

Maciej Adamiak

**Wykorzystanie technik uczenia maszynowego i teledetekcji
do wspomagania interpretacji przestrzeni geograficznej**

Applying machine learning and remote sensing techniques to support the geographical space
interpretation

**Rozprawa doktorska
w dyscyplinie nauki o Ziemi i środowisku**

Promotor:

dr hab. inż. Krzysztof Będkowski, prof. UŁ

Promotor pomocniczy:

dr Anna Majchrowska

Łódź 2022

Spis treści

1.	Spis publikacji	3
2.	Wprowadzenie	4
3.	Problem badawczy	8
4.	Metody badawcze	11
5.	Wyniki	13
5.1.	Klasyfikacja nadzorowana	13
5.2.	Segmentacja nadzorowana	17
5.3.	Segmentacja nienadzorowana	23
6.	Dyskusja	27
7.	Wnioski	37
8.	Literatura	39
9.	Kopie publikacji tworzących rozprawę doktorską	44

Prezentowana rozprawa doktorska przygotowana została pod opieką dr. hab. inż. Krzysztofa Będkowskiego, prof. UŁ oraz dr Anny Majchrowskiej, którym dziękuję za cenne uwagi i sugestie, okazaną pomoc i życzliwość, opiekę naukową, jak również za zaangażowanie przy wspólnych projektach badawczych.

Pragnę podziękować dr hab. Iwonie Jaźdżewskiej, prof. UŁ, dr Elżbiecie Papińskiej, dr inż. Marcie Nalej, dr Katarzynie Leśniewskiej - Napierale, dr. Tomaszowi Napierale, dr. Miroslawowi Biczkowskiemu i mgr. inż. Mikołajowi Koziarkiewiczowi. Cieszę się, że udało nam się wspólnie zorganizować i przeprowadzić wszystkie plany badawcze. Jestem pewien, że to nie koniec naszej współpracy i czeka nas jeszcze wiele wspólnych wyzwań naukowych.

Chciałbym również podziękować współpracownikom mgr. inż. Tomaszowi Szymańskiemu, mgr. Adamowi Warskiemu i mgr. Janowi Zborowskemu za nieustającą wiarę w możliwość integracji działalności badawczej i komercyjnej w zakresie nauk o Ziemi i środowisku oraz uczenia maszynowego.

Szczególnie podziękowania składam dr. Stanisławowi Krysiakowi. Nauczyłem się od Ciebie wiele o geografii i poczułem pewniej ze swoją wiedzą.

Pragnę również podziękować żonie mgr Joannie Adamiak za motywowanie mnie do pracy oraz córkom Karolinie i Jagodzie za bezwzględną krytykę warstwy wizualnej wszystkich wykonanych przeze mnie rycin.

Streszczenie

Niniejsza praca stanowi próbę opracowania metodyki wspierania procesu badawczego przestrzeni geograficznej, stosowanego w naukach o Ziemi i środowisku, opartego na analizie zobrazowań lotniczych i satelitarnych. Metodyka ta oparta jest o zastosowanie modeli uczenia maszynowego (ang. *machine learning*, ML), zbudowanych w oparciu o głębokie splotowe sieci neuronowe (ang. *deep convolutional neural networks*, DCNN). W trakcie powiązanych ze sobą przedmiotowo, przestrzennie i czasowo projektów badawczych Autor wraz z towarzyszącymi mu zespołami badaczy podjął się opracowania zaawansowanych rozwiązań geoinformatycznych. Umożliwiają one opracowanie problemów badawczych dotyczących analizy pokrycia terenu. Autor skupił się przede wszystkim na potwierdzeniu przydatności transformacji, jaką zachodzi w splotowej głębokiej sieci neuronowej podczas procesu uczenia reprezentacji (ang. *representation learning*) obrazu cyfrowego, w interpretacji przestrzeni geograficznej.

W ramach rozprawy powstały cztery wysokiej jakości modele głębokiego uczenia wraz z obsługującymi je programami komputerowymi. Opracowane rozwiązania informatyczne pozwalają na przeprowadzenie nadzorowanej i nienadzorowanej klasyfikacji oraz segmentacji pokrycia terenu przy użyciu zobrazowań satelitarnych i lotniczych. Zwieńczeniem badań jest opracowanie autorskiej metody nienadzorowanej segmentacji przestrzeni geograficznej z wykorzystaniem współzawodniczących generatywnych sieci neuronowych (ang. *generative adversarial networks*, GAN).

Słowa kluczowe: przestrzeń geograficzna, uczenie maszynowe, głębokie uczenie, teledetekcja, zobrazowania satelitarne i lotnicze, pokrycie terenu, klasyfikacja, segmentacja, generatywne sieci współzawodniczące.

