

Wprowadzenie

Cel badań i zarys osiągniętych wyników

W ostatnich dwudziestu latach całkowicie zmienił się sposób korzystania z map, a także sposób ich opracowywania. Użytkownicy odchodzą od klasycznych map papierowych na rzecz map cyfrowych. Internetowe serwisy mapowe takie jak Google Maps oraz OpenStreetMap wypierają papierowe mapy topograficzne w większości zastosowań profesjonalnych oraz codziennych. Wymienione serwisy internetowe oferują usługi wymiany, udostępniania, zapewniania dostępu i wykorzystywania danych przestrzennych lub ich metadanych. Choć takie usługi internetowe zapewniają niezwykle aktualny obraz świata zewnętrznego, co niewątpliwie stanowi ich mocną stronę, to z punktu widzenia zasad tradycyjnej kartografii zawierają one wiele błędnych rozwiązań redakcyjnych.

Ze względu na dostępność dużej ilości danych, czyli erę tzw. *big data* (Batty, 2013; Dangermond i Goodchild, 2019; Liu i inni, 2022), a także powszechny dostęp do technologii geoinformatycznych zatarciu ulega granica między redaktorem a użytkownikiem mapy. Przejęcie przez użytkownika roli redaktora mapy staje się łatwiejsze, gdyż technologia geoinformatyczna jest coraz bardziej powszechna. W internecie dostępne są materiały – w postaci instrukcji i filmów – wspomagające opracowanie map. Sprawia to, że na podstawie ogólnodostępnych materiałów, otwartych danych przestrzennych oraz darmowego oprogramowania mapy mogą opracowywać – oprócz doświadczonych redaktorów – także niedoświadczeni użytkownicy. Zjawisko to określa się terminami *citizen science* (Haklay, 2013; 2021) oraz *neogeography* (Goodchild, 2009). Niestety niedoświadczonym użytkownikom często brakuje wiedzy niezbędnej do poprawnej redakcji map, co powoduje, że opracowywane przez nich mapy i wizualizacje kartograficzne mogą być nieczytelne, niespójne i niezrozumiałe dla szerszego grona odbiorców.

Do poprawnej redakcji map potrzebne są kompleksowa wiedza i doświadczenie z zakresu grafiki, percepcji oraz redakcji map. Wiedza dotycząca poprawnego doboru i logicznego upraszczania treści mapy, stanowiąca zaawansowany proces decyzyjny, kompetencja dotycząca sztuki takiego doboru kolorów, aby mapa była czytelna i zrozumiała dla odbiorcy, a także świadomość ograniczeń i możliwości percepcyjnych użytkownika, która jest kluczowa, lecz nie jest możliwe zapisanie jej w jednej,

a nawet w kilku instrukcjach, to wiedza ekspercka, o charakterze kompleksowym. Zależna od konkretnego kontekstu graficznego i zarazem oparta na doświadczeniu redaktora zdobytym przez lata manualnej redakcji różnych opracowań.

Kolejna istotna zmiana to opracowywanie i wyświetlanie map na coraz mniejszych ekranach – tabletach, smartfonach, a nawet smartwatchach. Użytkowanie map na coraz mniejszych urządzeniach wymaga zmian w sposobie ich opracowywania: odpowiedniego dostosowania procesu ich projektowania, uwzględnienia interaktywności, zapewnienia możliwości efektywnego zmniejszania i zwiększania skali (*zoom*), a co za tym idzie wyświetlania map na różnych poziomach szczegółowości, czyli w różnych skalach (Touya i inni, 2023b).

