. *deep learning*, DL)? Czy taki model nadal generowałby mapę podatności na zalewy powodziowe, czy też mógłby symulować przebieg powodzi i stworzyć pełną mapę zagrożenia powodziowego?

D. W dziedzinie modelowania hydrologicznego pojawia się nowa klasa metod, a mianowicie sieci neuronowe wsparte zależnościami fizycznymi (ang. *physics-informed neural networks*, PINN). Łączą one klasyczne uczenie głębokie (ang. *deep learning*, DL) oparte na sztucznych sieciach neuronowych (ang. *artificial neural networks*, ANN) z modelowaniem wykorzystującym klasyczne zasady zachowania (masy, pędu itp.). Czy możliwe jest wdrożenie takich koncepcji w przedstawionej metodyce?

Dodatkowe uwagi i sugestie

(1) Byłoby dobrze, gdyby sformułowano hipotezę leżącą u podstaw przeprowadzonych badań, a wnioski odnosiłyby się do niej.
(2) Dlaczego sieć rzek pobrano z globalnego serwisu OpenStreetMap? Czy nie było możliwości uzyskania takich danych z polskiego MPHP (*Mapa Podziału Hydrograficznego Polski*)? Które ze źródeł jest dokładniejsze?
(3) Analiza dotyczy miasta, co wymaga danych przestrzennych o większej rozdzielczości lub bardzo dokładnych warstw wektorowych. Jednak niektóre dane rastrowe opisujące użytkowanie terenu (LULC) oraz wskaźniki wegetacji (NDVI, NDWI) mają raczej niską rozdzielczość (30 m, 100 m). Czy miało to wpływ na wyniki?
(4) Jakie są parametry poszczególnych modeli zastosowanych w programie HEC-HMS, a mianowicie hydrogramu jednostkowego typu SCS-CN oraz modelu Muskingum? Który model wybrano do szacowania zasilania wodami podziemnymi (ang. *baseflow*)? Jaką formułę i definicję przyjęto dla często stosowanego współczynnika spływu (ang. *runoff coefficient*)?
(5) Wymieniono różne miary służące do oceny dokładności modeli ML/DL (RMSE, MAE, ACC itp.). Które z nich zastosowano podczas uczenia (70% przypadków), a które podczas weryfikacji (30% przypadków)? Jaką metodę uczenia zastosowano, np. metody gradientowe, metody wyszukiwania bezpośredniego, optymalizację globalną, metodę prób i błędów?
(6) Czy wykorzystanie Google Colab jako środowiska języka Python wynika z dostępności modułów w tym serwisie? Czy możliwe jest przeprowadzenie tej samej analizy w standardowym środowisku Python z wykorzystaniem `pip` lub `conda` do zarządzania pakietami?
(7) Ogólnie rzecz biorąc, dobrze byłoby, gdyby różne modele wykorzystane w rozdziale 7, tj. Mark2Former, XGBoost i RESILO, zostały dokładniej opisane.

Wykryte nieścisłości i błędy redakcyjne

(1) W spisie treści mogłyby być umieszczone takie elementy jak:
    a. streszczenie graficzne (str. 6),
    b. podziękowania (str. 7),
    c. bibliografia (str.150),
    d. załączniki (od str. 172)
(2) We Wprowadzeniu (str. 17) ta sama koncepcja została sformułowana dwukrotnie w następujący sposób:

"Machine learning and explainable artificial intelligence offer a pathway beyond these modelling limitations, but their transformative potential lies not in applying them individually, but in chaining them with remote sensing and hydrological analysis into a coherent analytical pipeline."

Oraz w następującym zdaniu:

"Machine learning models offer a pathway beyond these modelling limitations, but their transformative potential lies in chaining them with remote sensing and hydrological analysis into a coherent pipeline rather than applying them individually [...]"

(3) Rysunek 3.1: Skalę numerycznego modelu terenu (ang. *digital elevation model*, DEM) w górnej części można zaokrąglić, np. od -20 do 180 m n.p.m.

(4) Nie jest do końca jasne, jaka jednostka [ms] została użyta w zdaniu „*Fale sztormowe, [...], mogą podnieść poziom morza o ponad 1,5 ms, a prognozy wskazują, że potencjalne fale mogą osiągnąć nawet 2.5 ms*" ("*Storm surges, [...], can raise sea levels by over 1.5 ms, with projections indicating potential surges reaching up to 2.5 ms.*") (str. 32).