Abstract

The following thesis is an attempt to determine the possibility of supporting the Earth and environmental sciences research process of geographical space interpretation based on the analysis of aerial and satellite imagery, by using machine learning models and deep convolution neural networks. During related, in terms of the subject, area and time, research projects, the author, together with various research teams undertook the development of advanced geoinformatics solutions enabling the development of research problems related to land cover classification and analysis. The author primary goal focused on confirming the usefulness of the image transformation that takes place in the convolutional neural network during representation learning of given geographical space in assisting geographers in obtaining answers to posed research questions.

As part of the dissertation, four high-quality machine learning models were developed by the author, enabling supervised and unsupervised classification and segmentation of land cover using satellite and aerial imagery. The main result of the research is the development of a novel method of unsupervised segmentation of geographic space with the use of generative adversarial neural networks (GAN).

Key words: geographical space, machine learning, deep learning, remote sensing, satellite imagery, aerial imagery, land cover, classification, segmentation, generative adversarial networks.

Spis publikacji

Rozprawa składa się z pięciu powiązanych tematycznie artykułów naukowych, dotyczących zastosowania uczenia maszynowego oraz głębokiego uczenia w procesie teledetekcyjnej interpretacji przestrzeni geograficznej. Poniżej zaprezentowano, w porządku chronologicznym, noty bibliograficzne publikacji wchodzących w skład rozprawy:

1. Krysiak, S., Papińska, E., Majchrowska, A., Adamiak, M., Koziarkiewicz, M. (2020). *Detecting Land Abandonment in Łódź Voivodeship Using Convolutional Neural Networks*, Land, 9(3), 82. <https://doi.org/10.3390/land9030082>
MEiN: 70, IF'20: 3,398, CiteScore'20: 3,0
2. Adamiak, M., Biczkowski, M., Leśniewska-Napierała, K., Nalej, M., Napierała, T. (2020). *Impairing Land Registry: Social, Demographic, and Economic Determinants of Forest Classification Errors*. Remote Sensing, 12(16), 2628, <https://doi.org/10.3390/rs12162628>
MEiN: 100, IF'20: 4.848, CiteScore'20: 6,6
3. Adamiak, M., Jaźdżewska I., Nalej M. (2021). *Analysis of Built-Up Areas of Small Polish Cities with the Use of Deep Learning and Geographically Weighted Regression*, Geosciences, 11(5), 223, <https://doi.org/10.3390/geosciences11050223>
MEiN: 70, CiteScore'21: 3,4.
4. Adamiak, M., Będkowski, K., Majchrowska, A. (2021). *Aerial Imagery Feature Engineering Using Bidirectional Generative Adversarial Networks: A Case Study of the Pilica River Region, Poland*. Remote Sensing, 13(2), 306, <https://doi.org/10.3390/rs13020306>
MEiN: 100, IF'20: 4.848, CiteScore'21: 6,9.
5. Adamiak, M. (2021). *Głębokie uczenie w procesie teledetekcyjnej interpretacji przestrzeni geograficznej – przegląd wybranych zagadnień*, Czasopismo Geograficzne, 92(1), 49, <https://doi.org/10.12657/czageo-92-03>
MEiN: 70

1. Wprowadzenie

Nauki o Ziemi i środowisku stają współcześnie przed koniecznością przetwarzania, często w czasie rzeczywistym, zbiorów danych charakteryzujących się skomplikowaną strukturą wewnętrzną, różnorodnym formatem zapisu i znaczą licznością. Dane te mogą mieć swoje źródło w obserwacji przeprowadzonej podczas badań terenowych, jak również w zobrazowaniach lotniczych i satelitarnych. Stale rosnące wymagania w zakresie dostępności danych, automatyzacji procesu ich przetwarzania i analizy wynikają z potrzeby zapewnienia geografom dostępu do aktualnych i rzetelnych danych, umożliwiających wnioskowanie o procesach i zjawiskach zachodzących w otaczającej ich rzeczywistości.

Podstawowe znaczenie koncepcji przestrzeni w geografii wraz z jej elementami składowymi i ich wzajemnymi powiązaniami można ograniczyć do trzech sfer: przedmiotu poznania, instrumentu pomiaru stosowanego w badaniach geograficznych oraz zasobu oddziałującego w złożony sposób na działania społeczne (Lisowski, 2014; Włodarczyk, 2014). Przestrzeń geograficzna obejmuje powierzchnię Ziemi w jej całej fizycznej złożoności, wyrażającej charakter i zróżnicowanie środowiska przyrodniczego (Dziewoński, 1967; Chojnicki, 1999). Jest przestrzenią mierzalną, obejmującą elementy przyrodnicze powłoki ziemskiej, tj. atmosferę, hydrosferę, biosferę i litosferę oraz trwałe zainwestowanie tej powłoki będące wynikiem działalności człowieka (Liszewski, 1995).