Dostosowanie mapy cyfrowej do wyświetlania na różnych poziomach szczegółowości wymaga wiedzy z zakresu redakcji i szczególnego przestrzegania zasad generalizacji kartograficznej. Generalizacja kartograficzna to zasadniczy etap procesu redagowania mapy. Polega on na podjęciu decyzji, które z obiektów powinny pozostać na mapie, a które należy pominąć oraz w jaki sposób obiekty pozostawione na mapie powinny być wizualizowane. Generalizacja jest niezbędna przy zmniejszaniu skali map i wymaga uwzględnienia przeznaczenia mapy oraz możliwości i ograniczeń użytkowników (Kraak i inni, 2020). Jest to zaawansowany proces decyzyjny, w którym uwypuklane są istotne cechy obiektów oraz ich kontekst geograficzny, czyli relacje między nimi. Każda mapa w mniejszym lub większym zakresie wymaga generalizacji kartograficznej. Autorzy wcześniejszych badań dotyczących percepcji map wskazywali, jak projektować papierowe mapy topograficzne w określonej skali, aby były czytelne i zrozumiałe dla użytkowników (Robinson i inni, 1988; Ratajski, 1989; Saliszczew, 1998; Żyszkowska, 2000; Tyner, 2014). Zasady te jednak nie w pełni mają obecnie zastosowanie, ponieważ kartografom brakuje wytycznych, aby opracowywać mapy, które są możliwe do eksploracji w różnych skalach.

Z uwagi na wizualizację dużej ilości danych bezpośrednio w serwisach internetowych, takich jak Google Maps czy OpenStreetMap, oraz istniejące tam narzędzia interaktywne pozwalające na dowolne pomniejszanie widoku mapy użytkownik, eksplorując dane, a zwłaszcza je pomniejszając, przez kilka pierwszych sekund po interakcji czuje się zagubiony (Touya i inni, 2023a). Dzieje się tak, gdyż brakuje efektywnych narzędzi do generalizacji (wyboru i uogólnienia) danych w czasie rzeczywistym, w wyniku czego pomniejszanie skali daje efekt nałożenia różnych obiektów lub pomijania istotnych i charakterystycznych danych. W literaturze ten stan określa się mianem bałaganu graficznego (*visual clutter*) (Ellis i Dix, 2007; Korpi i Ahonen-Rainio, 2013; Opach i inni, 2019).

W ostatnich dziesięciu latach znacząco zmienił się proces generalizacji kartograficznej. Wynika to z faktu, że coraz większą rolę w tym procesie zaczęło odgrywać zastosowanie sztucznej inteligencji (*artificial intelligence*, AI), w tym klasycznego uczenia maszynowego (*machine learning*, ML) oraz uczenia głębokiego (*deep learning*, DL) (Harrie i inni, 2024; Kang i inni, 2024; Yan i inni, 2025). Autorzy publikacji z ostatnich lat mówią nawet o nowym paradygmacie w generalizacji kartograficznej, jakim jest uczenie głębokie, które zasadniczo usprawni proces generalizacji,

pozwalając na jego pełną automatyzację i optymalizację (Touya i inni, 2019). Aby podążać za tym paradygmatem, potrzebne są nowe zasady generalizacji, wiedza na temat tego, jak użytkownicy postrzegają i rozumieją mapy opracowane z wykorzystaniem sztucznej inteligencji, oraz gruntowna weryfikacja map wykonanych z wykorzystaniem AI (Lisiewicz i Karsznia, 2021; Ajdacka i Karsznia, 2022a; Karsznia i inni, 2024b). Są to elementy niezbędne, aby zweryfikować istniejące oraz opracować nowe zasady redakcji i generalizacji map.