(5) Tabela 3.1: Opis w drugiej kolumnie (Rozdzielczość i Rok, ang. *Resolution & Year*) jest nieco mylący. Skala mapy (np. mapy glebowej, ang. *soil map*) odzwierciedla poziom szczegółowości, a nie rozdzielczość. Ponadto w przypadku numerycznych modeli terenu (ang. *digital elevation models*, DEM) można by podać dokładność pionową.

(6) Rysunek 4.1: Czcionki użyte w opisach powinny być większe. Nie są one wyraźnie widoczne.

(7) Rysunek 4.2: Skalę numerycznego modelu terenu (ang. *digital elevation model*, DEM) można by zaokrąglić, np. od 0 do 160 m n.p.m.

(8) Błędny numer rysunku w rozdziale 4 na stronie 46. Zamiast „*Rysunek 4.3*" ("*Figure 4.3*") widnieje „*Rysunek 2.3*" ("*Figure 2.3*").

(9) Rysunek 5.1: Schemat blokowy jest nieco zbyt skomplikowany. Nie jest do końca jasne, w jakim kierunku przebiega przepływ informacji na tym schemacie.

(10) Rysunek 5.2: Wykresy gleb (ang. *soil*) oraz użytkowania i pokrycia terenu (abbr. *LULC*) powinny być przedstawione i zinterpretowane w inny sposób niż wykresy pozostałych elementów. Gleby i LULC reprezentują cechy nieciągłe i nieuporządkowane. Dodatkowo oś pionowa przedstawiająca częstotliwość powinna mieć tę samą skalę. Być może lepiej byłoby zastosować częstotliwość względną, aby wartości na osi pionowej mieściły się w przedziale od 0 do 1.

(11) Rysunek 6.4: Nie jest jasne, czym są PR1, PR2, PR3 i PR4 na liście zmiennych zależnych. Czy są to prognozowane opady związane ze scenariuszami RCP4.5 i RCP8.5 określonymi dla okresów 2021–2050 i 2071–2100?

(12) W sekcji 6.1.4 użyto terminu „*czynniki wyjaśniające*" (ang. "*explanatory factors*"). Termin ten należy tutaj wyjaśnić. O „*czynnikach*" (ang. "*factors*") wspomniano we *Wprowadzeniu* (*Introduction*) (str. 26), ale nie nazwano ich „*wyjaśniającymi*" (ang. "*explanatory*"). Dla czytelnika niezaznajomionego z terminologią stosowaną w metodach regresji stwierdzenie to może być mylące. Moim zdaniem należy to wyjaśnić w tekście.

(13) W opisie równania 7.3 użyto terminu "*proportion*" (pol. „*proporcja*"). Jednak z kontekstu wynika, że bardziej odpowiednie byłoby użycie terminu "*ratio*" (pol. „stosunek").

(14) Błędny numer rysunku w załączniku A na stronie 174. Zamiast „*Rysunek A.2*" (ang. "F*igure A.2*") widnieje „*Rysunek 3*" (ang. "*Figure 3*").

(15) Błędny numer rysunku w załączniku C na stronie 189. Zamiast „*Rysunek C.2*" (ang. "*Figure C.2*") widnieje „*Rysunek C4*" (ang. "*Figure C4*").

(16) Na liście źródeł występują powtórzenia, np.:

44 Cheng, B., Misra, I., Schwing, A.G., Kirillov, A., Girdhar, R., 2022a. Masked-attention mask transformer for universal image segmentation, in: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. pp. 1290–1299.

45 Cheng, B., Misra, I., Schwing, A.G., Kirillov, A., Girdhar, R., 2022b. Masked-attention mask transformer for universal image segmentation, in: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. pp. 1290–1299.

(17) W wykazie bibliograficznym występują również pewne problemy z formatowaniem, np.:

73 Ewelina, C., Liliana, J., Katarzyna, K., Mateusz, K., Wojciech, Ł., Aleksandra, Ł., Piotr, O., Karolina, P., Paweł, P., Agnieszka, R., Agnieszka, S., Magdalena, Z., 2021a. Raport o stanie polskich miast. Środowisko i adaptacja do zmian klimatu / Report on the State of Polish Cities: Environment and Adaptation to Climate Change. Warszawa – Kraków.