Przestrzeń fizyczna wyraża relacje między obiektami i zdarzeniami w świecie rzeczy, obejmując lokalizacje, rozmieszczenie oraz współwystępowanie w tym samym miejscu lub na odległość. Przedmiotem badań z wykorzystaniem koncepcji przestrzeni fizycznej jest albo zróżnicowanie przestrzenne albo organizacja przestrzenna (Lisowski, 2014). Fizyczne aspekty przestrzeni geograficznej są obserwowane w celu prowadzenia pomiarów i systematycznego gromadzenia danych o jej cechach, właściwościach, kompozycji oraz zachodzących w jej obrębie procesach i zjawiskach. W przypadku odniesienia pozyskanych danych do wybranego układu referencyjnego, możliwe jest lokalizowanie ich w danej przestrzeni geograficznej w sposób jednoznaczny, jawnny bądź niejawnny (Ney, 2007; ISO, 2021). Mówimy wtedy o danych przestrzennych (ang. *spatial data*) lub precyzyjniej danych geograficznych (ang. *geographical data*). W geomatyce (inaczej geoinformatyce, ang. *geoinformatics*) przyjmuje się podział na dwa podstawowe typy danych: geometryczne – zawierające opis przestrzennego rozmieszczenie obiektów, ich kształtu geometrycznego i wzajemnych relacji w formie rastrowej bądź wektorowej (gromadzonych w odpowiedniej

formie) oraz opisowe – zawierające opisy nieprzestrzennych cech obiektów oraz relacji pomiędzy nimi, w tym dane statystyczne i atrybutowe. Przykładem danych geometrycznych rastrowych są dane teledetekcyjne.

Zobrazowania satelitarne, zdjęcia lotnicze czy dane radarowe wchodzące w skład danych teledetekcyjnych, po wstępnym ich przetworzeniu i korekcie, można uznać za dane pierwotne. Po odpowiednim opracowaniu mogą one służyć jako źródło danych innego typu. Poziom dokładności danych teledetekcyjnych określany jest między innymi przez ich rozdzielczość przestrzenną, radiometryczną, spektralną i czasową (Adamczyk i Będkowski, 2007). Postęp, jaki dokonuje się w teledetekcji, mający swoje podłożę w rozwoju techniki wspartym przez aktywnie działającą społeczność naukową, skutkuje stałym wzrostem każdego z typów rozdzielczości zobrazowań. Istotnie zwiększała się również dostępność danych teledetekcyjnych i jakość rozwiązań wspomagających ich przechowywanie, pobieranie i przetwarzanie.

Współcześnie osiągnięto już stan, w którym zdolność do gromadzenia i tworzenia danych przestrzennych znacznie przewyższa możliwości ich rozsądnej asymilacji, nie mówiąc już o ich interpretacji czy rozumieniu. Liczba metod i narzędzi analitycznych w ciągu ostatnich kilku dekad nie rosła równie szybko jak dostępność danych. Tym samym, aby w pełni wykorzystać mnogość i różnorodność danych przestrzennych, należy zapewnić istnienie efektywnych rozwiązań wydobywających wartościową wiedzę z dostępnych źródeł oraz modeli, które ucząc się przy ich pomocy, wychodzą poza tradycyjne metody przetwarzania i analizy danych (Reichstein i in., 2019). Implikuje to wzrost złożoności procesu badawczego z użyciem danych przestrzennych i naturalnie zwiększa stopień jego informatyzacji. Przez informatyzację pojmuje się racjonalne wykorzystanie danych, uprzednio wprowadzonych do instrumentalnych systemów, które służą nie tylko przetwarzaniu tych danych, ale też ich produkowaniu w pewnych zgeneralizowanych postaciach (Chojnicki, 2010).

Informatyzacja procesu badawczego opartego o dane przestrzenne jest domeną geomatyki oraz wspierających ją systemów informacji geograficznej (ang. *geographic information system*, GIS). Systemy te przeszły w ostatnich latach szereg istotnych zmian. Początkowo służyły jedynie jako mechanizm integracji, przetwarzania, przechowywania i wizualizacji danych geograficznych, aby z czasem zyskać możliwość prowadzenia działań związanych z eksploracją danych, a tym samym uczestniczyć w procesie decyzyjnym, podejmowanym w oparciu o dane przestrzenne.

Wyzwaniem w badaniach nad przestrzenią geograficzną, wspieranych przez rozwój teledetekcji, nie jest jedynie szybki przyrost liczności zbiorów danych, ich złożoności oraz jakości, ale również potrzeba systematyzowania informacji naukowych związanych z danymi przestrzennymi. Jednym z podstawowych celów takiego działania jest umożliwienie wymiany zgromadzonej wiedzy o przestrzeni między naukowcami w obrębie nauk geograficznych i innych dyscyplin. W tym zakresie niezbędne są doświadczenie i współpraca geografów z informatykami oraz kontrolowana automatyzacja procesu odkryć naukowych (Jaźdżewska, 2021).