Obecnie możliwe jest wykorzystanie AI oraz ML i DL do generalizacji kartograficznej wybranych obiektów na mapach, np. selekcji (wyboru) miejscowości, dróg, rzek (Karsznia i Weibel, 2018; Karsznia i Sielicka, 2020; Karsznia i inni, 2022a; 2022b; 2024a; Ajdacka i Karsznia, 2022a; 2022b; Chaode i inni, 2022; Le Mao i inni, 2024), upraszczania i agregacji (łączenia) budynków (Sester i inni, 2018; Feng i inni, 2019; Fu i inni, 2024; Zhiyong i inni, 2024) czy upraszczania przebiegu dróg i rzek (Sen i Gokgoz, 2015; Courtial i inni, 2020; 2021; 2022; Courtial i Touya, 2022; Du i inni, 2022a; 2022b; Yu i inni, 2023). Nie opracowano jednak dotychczas rozwiązań i algorytmów AI pozwalających na automatyczne i optymalne opracowanie mapy ogólnogeograficznej o pełnym zakresie treści. Nie ma zatem jeszcze systemu, narzędzia czy też oprogramowania pozwalającego na automatyczne, zgodne z metodyką kartograficzną opracowanie pełnej pod względem treści mapy ogólnogeograficznej oraz efektywnych narzędzi jej automatycznej generalizacji do skal mniejszych. Podejmowane próby dotyczą jedynie pojedynczych klas obiektów (dróg, budynków lub rzek).

W opracowaniu skoncentrowano się na kluczowym etapie procesu generalizacji kartograficznej, czyli wyborze (selekcji). Jest to pierwszy i zasadniczy, jednak nie jedyny etap generalizacji. Po etapie selekcji następują kolejne, dotyczące generalizacji ilościowej i jakościowej, takie jak agregacja (łączenie), upraszczanie, wygładzanie. Przedmiotem niniejszych badań są trzy wybrane, a zarazem najważniejsze warstwy tematyczne składające się na treść mapy ogólnogeograficznej, czyli miejscowości prezentowane w postaci sygnatur punktowych, sieć drogowa oraz sieć rzeczna. Oczywiście pełna treść mapy to również kontury miejscowości, kontury lasów, jeziora, rzeźba terenu oraz inne elementy. Nie są one jednak przedmiotem niniejszych badań, lecz niewątpliwie należy rozważać je w przyszłych pracach w tym zakresie w celu zaproponowania rozwiązań jak najbardziej holistycznych, obejmujących pełną treść mapy. W opisanych badaniach podjęto problematykę automatyzacji generalizacji kartograficznej, w szczególności selekcji w ciągu skalowym, wychodząc od skali 1:250 000 i prowadząc generalizację do skal 1:500 000 oraz 1:1 000 000.

Zawarte w opracowaniu badania mają charakter interdyscyplinarny. Koncentrują się wokół zagadnień z pogranicza kartografii, geoinformatyki, informatyki, w tym nauki o danych (*data science*), oraz geografii społeczno-ekonomicznej. Przedmiotem badań są elementy o charakterze zarówno antropogenicznym, jak osadnictwo, sieć drogowa (jako element związany z transportem), jak i naturalnym, czyli sieć rzeczna (element hydrologiczny). Z uwagi na interdyscyplinarny charakter badań oraz ich zakres przedmiotowy dyscyplina, jaką jest geografia społeczno-ekonomiczna i gospodarka przestrzenna, stanowi optymalną i cenną ramę merytoryczną dla prowadzonych analiz.

Bezpośrednią inspiracją, a zarazem motywacją do podjęcia niniejszych badań był brak kompleksowych rozwiązań opartych na AI oraz bazie wiedzy kartograficznej, odpowiednio sformalizowanej, zaimplementowanej i wykorzystanej w tym celu w środowisku komputerowym. Tę lukę badawczą starano się wypełnić w badaniach przedstawionych w niniejszym opracowaniu. Stanowią one jedną z pierwszych prób optymalizacji redakcji podstawowej treści mapy ogólnogeograficznej (1) w sposób w pełni automatyczny, (2) oparty na odpowiednio sformalizowanej wiedzy kartograficznej, a więc optymalny, i (3) z wykorzystaniem najbardziej zaawansowanych algorytmów AI, ML i DL.