5. Końcowa ocena rozprawy

Problem badawczy został poprawnie zdefiniowany. Jego znaczenie nie budzi żadnych wątpliwości, a zastosowane metody są zaawansowane i zgodne z aktualnym stanem wiedzy. Nie wykryto poważnych błędów ani uchybień. Złożoność poruszonego problemu jest duża a zakres przeprowadzonych analiz bardzo szeroki. Wybór zaawansowanej i zróżnicowanej metodyki jest w pełni uzasadniony. Wszystkie te elementy razem sprawiają, że przedłożona rozprawa doktorska jest oryginalna i cechuje ją duża innowacyjność. Wyniki stanowią cenny wkład w stan wiedzy i niosą ze sobą ogromny potencjał praktyczny. Przedstawiona metodologia może być bezpośrednio zastosowana w Gdańsku i z łatwością przeniesiona na inne lokalizacje. Niektóre wyniki są już dostępne dla potencjalnych interesariuszy i decydentów za pośrednictwem profesjonalnie przygotowanych serwisów internetowych. Jest to też dobry przykład, w jaki sposób należy zorganizować komunikację ze społeczeństwem.

Temat badań jest bardzo ważnym zagadnieniem z zakresu dyscypliny Inżynieria Lądowa, Geodezja i Transport. Rozprawa podkreśla znaczenie dokładnej oceny hydrologicznej oraz identyfikacji obszarów zagrożonych powodzią w procesie planowania i projektowania infrastruktury miejskiej. W związku z tym ma ona istotny wpływ na inne dziedziny badań naukowych i praktyki, takie jak hydrologia, ochrona przeciwpowodziowa oraz planowanie przestrzenne. Wyraźnie wykazano przydatność zielonej infrastruktury i rozwiązań opartych na naturze. Ponadto badanie ilustruje potencjał narzędzi GeoAI w planowaniu przestrzennym i gospodarowaniu terenami. Przeprowadzone analizy przyczyniają się do lepszego zrozumienia procesów, skutków i praktyk zarządzania w środowisku miejskim. Mogą one również wpłynąć na dalszy rozwój modelowania hydrologicznego i

hydrodynamicznego, a także na zastosowanie metod uczenia maszynowego i głębokiego uczenia w hydrologii.

6. Wnioski

Ogólnie rzecz biorąc, praca doktorska stanowi cenny wkład w badania nad modelowaniem powodzi miejskich, zapobieganiem powodziom oraz planowaniem przestrzennym infrastruktury przeciwpowodziowej. W pracy wykazano również potencjalne zastosowanie uzyskanych wyników. Doktorantka wykazała się rozległą wiedzą i dogłębnym zrozumieniem literatury fachowej przy formułowaniu celów pracy, prowadzeniu badań i analizowaniu wyników. Uważam, że praca doktorska zasługuje na wyróżnienie ze względu na szeroki zakres i zaawansowanie przedstawionych badań, jej znaczenie dla nauki oraz praktyczną użyteczność.

Praca doktorska przedłożona przez panią Khansę Gulshad spełnia wszystkie wymagania dotyczące prac doktorskich określone w ustawie z dnia 20 lipca 2018 r. o szkolnictwie wyższym i nauce. Na podstawie mojej pozytywnej oceny rekomenduję Przewodniczący Rady Naukowej Dyscypliny Inżynieria Lądowa, Geodezja i Transport dopuszczenie pani Khansy Gulshad do kolejnych etapów procesu nadawania stopnia doktora, w tym do publicznej obrony pracy.

T. Dysarz

Tomasz Dysarz

dr hab. inż. Tomasz Dysarz, prof. UPP

Faculty of Environmental and Mechanical Engineering
Poznan University of Life Sciences
e-mail: tomasz.dysarz@up.poznan.pl

Poznań, 21.09.2026 r.