Komputerowe systemy odkryć naukowych mają związek z teorią sztucznej inteligencji (ang. *artificial intelligence*, AI), która zajmuje się automatyzacją różnych czynności umysłowych. Maszynowy odkrywca jest szczególnym źródłem wiedzy. Początkowo posiada on niewielką wiedzę, która narasta w miarę dokonywanych odkryć, natomiast metoda stosowana przez system się nie zmienia. System może zachowywać się inaczej w obliczu nowych danych, ale tylko w ramach wcześniej zaprogramowanych rozwiązań (Żytkow, 1993). Subdyscypliną w ramach AI jest uczenie maszynowe (ang. *machine learning*, ML) wraz z głębokim uczeniem (ang. *deep learning*, DL), będącym jego odmianą wykorzystującą sztuczne sieci neuronowe (ang. *artificial neural networks*, ANN). Mówimy, że program komputerowy uczy się podczas nabywania doświadczenia w odniesieniu do pewnej klasy zadań przy jednoczesnym pomiarze skuteczności, jeśli jego skuteczność w trakcie wykonywania tych zadań poprawia się wraz z doświadczeniem (Mitchell, 1997). Model uczenia maszynowego, będący matematyczną reprezentacją badanego obiektu czy zjawiska, stanowi główny element programu. Dopasowuje się on do danych wejściowych przez rekonfigurację w trakcie iteracyjnego procesu optymalizacyjnego.

W naukach o Ziemi i środowisku, a przede wszystkim w teledetekcji, wiele metod i narzędzi badawczych opartych jest o algorytmy uczące się. Uczenie maszynowe wspiera teledetekcję w jej podstawowym zadaniu, jakim jest rozpoznanie obiektów i zjawisk występujących na danym obszarze, a także określenie ich stanu, zasięgu i dostarczenie informacji pozwalającej na prognozę dynamiki i kierunków ewentualnych zmian. Z punktu widzenia poziomu automatyzacji proces klasyfikacji może przebiegać w sposób nadzorowany z użyciem obiektów wzorcowych przy dużej kontroli operatora oraz w sposób nienadzorowany, gdy program działa autonomicznie, zaś rolą badacza jest poddać interpretacji wyprodukowane przez niego rezultaty (Adamczyk i Będkowski, 2007).

Mimo olbrzymich możliwości oferowanych przez uczenie maszynowe, ze szczególnym wskazaniem na głębokie uczenie, na rzecz wspomagania interpretacji przestrzeni geograficznej z użyciem danych przestrzennych, niewielkie wydaje się jego zastosowanie w geografii. Przyczyn tego stanu rzeczy należy upatrywać w stosunkowo niedawno upowszechnionym dostępie do sprzętu oraz bibliotek umożliwiających trenowanie sieci neuronowych, jak również w wysokiej barierze wejścia związanej z potrzebą tworzenia dedykowanego oprogramowania dostosowanego do zdefiniowanego problemu badawczego, a więc leżących poza ogólnodostępnymi funkcjonalnościami oferowanymi przez współczesne programy GIS. Inni badacze zwracają uwagę, że czynnikiem ograniczającym informatyzację w ogóle może być traktowanie nowych technologii jedynie jako narzędzi ułatwiających pracę naukową i brakiem szerszej dyskusji wśród geografów, obejmującej zagadnienia teoretyczno-metodologiczne związane z techniką (Jaźdżewska, 2021).

Nie należy utożsamiać uczenia maszynowego jedynie ze zbiorem metod. Pod tym pojęciem kryje się nie tylko mnogość różnego rodzaju algorytmów i narzędzi, ale przede wszystkim pewien określony styl prowadzenia procesu badawczego. Łączy on w sobie cechy projektu inżynierijnego z zakresu budowy i wdrożenia oprogramowania z klasycznym podejściem do badań podstawowych w naukach o Ziemi i środowisku. Zdaniem Autora bliżej mu jest do jednej z wielu warstw procesu badawczego, w obrębie której precyzyjnie określone zostają wymagania odnośnie do zarządzania, przetwarzania oraz analizy w oparciu o liczne i różnorodne zbiory danych (ang. *big data*). W literaturze anglojęzycznej używa się określeń *machine learning operations* (MLOps) lub *machine learning pipeline*, które dobrze oddają charakter tej dyscypliny i wskazują na istnienie pewnej określonej sekwencji działań. Sekwencja ta wyrażona jest w postaci kodu komputerowego. Tym samym projekt badawczy zostaje częściowo zautomatyzowany i skodyfikowany, tj.: opisany w wersjonowanej, dostępnej, modyfikowalnej i wykonywalnej formie. Ma to olbrzymie znaczenie z punktu widzenia procesu badawczego, ponieważ umożliwia wgląd w całą procedurę, jej weryfikację, interpretację, a w rezultacie reprodukowanie wyników pracy naukowej.

W niniejszej rozprawie Autor podjął wyzwanie połączenia swojej wiedzy i doświadczenia z zakresu geografii, inżynierii oprogramowania oraz uczenia maszynowego. Jego celem jest uzyskanie odpowiedzi na nurtujące go pytania badawcze, powiązane z możliwością zastosowania zaawansowanych metod głębokiego uczenia we wspomaganiu interpretacji przestrzeni geograficznej.