Ogólnym celem badań była optymalizacja jednego z kluczowych elementów redakcji map, jakim jest generalizacja kartograficzna. Motywację do podjęcia badań stanowiły wyzwania oraz luki badawcze obejmujące następujące aspekty:

- W dotychczas zaproponowanych rozwiązaniach metodycznych i opracowanych narzędzi służących automatyzacji procesu generalizacji kartograficznej koncentrowano się na szczegółowych bazach danych oraz mapach w skalach dużych, topograficznych.
- Obecnie rozwijane programy oraz narzędzia służące wspomaganemu, w szczególności formalizacji oraz automatyzacji procesu generalizacji, oparte na zaawansowanych algorytmach sztucznej inteligencji oraz uczenia maszynowego opracowywane są z wykorzystaniem danych rastrowych, brakuje natomiast rozwiązań dla baz danych wektorowych.
- Sztuczna inteligencja i uczenie maszynowe były już wprawdzie przedmiotem badań w zakresie automatyzacji generalizacji kartograficznej, jednak technologia nie była na tyle rozwinięta, aby rozwiązania te mogły zostać w pełni zaimplementowane w środowisku komputerowym. Brakuje narzędzi i algorytmów wspomagających automatyzację procesu generalizacji dla skal małych, przeglądowych, niezbędnych do opracowania spójnej oraz sformalizowanej metodyki generalizacji w tych skalach.

Niniejsze badania stanowią istotny etap zmierzający do opracowania spójnej metodyki redakcji map w skalach małych (przeglądowych) oraz zaproponowania i weryfikacji narzędzi przeznaczonych do automatyzacji jednego z jej kluczowych elementów, jakim jest generalizacja kartograficzna. W badaniach skupiono się na pierwszym i kluczowym etapie generalizacji kartograficznej, mianowicie selekcji prezentowanej treści. Selekcji poddano trzy najważniejsze warstwy tematyczne mapy małoskalowej: miejscowości, drogi oraz rzeki. W badaniach przyjęto założenie, że wynik automatycznej selekcji wymienionych rodzajów obiektów będzie optymalny, jeżeli zostanie ona przeprowadzona w taki sposób, aby jej wynik był jak najbliższy mapom redagowanym ręcznie przez doświadczonych kartografów¹.

¹ Przez doświadczonych kartografów autorka monografii rozumie osoby z wieloletnim stażem w zakresie redakcji map, w szczególności pracowników Katedry Kartografii UW oraz autorów atlasu opracowanego w Polskiej Akademii Nauk, m.in. dr. hab. Wiesława Ostrowskiego i mgr. Jerzego Ostrowskiego.

Istotny aspekt badań obejmuje usprawnienie procesu generalizacji kartograficznej poprzez jego formalizację, rozumianą jako uspoźnienie i zestandaryzowanie w celu automatyzacji.

Ważną część badań stanowi eksploracja procesu generalizacji obejmująca weryfikację istniejących i wskazanie nowych, istotnych zmiennych charakteryzujących generalizowane obiekty oraz zaproponowanie dodatkowych zasad selekcji, które powinny stanowić uzupełnienie zasad zawartych w obowiązujących aktach prawnych, a więc w Rozporządzeniu Ministra Spraw Wewnętrznych i Administracji z dnia 17 listopada 2011 r. w sprawie bazy danych obiektów topograficznych oraz bazy danych obiektów ogólnogeograficznych, a także standardowych opracowań kartograficznych (MSWiA, 2011) oraz Rozporządzeniu Ministra Rozwoju, Pracy i Technologii z dnia 27 lipca 2021 r. w sprawie bazy danych obiektów topograficznych oraz bazy danych obiektów ogólnogeograficznych, a także standardowych opracowań kartograficznych (MRPiT, 2021).

Istotnym elementem przeprowadzonych badań był także proces wzbogacania danych źródłowych (*data enrichment*). Wzbogacanie danych polega na dodaniu istotnych zmiennych charakteryzujących obiekty podlegające procesowi generalizacji, tak aby uwzględnić cechy, którymi kierują się doświadczeni kartografowie opracowujący mapę ręcznie.