Review of

Doctoral Dissertation written by Khansa Gulshad

From Flood Dynamics to Nature-Based Solutions: A Geospatial AI Framework for Urban Resilience

Od dynamiki powodzi do rozwiązań opartych na przyrodzie: geoprzestrzenne ramy sztucznej inteligencji dla odporności miast

1. Formal and legal basis

The formal basis for preparing the review is the invitation letter written by prof. dr hab. inż. Ewa Wojciechowska, the Dean of the Faculty of Civil and Environmental Engineering at Gdansk University of Technology (l.dz. 605/WILiŚ/2026). The evaluation was conducted based on the doctoral dissertation prepared in English by the PhD Candidate, Ms. Khansa Gulshad. Prof. dr hab. inż. Michał Szydłowski, from the Department of Geotechnical and Hydraulic Engineering at Gdansk University of Technology, is the supervisor of the dissertation. The dissertation was submitted in both paper and digital forms to the Council of the Discipline of Civil Engineering, Geodesy, and Transport at Gdansk University of Technology. The review was conducted in accordance with the requirements outlined in Article No. 187 of the Act on Higher Education and Science of July 20, 2018 (POL-2018-R-109017), as amended by subsequent regulations (POL-2018-R-109019).

2. Overview of the conducted research

The main subject of the study is the modeling of flood hazard, with special emphasis on urban flooding. The research is focused on implementing modern technologies such as geoprocessing, hydrological modeling, and especially Machine Learning/Deep Learning (ML/DL) methods. In her dissertation, the PhD Candidate correctly identifies the greatest gap that exists in this field currently, i.e. the implementation of ML/DL methods to generate flood susceptibility maps without properly accounting for the physical principles governing water flow in natural environments. The second interest is related to the development of Nature-based Solutions (NbS) and planning Green Infrastructure (GI) in

cities. In this area, the investigations are focused on connecting existing computer vision methods with effective planting strategies, which is also one of today's challenges. The main concept of this doctoral dissertation is to integrate the methods currently used in flood risk analysis and urban water management and to develop a coherent methodology that enables efficient management of urban infrastructure. This concept goes beyond the standalone application of ML/DL methods—which is currently the most common practice—and instead seeks to implement them while giving due consideration to hydrological processes and hydraulic interactions within the system under study.

To illustrate the importance of a integrated approach, this thesis uses the city of Gdansk as a case study. Taking into account the historical flood experiences in Gdansk, the choice is reasonable. As indicated in the thesis, the flood hazard in the city is composed of three different factors: (1) surface runoff from post-glacial moraine hills, (2) river outflow during intense precipitation events, and (3) rising sea levels in the Gulf of Gdańsk. The PhD Candidate also noticed that *"[...] no study applied to a coastal city has yet integrated these [*mentioned previously*] components [...]."*

Hence, the importance of the presented research is unquestionable. The goals are properly defined, and the novelty is clearly indicated. The applied methods are advanced and consistent with current practices and research. The procedure ensures that the results are valid and that the defined purposes are properly met.

3. Analysis of the dissertation

The submitted dissertation comprises 9 regular chapters, 3 appendices, the list of abbreviations (82 items), the abstract, and references. At the beginning of the dissertation, there are also the graphical abstract and the acknowledgments, with a statement about the lack of substantial funding from external sources. The formal statements are added before the title page. The dissertation includes 51 figures, 30 tables, and 57 equations, most of which appear in the main chapters. Adding list of figures and list of tables would improve readability. There are 288 references, including 218 papers in scientific journals. Some repetitions in the list of references were detected. The problem is described in the detailed remarks.

Chapter 1, entitled "*Introduction,*" presents the problem and illustrates all its different facets. The PhD Candidate starts with a general overview of the modern challenges related to climate change and increasing flood risk, which is supported by examples of past urban floods in Gdansk. Next, the description is focused on the first major concern in this research: the variability of methods for modeling hydrological hazards. The PhD Candidate leads discussion from more physically oriented models like HEC-HMS to modern data-driven methods, including AI algorithms. The second concern is the spatial planning of Nature-based Solutions (NbS) and Green Infrastructure (GI) in the city. The author precisely identifies the main gaps in these two areas and briefly explains the approach applied in the presented research. Then the purpose of the research is formulated:

"*[…] to demonstrate that GeoAI, […], can directly support transparent, equitable, and evidence-based urban adaptation.*"

Additionally, the PhD Candidate indicates that this is not only a methodological advancement in urban hydrology and GI planning, and that the key to success is applying GeoAI in a structured, integrated pipeline rather than as a collection of tools. The scientific tasks are specified as follows:

1. *"To quantify the historical and projected effects of LULC dynamics and climate change on surface runoff at basin and city scale, […]."*
2. *"To develop an interpretable, ensemble machine learning framework, […], to map urban flood susceptibility and identify the dominant spatial drivers of flood."*
3. *"To diagnose the spatial inequity of green infrastructure distribution across Gdańsk […]."*
4. *"To quantify urban greening potential at rooftop and street level […], and to assess the cumulative stormwater retention benefits of integrated GI interventions across design storm scenarios."*

The above statements are sufficient for precise definition of the scientific problem. However, to align with scientific methodology, the research hypothesis could also be stated.