2. Problem badawczy

Problem badawczy niniejszego opracowania dotyczy oceny przydatności modeli uczenia maszynowego, opartych o głębokie splotowe sieci neuronowe (ang. *deep convolutional neural networks*, DCNN), we wspomaganiu teledetekcyjnej interpretacji przestrzeni geograficznej. Jest to problem istotny z wielu względów, z których najważniejszym jest umożliwienie automatyzacji szeregu zadań badawczych przy jednoczesnym zwiększeniu rozdzielczości spektralnej, radiometrycznej, przestrzennej i czasowej opracowywanego materiału badawczego.

Celem nadzawanego pracy było wykazanie zasadności zastosowania zaawansowanych metod i technik uczenia maszynowego, a przede wszystkim głębokiego uczenia, we współczesnym procesie badawczym w obszarze geografii, obejmującym przetwarzanie i analizę danych przestrzennych, pozyskanych w formie zobrazowań lotniczych i satelitarnych. Cel ten został zrealizowany w ramach szeregu projektów badawczych bezpośrednio dotyczących analizy zjawisk oraz procesów zachodzących w przestrzeni geograficznej i traktujących informację o pokryciu terenu za niezbędną w opracowaniu postawionych pytań badawczych. Umożliwiło to zrozumienie mechanizmu kodowania i przechowywania informacji przestrzennej przez wybrane architektury sieci neuronowych, zbudowane w oparciu o warstwy splotowe (ang. *convolutional layers*). Pozyskana wiedza posłużyła do zaprojektowania, wdrożenia i przetestowania metody umożliwiającej nienadzorowaną segmentację przestrzeni geograficznej ze względu na pokrycie terenu, wykorzystując przy tym ogólnodostępne dane pochodzące z zobrazowania lotniczego. Wypełnienie postawionego celu wymagało uzyskania odpowiedzi na zdefiniowane poniżej pytania badawcze:

1. W jaki sposób przebiega nadzorowana klasyfikacja i segmentacja, prowadzona w ramach wybranej przestrzeni geograficznej, której reprezentacją w procesie analitycznym jest obraz cyfrowy uzyskany metodami teledetekcyjnymi?
2. Czy informacje, dotyczące cech badanej przestrzeni geograficznej przechowywane w warstwach splotowej sieci neuronowej, umożliwiają prowadzenie analizy zjawisk zachodzących w tej przestrzeni?
3. Czy istnieje możliwość zastosowania rezultatów otrzymanych przy pomocy metod głębokiego uczenia jako danych wejściowych klasycznych algorytmów analizy przestrzennej, w tym analizy skupień?

4. W jakim stopniu analiza przestrzeni geograficznej może być prowadzona w oparciu o uczenie nienadzorowane?
5. Czy możliwe jest zaprojektowanie sieci neuronowej pozwalającej na zapis cech przestrzennych w postaci dopuszczającej przeprowadzenie z ich udziałem analizy skupień i nienadzorowanego podziału przestrzeni geograficznej na odrębne jednorodne fragmenty?
6. Czy jakość opracowanej metody może być weryfikowana na podstawie procesu rekonstrukcji, polegającego na porównaniu prawdziwych próbek do ich sztucznie wytworzonych odpowiedników?

Struktura projektu badawczego niniejszej rozprawy ma postać sekwencyjną. Rozpoczęto od zastosowania uczenia maszynowego do rozwiązania problemu badawczego, opartego o nadzorowaną klasyfikację pokrycia terenu (publikacja 1). Celem tego etapu jest poznanie budowy głębszych splotowych sieci neuronowych oraz zidentyfikowanie sposobu utrwalania przez nie danych geograficznych. Co więcej, określono punkty styku procesów badawczego i budowy oprogramowania, tworząc tym samym schemat postępowania wykorzystywany w trakcie dalszych badań. Następnie podjęto się zastosowania uczenia maszynowego w badaniach naukowych, wymagających precyzyjnej delimitacji typów pokrycia terenu, występujących w ramach wybranego wycinka przestrzeni geograficznej (publikacje 2 i 3). Zastosowano modele nadzorowanej segmentacji, co umożliwiło zrozumienie mechanizmu kodowania cech przestrzennych oraz ich dekodowania do masek segmentacyjnych. Pozwoliło to również na uzyskanie biegłości w projektowaniu i przeprowadzaniu procesu badawczego, opartego o metody i techniki głębszego uczenia, wykorzystującego dane pochodzące z obrazowania teledetekcyjnego na rzecz analizy przestrzeni geograficznej. Ostatnim etapem było odejście od zastosowania metod nadzorowanych na rzecz nienadzorowanych, opierając proces segmentacji przestrzeni o interakcję między wieloma sieciami neuronowymi (publikacja 4). Rezultatem tego jest opracowanie metody nienadzorowanej segmentacji pokrycia terenu z użyciem generatywnych sieci współzawodniczących i metody Warda.