W realizowanych badaniach postawiono trzy hipotezy:

- Hipoteza pierwsza: metodyka oparta na wzbogacaniu danych oraz modelach uczenia maszynowego, stanowiących elementy sztucznej inteligencji, umożliwi optymalizację procesu selekcji.
- Hipoteza druga: implementacja modeli uczenia maszynowego oraz elementów teorii grafów pozwala na uwzględnienie wiedzy kartograficznej wykorzystanej przy manualnym opracowaniu map.
- Hipoteza trzecia: zastosowanie modeli uczenia maszynowego umożliwi formułowanie nowych, istotnych zasad generalizacji uzupełniających istniejącą wiedzę kartograficzną.

Badania dotyczyły automatycznej selekcji miejscowości, dróg oraz rzek stanowiących podstawowe kategorie treści Bazy Danych Obiektów Ogólnogeograficznych (BDOO), opracowanej na poziomie szczegółowości 1:250 000 do skal 1:500 000 oraz 1:1 000 000. W badaniach wykorzystano elementy sztucznej inteligencji, w szczególności wybrane modele uczenia maszynowego oraz elementy teorii grafów.

Badania mają charakter poznawczo-koncepcyjny i w tym aspekcie obejmują prace o charakterze metodycznym. Mają również wymiar aplikacyjny, ponieważ dotyczą implementacji zaproponowanych metod oraz ich weryfikacji. W celu eksploracji, poznania oraz automatyzacji procesu selekcji na różnych etapach badań zaimplementowano i zweryfikowano następujące modele uczenia maszynowego: drzewa decyzyjne (*decision trees*, DT), drzewa decyzyjne wspomagane algorytmami genetycznymi (*decision trees and genetic algorithms*, DT-GA), maszynę wektorów nośnych (*support vector machine*, SVM), las losowy (*random forest*, RF), sztuczne sieci neuronowe (*artificial neural network*, ANN) oraz uczenie głębokie (*deep learning*, DL).

Rezultatem przeprowadzonych badań jest przede wszystkim metodyka automatycznej selekcji miejscowości, dróg oraz rzek opracowana w celu optymalizacji redakcji map w skalach małych z wykorzystaniem wybranych modeli uczenia maszynowego. Opracowana metodyka pozwala na pełną automatyzację procesu selekcji miejscowości, dróg i rzek ze skali 1:250 000 do skal 1:500 000 oraz 1:1 000 000. W ramach opracowanej metodyki wskazano cechy miejscowości, dróg oraz rzek, które stanowią kluczowe zmienne decyzyjne w procesie selekcji. Zastosowanie modeli uczenia maszynowego umożliwiło także eksplorację i wskazanie wielu dodatkowych zasad selekcji, które stanowią istotne, a nawet niezbędne uzupełnienie zasad zawartych w obowiązujących instrukcjach redakcji map (MSWiA, 2011; MRPiT, 2021). W ramach opracowanej metodyki wykonano również analizę istotności wykorzystanych zmiennych, określając ich wagi oraz korelacje między nimi.

Istotnym wynikiem badań, który może zostać wykorzystany w praktyce, jest również przeprowadzona weryfikacja zmiennych oraz zasad selekcji miejscowości i dróg zawartych w obowiązujących instrukcjach redakcji map, które dotychczas nie zostały kompleksowo sprawdzone. W ramach tego etapu sformalizowano i zaimplementowano z wykorzystaniem odpowiednich narzędzi geoinformatycznych instrukcje redakcji miejscowości, dróg oraz rzek. Instrukcje te zawarte są w rozporządzeniach MSWiA (2011) oraz MRPiT (2021). Implementację wykonano z wykorzystaniem programu ArcMap 10.8, w szczególności z użyciem funkcjonalności aplikacji Model Builder, pozwalającej na budowę modeli generalizacji i automatyzację tych procesów.