The next chapter, entitled "*State of the art*", describes the current state of knowledge in four specific fields important to the dissertation. The discussion of climate change impacts, changes in land use/land cover (LULC), and applications of hydrological modeling is followed by a discussion of methods for flood susceptibility assessment. This survey also includes specific reflections formulated by the PhD Candidate. Although arguments about time-consuming and calibration problems with hydrologic and hydraulic models are repeated following the scientific literature, the criticism about the black-box nature of AI models is also provided. The latter is totally correct, but it is not usually mentioned in papers on flood susceptibility maps. The next sections illustrate the concept of green infrastructure in cities and its driving factors with examples. The next part discusses the implementation of NbS and GeoAI tools for urban planning.

Chapter 3 is entitled "*Study area and data framework*". In the first passages, the author clearly explains the motivation for choosing Gdansk, the largest harbor in the Baltic Sea, as a case study. The chapter includes details about this area and an interesting discussion of GI implementation in Polish cities. Table 3.1 lists the source data, with references to the subsequent chapters where the data are used. A short discussion with a classification of the different data types could highlight the differences between spatially distributed data and point data, as well as static data and time-variable data. It would be helpful to specify which data come from Polish sources, which come from European services, and which are global.

Chapters 4 to 7 discuss specific methods used in the research. The internal structure of each such chapter is similar. First, each chapter introduces the topic, then describes the methodology, presents specific results, discusses the particular subject, and concludes briefly. The first two chapters (Chapters 4 and 5) are focused on flood modeling using two

approaches: standard hydrological routing and flood susceptibility mapping with AI methods. The next two chapters (Chapters 6 and 7) are focused on green infrastructure and Nature-based Solutions. In the next paragraphs the methodological part is described with more details.

Chapter 4, entitled "*Land Use Dynamics and Hydrological Response*", is focused on changes in land use and land cover in the cities, with special emphasis on Gdansk. The investigations use satellite data from Landsat and Sentinel-2. Google Earth Engine (GEE) was used for data processing. The impact of LULC changes on urban hydrology is then modeled using HEC-HMS. Figure 4.1 illustrates the overall concept, while Figure 4.2 shows the catchment. There are also two equations discussing core elements of the method applied for calculating abstractions, namely NRCS-CN (previously known as SCS-CN). According to the text, the SCS-CN version of the unit hydrograph models the transformation of excess rainfall into watershed outflow, and the Muskingum model is applied for flow routing in the channels. Because these methods are not the default choice in the applied software, it would be good to justify choice of them and provide their parameters briefly. It is also unclear what baseflow model was chosen. Table 4.1 summarizes the simulation configuration, while Table 4.2 briefly explains the climate change scenarios. The PhD Candidate focused on projections related to RCP4.5 and RCP8.5 scenarios recommended by the IPCC (Intergovernmental Panel on Climate Change). The results are discussed using 3 tables and 10 figures. In my opinion, the maps showing historical LULC changes and trends may have high practical importance. The results of the hydrological section are mainly focused on changes in the runoff coefficient, which could help design water management facilities.

The next chapter, "*Flood Susceptibility Mapping with Interpretable ML*", describes ML/DL methods applied to determine flood-prone areas in the city. Figure 5.1 presents the overall approach. The author trained models of three different types: Support Vector Machine (SVM), Random Forest (RF), and Artificial Neural Networks (ANN). The data about interventions during floods in the period of 12 years (2010-2022), obtained from the State Fire Station and Gdansk Water Company, are the basis for the learning process. The driving factors are classified as physical and anthropogenic. The SHapley Additive exPlanations (SHAP) is applied for specific sensitivity analysis. In the chapter, there are 21 equations explaining key elements of the models and defining the statistical metrics. Table 5.1 summarizes the model parameters selected in this research. The results are shown in 4 tables and 9 figures. Figure 5.9 presents the final susceptibility maps, while Figure 5.10 shows only the areas prone to flash floods.