Obszar badawczy zdefiniowano w sposób następujący:

1. Na potrzeby badań nad nadzorowaną segmentacją obejmował on obszar całego kraju (publikacje 2 i 3). Wybór ten wynikał przede wszystkim z dostępności wysokiej jakości informacji, dotyczącej pokrycia terenu Polski obszarami leśnymi i miejskimi dostępnymi w Bazie Danych Obiektów Topograficznych (BDOT) oraz Corine Land Cover (CLC).

2. Opracowanie nadzorowanej klasyfikacji zostało ograniczone do pojedynczego województwa co związane jest z charakterystyką badań prowadzonych w macierzystym ośrodku naukowym nad odłogami, występującymi w strefach buforowych parków krajobrazowych województwa łódzkiego (publikacja 1).
3. Segmentacja nienadzorowana dotyczy obszaru doliny Pilicy w regionie łódzkim między Maluszynem a Tomaszowem Mazowieckim (publikacja 4). Jest to obszar niezmiernie interesujący pod względem przyrodniczym. Został opisany w wielu opracowaniach z zakresu geografii fizycznej, zrealizowanych w łódzkim ośrodku naukowym. Zawiera się on również we wszystkich wcześniej zdefiniowanych zasięgach. Obszar doliny Pilicy jest względnie homogeniczny pod względem cech pokrycia terenu, co ma istotne znaczenie w procesie testowania opracowanej metody nienadzorowanej segmentacji pokrycia terenu.

3. Metody badawcze

Adamiak, M. (2021). *Głębokie uczenie w procesie teledetekcyjnej interpretacji przestrzeni geograficznej – przegląd wybranych zagadnień*, Czasopismo Geograficzne, 92(1), 49, <https://doi.org/10.12657/czageo-92-03>

Artykuł przeglądowy zawiera opis wybranych zagadnień z zakresu uczenia maszynowego i głębokiego uczenia w odniesieniu do problemów badawczych z zakresu dyscypliny nauki o Ziemi i środowisku. W niniejszym cyklu artykułów przedstawiony on został jako pierwszy, aby umożliwić czytelnikowi zapoznanie się z podstawowymi pojęciami dotyczącymi metod wykorzystanych w cyklu publikacji. Jest w całości oparty na wynikach prac badawczych prowadzonych w trakcie przygotowania rozprawy. Wśród istotnych zagadnień, poruszanych w opisywanym artykule, odnajdziemy definicję głębokiego uczenia. Wyjaśniona została również zasada działania mechanizmu utrwalania informacji przestrzennej przez splotowe sieci neuronowe. Istotnym, z punktu widzenia rozprawy jest opis procesu uczenia sztucznych sieci neuronowych oraz ich zastosowania w rozwiązywaniu problemów badawczych opartych na klasyfikacji, segmentacji, wzbogacania danych czy ich syntetyzowania w odniesieniu do problemów badawczych, wymagających poddania interpretacji wybranej przestrzeni geograficznej.

Przyjmijmy, za wcześniej przytoczoną definicją Mitchella (1997), że program komputerowy uczy się, gdy wraz z dostarczeniem mu nowych danych, podczas pewnego procesu rekonfiguracji, staje się lepszy w wypełnianiu swoich zadań, tj. zwraca coraz dokładniejsze wyniki. Głębokie uczenie jest subdyscypliną uczenia maszynowego, w której stosowane są głębokie sztuczne sieci neuronowe. Rdzeniem programu jest model sieci neuronowej, będący kombinacją warstw i funkcji aktywacji. Warstwa jest strukturą, w obrębie której sygnał wejściowy jest modyfikowany przy jednoczesnej aktualizacji stanu wewnętrznego danej warstwy, który stanowią jej wagи (Google, 2021b). Po agregacji danych wejściowych z uwzględnieniem wag, powstaje sygnał sumarycznego pobudzenia. Rola funkcji aktywacji polega na obliczaniu wartości sygnału wyjściowego (Szaleniec i Tadeusiewicz, 2015). Cykl, w którym następuje aktualizacja wag poszczególnych warstw składających się na model, nazywamy uczeniem sieci neuronowej. Mówimy, że model jest trenowany (ang. *model training*).

Zastosowanie głębokiego uczenia do klasyfikacji danych związane jest z potrzebą pogrupowania danych wejściowych przez przyporządkowanie każdej z obserwacji do pewnej

kategorii lub inaczej klasy. Charakterystyczna dla klasyfikacji materiału pochodzącego ze zobrazowań jest, związana z jego znaczną rozdzielczością, praca na określonym wycinku obrazu, któremu w całości przypisywana jest dana klasa. Segmentacja jest szczególnym przypadkiem klasyfikacji, w której obraz dzielony jest na rozłączne obszary, zwane regionami. Każdy region przypisany jest do co najmniej jednej ze ścisłe określonych klas.