Kluczowym wynikiem badań podnoszącym ich wartość aplikacyjną są narzędzia informatyczne służące do automatycznego wzbogacania danych, opracowane w postaci skryptu w języku programowania Python, oraz modele automatycznej selekcji miejscowości, dróg i rzek opracowane z wykorzystaniem programu do eksploracji danych RapidMiner v. 9.

Modele automatycznego wzbogacania danych oraz modele generalizacji osadnictwa oparte na algorytmach uczenia maszynowego zastosowane w niniejszych badaniach zaproponowano i oprogramowano w ramach stażu doktorskiego na Uniwersytecie w Zurichu, realizowanego od 15 lutego 2014 r. do 30 czerwca 2015 r. (grant nr 12.187 *AutoGenSettleRoad: Automation of the generalization process of settlements and road networks for medium and small-scale maps*). Projekt został sfinansowany przez rząd Szwajcarii w ramach programu SCIEX – Scientific Exchange Programme oraz przez Uniwersytet w Zurichu. Opracowaną metodykę badań oraz narzędzia programistyczne rozwijano w kolejnych pracach badawczych. Projekt realizowano w Instytucie Geografii Uniwersytetu w Zurichu we współpracy z prof. Robertem Weiblem. Narzędzia te rozwijano także we współpracy z prof. Stefanem Leykiem w ramach staży badawczych na Uniwersytecie Boulder w stanie Kolorado, realizowanych od 7 do 13 października 2018 r. oraz od 23 do 29 października 2022 r. Opracowane modele automatycznej selekcji zostały także zastosowane do selekcji dróg oraz rzek na mapach małoskalowych. Uzyskano bardzo dobre rezultaty, znacznie lepsze i bliższe mapom opracowywanym przez doświadczonych

kartografów niż przy zastosowaniu zasad selekcji zawartych w urzędowych specyfikacjach map (MSWiA, 2011; MRPiT, 2021).

Zaproponowane rozwiązania metodyczne oraz aplikacyjne po odpowiednich modyfikacjach mogą zostać wykorzystane dla innych warstw tematycznych, także w obecnie realizowanym projekcie badawczym finansowanym przez Narodowe Centrum Nauki (grant nr UMO2020/37/B/HS4/02605 pt. *Optymalizacja redakcji osadnictwa oraz sieci dróg w skalach przeglądowych z wykorzystaniem sztucznej inteligencji oraz teorii grafów*, akronim: *GeneralizationAI*²). W projekcie rozwiązania te są wykorzystywane do automatycznej selekcji dróg i rzek na mapach małopolskich. Po odpowiedniej modyfikacji opracowana metodyka oraz narzędzia geoinformatyczne mogą zostać wykorzystane do automatycznej selekcji kolejnych warstw tematycznych, również w innych skalach, np. przy automatycznej selekcji obiektów z Bazy Danych Obiektów Topograficznych (BDOT10k) do Bazy Danych Obiektów Ogólnogeograficznych (BDOO). Obecnie proces ten w Głównym Urzędzie Geodezji i Kartografii ma charakter półautomatyczny. Opracowane narzędzia mogą zostać zastosowane do jego pełnej automatyzacji. Ze względu na aplikacyjny charakter oraz możliwość ich uogólnienia i dostosowania do innych danych zaproponowane rozwiązania mogą również zostać wykorzystane w europejskich oraz międzynarodowych agencjach kartograficznych do automatyzacji procesu selekcji obiektów w bazach danych przestrzennych.