The focus on concept of green infrastructure and Nature-based Solutions begins in Chapter 6, "Spatial Distribution and Determinants of Green Infrastructure." Figure 6.1 illustrates the methodology elements, and 9 pivotal equations support their description. In general, the stages include data collection, three steps of data processing, and analysis of results presented at the end. The three-step data processing consists of preprocessing, including the choice of resolution, spatial autocorrelation, and regression between GI

density and "*explanatory factors*". The grid with 1 km resolution is used to represent spatial distribution of GI density across the city. The methods for calculating autocorrelation are used to check whether GI density values are spatially clustered, dispersed, or randomly distributed. The regression between GI density and "*explanatory factors*" is processed in the Python Colab environment. The methodology used is advanced and ensures accurate results with practical significance. The examples are presented in 6 figures and 2 tables. Appendix B includes the rest of results. It is worth to highlight that chapter 6 includes results of particular theoretical importance, e.g., graphs presenting correlations between explanatory factors (Figure 6.4) and a comparison of regression model performance (Table 6.2). However, there are also results of high utility for practitioners, e.g., a map of GI distribution (Figure 6.2), a map of GI priority areas (Figure 6.7).

Chapter 7, "*GeoAI Framework for NBS Suitability & Stormwater Analysis*", describes the application of GeoAI tools for robust planning of Nature-based Solutions such as blue-green roofs (BGR), street-level greenery, and street trees, and then presents the estimation of retention and interception in the city. The methodology applied combines geoprocessing procedures, image processing and recognition, and ML/DL methods. The entire procedure is presented with a diagram in Figure 7.1. Different kinds of models are implemented at this stage of investigations, e.g., Mask2Former, XGBoost, and RESILO. The description of the methodology is supported by 8 equations and one table (Table 7.1), which includes a short characteristic of tested rainfall scenarios. In general, the methodology implemented in the models could be described more extensively. The results are presented and illustrated with 5 figures and 2 tables. The figures include examples of maps and city images (ground-level photos) that illustrate the implemented concepts. There are more results in Appendix C. The tables show the characteristics of retention reduction and interception impact. Two publicly available web services, called *GreenRoofs* and *GreenStreets*, are the effect of the analyses, too.

The integration of the above concepts is located in Chapter 8, "*Synthesis, Implications & Transferability*". It starts with a graphical summary of the previously explained ideas (Figure 8.1). The chapter is a broad discussion, but conclusions come in the following Chapter 9. The PhD Candidate leads this discussion from a synthesis of the methodological chapters, through reflections on the methodological contribution made by the GeoAI framework, and considerations about its uncertainty and robustness. The recommendations for the city of Gdansk are presented in three tables, including policy recommendations, implementation pathways, and spatial conflicts.

In the chapter 9, "*Conclusion and Future Research*", in the first steps it is proved that the purpose of the research was achieved and explains how it was done. Then the focus is on the scientific problems defined in the Introduction. Chapter 4 presents the first, quantification of LULC dynamics and the effects of climate change on surface runoff, what is the scientific problem no. 1. The next chapter illustrates flood susceptibility assessment in the urban environment, which is problem no. 2. Chapter 6 is focused on problem no. 3,

i.e., green infrastructure distribution across the city of Gdansk and its relationship to hydrological characteristics. Finally, Chapter 7 determines urban greening potential, taking into account the benefits of cumulative stormwater retention, which is problem no. 4. Additionally, the author emphasized some specific innovations achieved during research, e.g., the application of "*a scenario-based GPS (greening potential score) framework that links green roof technical feasibility to planning constraints*." Next, the limitations of the study are summarized and briefly discussed. The author presents observations and suggestions that go beyond current practice and the state of knowledge, e.g., she suggests that flood type is not taken into account in flood susceptibility mapping, but the obtained results indicate significance of this factor. Finally, the author presents the conclusions and highlights the "most important finding": combining the four more-or-less distinct methods into a single procedure. According to the reviewer's knowledge, this is exactly the current concern in the discipline and the purpose to achieve for many scientists working in the field of flood risk management. Hence, innovative character of the proposed methodology is obvious.

It is worth highlighting that describing the methodology in four separate chapters has a definitely better effect than following the typical scheme: *materials-methods-results-discussion*. The presented description is clear and understandable. The connections between elements are well defined and finally synthesized in Chapter 8.