Wzbogacanie danych lub inaczej augmentacja to proces sztucznego zwiększenia liczebności badanej próby. Modele uczenia maszynowego często wymagają tysięcy, a nawet setek tysięcy przykładów, aby wyspecjalizować się w pewnym zadaniu, czy będzie to klasyfikacja, detekcja czy segmentacja. Jest to charakterystyczne dla danych w formie niestrukturyzowanej, czyli tekstu, obrazu i dźwięku. Wzbogacanie danych pozwala na wykorzystanie istniejących próbek jako wzorców do tworzenia nowych próbek. Dla przykładu obrót obrazu czy jego rozciągnięcie są przykładem augmentacji, podobnie jak wyprodukowanie próbki sztucznej. Model uczony na wzbogaconym zbiorze powinien lepiej się generalizować, czyli mieć wyższą skuteczność podczas pracy z nowymi danymi. Każde z wymienionych zadań może przebiegać w sposób nadzorowany i nienadzorowany.

W cyklu publikacji wykorzystano, jako wzorcowe, następujące architektury sieci neuronowych: U-Net (Ronneberger i in., 2015), FPN (Lin i in., 2017), PSPNet (Zhao i in., 2017), DeepLabV3+ (Chen i in., 2017), BiGAN (Donahue i in., 2017), BigGAN (Brock i in., 2019), BigBiGAN (Donahue i Simonyan, 2019). Źródło informacji o konstrukcji sieci neuronowych, jak również charakterystyce poszczególnych algorytmów, stanowiły: podręczniki *Pattern Recognition and Machine Learning* (Bishop, 2006), *Hands-On Machine Learning* (Gron, 2019), dokumentacja bibliotek wspomagających proces implementacji sieci neuronowych, repozytorium artykułów naukowych dotyczących głębokiego uczenia i widzenia komputerowego (*Papers with Code*, 2021) oraz kurs *Deep Learning Specialization* (*DeepLearning.AI*, 2021) dostępny w serwisie Coursera. Źródło danych stanowiły ogólnodostępne serwisy jak: Geoportal (*Geoportal*, 2021), SentinelHub (*EO Browser*, 2021), Copernicus Open Access Hub (*Open Access Hub*, 2021) oraz OpenStreetMap (*OpenStreetMap*, 2021). Oprogramowanie, wykorzystane do trenowania oraz wnioskowania z użyciem modeli sztucznych sieci neuronowych, zostało zaimplementowane w języku Python (Python.org, 2021) w oparciu o biblioteki PyTorch (Facebook, 2021) i TensorFlow (Google, 2021a). Badania zrealizowano z wykorzystaniem karty graficznej (ang. *graphical processing unit*, GPU) NVIDIA TITAN RTX (NVIDIA, 2022).