Monografia składa się z wprowadzenia, pięciu rozdziałów oraz podsumowania. We wprowadzeniu określono cel i zakres badań oraz przedstawiono zarys osiągniętych wyników. Przedmiotem opisanych badań są generalizacja kartograficzna oraz sztuczna inteligencja, których definicje i rodzaje, zgodne z obecnym stanem wiedzy, przytoczono w rozdziale pierwszym. W rozdziale tym przedstawiono stan badań w obszarze automatyzacji generalizacji kartograficznej oraz zaprezentowano pojęcie sztucznej inteligencji, a także stanowiącego jej poddziedzinę uczenia maszynowego. Scharakteryzowano również podstawowe typy uczenia maszynowego. Zdefiniowano pojęcie generalizacji kartograficznej i sztucznej inteligencji oraz rolę jednego z kluczowych operatorów wchodzącego w skład generalizacji danych, mianowicie selekcji, czyli wyboru lub pominięcia obiektów. Ponadto przedstawiono rolę selekcji w najnowszym modelu generalizacji. Wskazano także źródła wiedzy kartograficznej niezbędnej do pozyskania, formalizacji i implementacji w celu efektywnej generalizacji danych. W rozdziale drugim opisano dotychczasowe próby zastosowania uczenia maszynowego w generalizacji kartograficznej, z podziałem na rozwiązania stosowane dla miejscowości, sieci dróg oraz sieci rzek. W kolejnym rozdziale, trzecim, scharakteryzowano wybrane modele uczenia maszynowego zastosowane w prowadzonych badaniach. W rozdziale czwartym zawarto opis przedmiotu i zakresu prowadzonych badań. Rozdział piąty poświęcony jest szczegółowej charakterystyce metodyki automatycznej selekcji miejscowości, dróg oraz rzek wraz z jej implementacją w postaci skryptów programistycznych, a także opracowanych modeli uczenia maszynowego

² <http://geoinformatics.uw.edu.pl/generalizationai/>

i algorytmów. Monografię zamyka podsumowanie, w którym zawarto syntezę prowadzonych badań, skupiając się na możliwości ich wykorzystania oraz wdrożenia, a także na wskazaniu dalszych kierunków badawczych.

Realizacja badań opisanych w niniejszej publikacji nie byłaby możliwa bez wsparcia zespołu badawczego. W tym miejscu chciałabym serdecznie podziękować zespołowi badawczemu z Katedry Geoinformatyki, Kartografii i Teledetekcji na Wydziale Geografii i Studiów Regionalnych Uniwersytetu Warszawskiego, którym miałam przyjemność kierować i z którym współpracuję od 2016 r., a od roku 2021 – w ramach projektu *GeneralizationAI*. Serdecznie dziękuję dr inż. Karolinie Wereszczyńskiej, kiedyś mojej doktorantce, a obecnie pani doktor, której rozprawą doktorską – wraz z dr. hab. Wiesławem Ostrowskim – miałam przyjemność się opiekować. Dziękuję dr. Maciejowi Lisiewiczowi, mojemu byłemu magistrantowi, za współpracę i wspólne badania. Dziękuję mgr. Albertowi Adolfowi oraz mgr Idze Ajdackiej, moim obecnym doktorantom, za współpracę w ramach projektu badawczego *GeneralizationAI*. Dziękuję dr. hab. Wiesławowi Ostrowskiemu oraz prof. Jackowi Paślawskiemu za wieloletnią współpracę nad różnymi aspektami generalizacji kartograficznej oraz konstruktywne uwagi do niniejszej monografii.

Serdecznie dziękuję recenzentom tej publikacji. Dziękuję prof. Beacie Konopskiej za bardzo pomocną i wnikliwą recenzję książki oraz zainspirowanie mnie do jej napisania. Dziękuję również prof. Przemysławowi Śleszyńskiemu za recenzję monografii i cenne uwagi.

Badania zawarte w monografii zostały sfinansowane przez Narodowe Centrum Nauki w ramach projektu nr UMO2020/37/B/HS4/02605 pt. *Optymalizacja redakcji osadnictwa oraz sieci dróg w skalach przeglądowych z wykorzystaniem sztucznej inteligencji oraz teorii grafów*. Wydanie monografii umożliwiły środki pozyskane z wewnętrznego systemu grantowego Uniwersytetu Warszawskiego pt. „Program Wsparcie Działalności Publikacyjnej Pracowników Uczelni”.