4. Remarks and questions

Major remarks and questions

A. The hydrological components are present in the hydrodynamic models now. Software such as HEC-RAS or Iber can simulate 2D flow over specific areas, including rainfall and infiltration. Is it possible that a model based on the full mass and momentum balance equations, e.g., shallow water equations, give more interesting results? How such a model could be verified on the data used in the current research?

B. The bimodality of the graph representing dependence of the frequency on distance from the river channel (Figure 5.2) suggests that there are fluvial and non-fluvial floods in the dataset. Supposedly, inundations at long distances from the river were caused by rainfall and surface runoff or failure of the collectors. In the Conclusions, there is a comment about the role of the flood type (in section "*9.1. Limitations and future research*"). How could this aspect impact the flood susceptibility maps presented? Is it possible that the distribution of flood susceptibility areas the city is different if the flood type is taken into account?

C. Is it possible to use satellite images of the historical floods to calibrate ML/DL models? Would such a model still produce a flood-susceptibility map, or could it simulate the flood process and produce a full flood hazard map?

D. A new class of methods appears in the field of hydrological modeling, namely physics-informed neural networks (PINN). It integrates classical deep learning based on artificial neural networks with physically based modeling based on classical balance principles (mass, momentum, etc.). Is it possible to implement such concepts in the framework presented here?

Additional remarks and questions

(1) It would be good if the hypothesis behind the conducted research is formulated and the conclusions refer to it.

(2) Why is the river network taken from the global service OpenStreetMap? Was it not possible to obtain such data from the Polish MPHP (Polish: *Mapa Podziału Hydrograficznego Polski*)? Which of the sources is more accurate?

(3) The analysis is done for the city, which requires spatial data at a finer resolution or highly accurate vector layers. However, some raster data describing LULC and vegetation indices (NDVI, NDWI) have a rather coarse resolution (30 m, 100 m). Has it impacted the results?

(4) What are the parameters of the particular models applied in HEC-HMS, namely the unit hydrograph based on SCS-CN and the Muskingum model? What model was chosen for baseflow? What kind of formula and definition is adopted for widely used runoff coefficient?

(5) Different measures are mentioned for evaluation of the ML/DL models' performance (RMSE, MAE, ACC, etc.). Which were used during training (70% of cases), and which were used for verification (30% of cases)? What kind of training method was implemented, e.g., gradient methods, simple search methods, global optimization, trial-and-error?

(6) Is the application of Google Colab as a Python environment motivated by the modules available there? Is it possible to make the same analysis in a standard Python environment with `pip` or `conda` for package management?

(7) Generally, it would be good if the different models used in Chapter 7, i.e., Mark2Former, XGBoost, and RESILO, were better described.

Detected problems and technical inaccuracies

(1) Some elements should be mentioned in the Contents:

   a. the graphical abstract (page 6)
   b. the acknowledgments (page 7)
   c. the References (page 150)
   d. the Appendices (start on page 172)

(2) In the Introduction (page 17), one and the same concept is formulated twice as follows:

"*Machine learning and explainable artificial intelligence offer a pathway beyond these modelling limitations, but their transformative potential lies not in applying them individually, but in chaining them with remote sensing and hydrological analysis into a coherent analytical pipeline.*"

And the following sentence:

"*Machine learning models offer a pathway beyond these modelling limitations, but their transformative potential lies in chaining them with remote sensing and hydrological analysis into a coherent pipeline rather than applying them individually [...]*"

(3) Figure 3.1: The scale of the DEM in the top could be rounded, e.g., from -20 to 180 m a.s.l.

(4) It's not quite clear what kind of unit [ms] is used in the sentence "*Storm surges, [...], can raise sea levels by over 1.5 ms, with projections indicating potential surges reaching up to 2.5 ms*." (page 32).

(5) Table 3.1: The description in the second column (Resolution & Year) is a little bit confusing. The scale of the map (e.g., soil map) represents the level of detail, not resolution. Additionally, the vertical accuracy could be provided in the case of DEMs.

(6) Figure 4.1: The fonts used in the descriptions should be larger. These are not clearly visible.

(7) Figure 4.2: The scale of the DEM could be rounded, e.g., from 0 to 160 m a.s.l.

(8) Wrong figure number in Chapter 4 on page 46. There is "Figure 2.3" instead of "Figure 4.3".

(9) Figure 5.1: The flowchart is a little bit complex. It's not so clear what the direction of information is in this chart.

(10) Figure 5.2: The graphs for Soil and LULC should be presented and interpreted in a different way than the graphs for other elements. Soil and LULC represent discontinuous, unordered characteristics. Additionally, the vertical axis representing frequency should have the same scale. Maybe it would be better to use relative frequency to keep the vertical values between 0 and 1.

(11) Figure 6.4: It's not clear what PR1, PR2, PR3, and PR4 are in the list of dependent variables. Are these projected precipitations related to scenarios RCP4.5 and RCP8.5 determined for the periods 2021-2050 and 2071-2100?

(12) In section 6.1.4, the term "*explanatory factors*" is used. This term should be explained here. The "*factors*" are mentioned in the Introduction (page 26), but these are not called "*explanatory*". For the reader not familiar with terminology used in regression methods, this statement might be confusing. In my opinion, it should be clarified in the text.

(13) In the description of equation 7.3, the term "*proportion*" is used. However, the context suggests that "*ratio*" would fit better.

(14) Wrong figure number in Appendix A on page 174. There is “Figure 3” instead of “Figure A.2”.

(15) Wrong number in Figure C.2 in Appendix C on page 189. There is “Figure C4” instead of “Figure C.2”

(16) There are some repetitions in the list of references, e.g.:

44 Cheng, B., Misra, I., Schwing, A.G., Kirillov, A., Girdhar, R., 2022a. Masked-attention mask transformer for universal image segmentation, in: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. pp. 1290–1299.

45 Cheng, B., Misra, I., Schwing, A.G., Kirillov, A., Girdhar, R., 2022b. Masked-attention mask transformer for universal image segmentation, in: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. pp. 1290–1299.

(17) There are also some formatting problems in the list of references, e.g.:

73 Ewelina, C., Liliana, J., Katarzyna, K., Mateusz, K., Wojciech, Ł., Aleksandra, Ł., Piotr, O., Karolina, P., Paweł, P., Agnieszka, R., Agnieszka, S., Magdalena, Z., 2021a. Raport o stanie polskich miast. Środowisko i adaptacja do zmian klimatu / Report on the State of Polish Cities: Environment and Adaptation to Climate Change. Warszawa – Kraków.

5. Final evaluation of the dissertation

The research problem has been correctly defined. Its significance is beyond doubt, and the methods used are advanced and consistent with the current state of knowledge. No serious errors or shortcomings were detected. The problem addressed is highly complex, and the scope of the analyses conducted is very broad. The choice of an advanced and diverse methodology is fully justified. All these elements together make the submitted doctoral dissertation original and highly innovative. The results represent a valuable contribution to the state of the art and hold enormous practical potential. The presented methodology can be directly applied in Gdańsk and easily adapted to other locations. Some of the results are already available to potential stakeholders and decision-makers through professionally designed websites. This also serves as a strong example of how to organize public communication.

The research topic is a critical issue in Civil Engineering, Geodesy, and Transport. The dissertation emphasizes the importance of accurate hydrological assessment and identifying flood-prone areas in planning and designing urban infrastructure. Consequently, it has a significant impact on other fields of scientific research and practice, such as hydrology, flood protection, and land-use planning. The usefulness of green infrastructure and nature-based solutions has been clearly demonstrated. Furthermore, the study illustrates the potential of GeoAI tools in land-use planning and management. The analyses conducted contribute to a better understanding of processes, impacts, and management practices in the urban environment. They may also influence the further development of hydrological and hydrodynamic modeling, as well as the application of Machine Learning and Deep Learning methods in hydrology.

6. Conclusions

Overall, the doctoral dissertation is a valuable contribution to research on urban flood modeling, flood prevention, and spatial planning of flood protection infrastructure. The dissertation also demonstrated the potential application of the results. The PhD Candidate has demonstrated substantive knowledge and a deep understanding of the professional literature in formulating the goals of the work, conducting research and analyzing results. In my opinion, the PhD dissertation deserves distinction due to its broad scope and advancement of the presented research, its importance to science, and its practical usefulness.

The PhD thesis submitted by Ms. Khansa Gulshad meets all the requirements for doctoral dissertations by the Act of 20 July 2018 Law on Higher Education and Science. Based on my positive assessment, I recommend to the Chairman of the Scientific Council of the Discipline of Civil Engineering, Geodesy and Transport to admit Ms. Khansa Gulshad to the next stages of the doctoral dissertation process, including public defense of the dissertation.

T. Dysarz

Tomasz Dysarz