4. Wyniki

4.1. Klasyfikacja nadzorowana

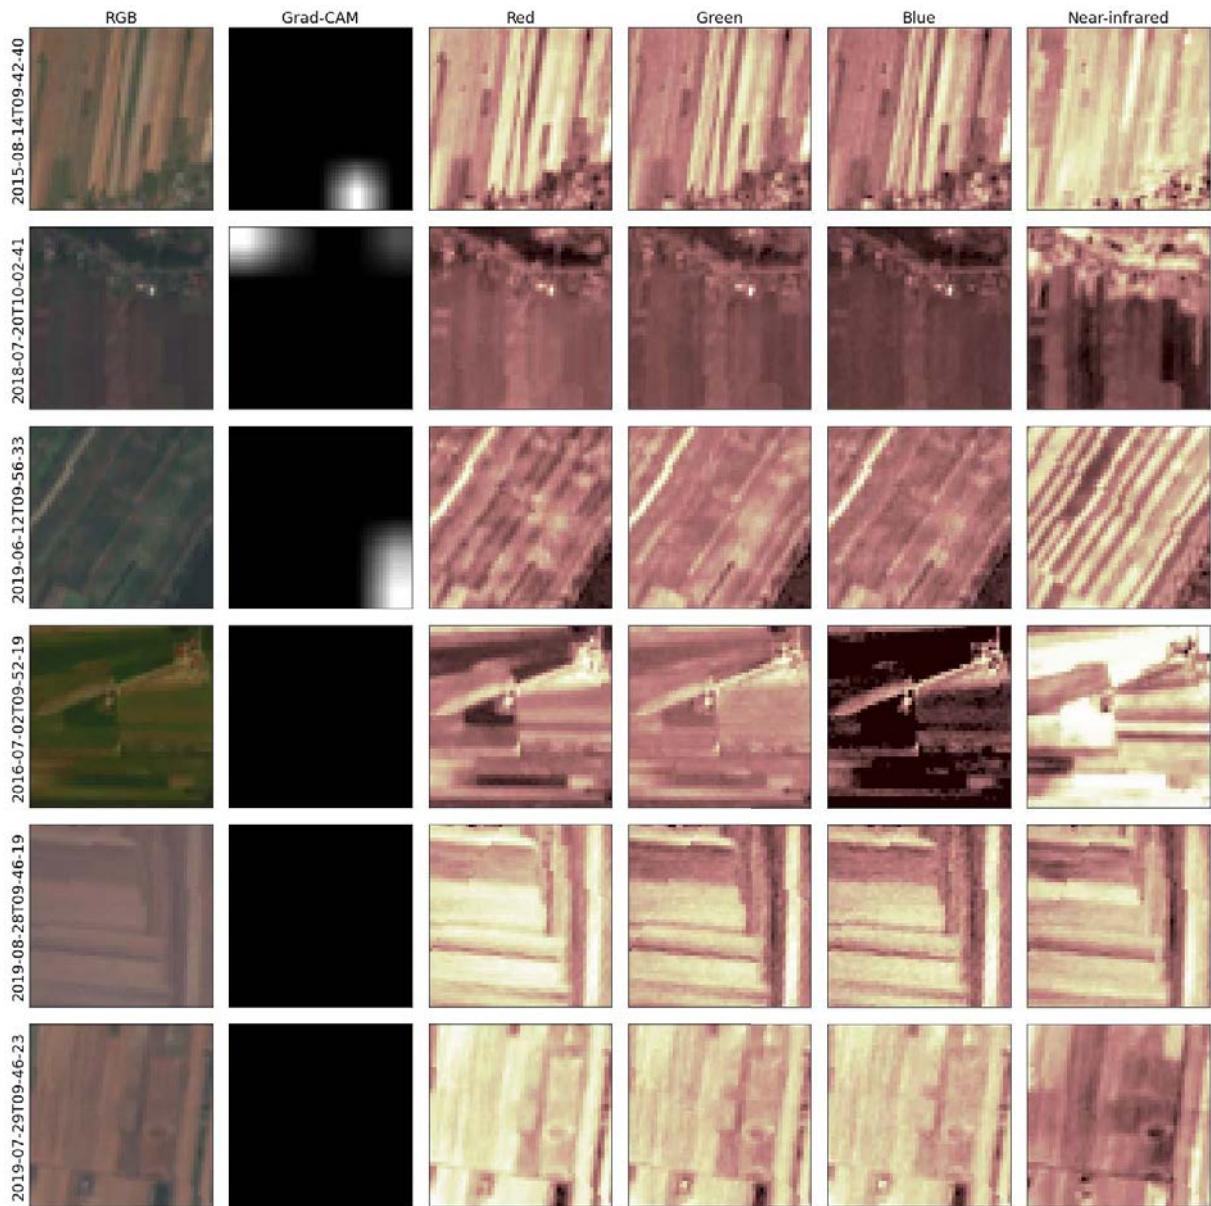
Krysiak, S., Papińska, E., Majchrowska, A., Adamiak, M., Koziarkiewicz, M. (2020), *Detecting Land Abandonment in Łódź Voivodeship Using Convolutional Neural Networks.* Land, 9(3), 82. <https://doi.org/10.3390/land9030082>

Celem projektu badawczego była ocena przydatności głębokiego uczenia, w szczególności splotowych sieci neuronowych (ang. *convolutional neural network*, CNN), w klasyfikacji pokrycia terenu i detekcji odłogów na obszarze województwa łódzkiego. W ramach prowadzonych prac badawczych opracowano model głębokiej splotowej sieci neuronowej (ang. *deep convolutional neural network*, DCNN), umożliwiający predykcję występowania odłogu na obszarze utrwalonym na wycinkach wielospektralnego zobrazowania satelitarnego Sentinel-2 o powierzchni od 15 do 25 ha. Klasyfikator składał się z szeregu warstw splotowych, zwieńczonych sigmoidalną funkcją aktywacji zwracającą wartość między 0 - 1, gdzie 0 to brak odłogu, zaś 1 to jego pewne występowanie. Wejście do sieci stanowił czterokanałowy (RGB + NIR) obraz $50 \text{ px} \times 50 \text{ px}$. Model trenowany oraz testowany był w sposób nadzorowany z zastosowaniem materiału badawczego opracowanego na podstawie wcześniejszych prac zespołu badawczego, dotyczącego występowania odłogów. Powstał wtedy zbiór etykiet, opisujących udział procentowy odłogu w 25 ha wycinkach przestrzeni geograficznej stref buforowych parków krajobrazowych województwa łódzkiego (Krysiak i in., 2016). W wyniku transformacji etykiet oraz ich połączenia z obrazami satelitarnymi, utworzono nowy zbiór danych przestrzennych. Składał się on z wycinków obrazu satelitarnego wraz z przypisaną klasą informującą o występowaniu odłogu. Pokrywał obszar $3073,05 \text{ km}^2$. Zbiór danych podzielono na trzy podzbiory: treningowy - służący do uczenia sieci, walidacyjny - stosowany podczas dostrajania parametrów konfiguracyjnych modelu oraz testowy - wykorzystany do oceny jakości modelu.

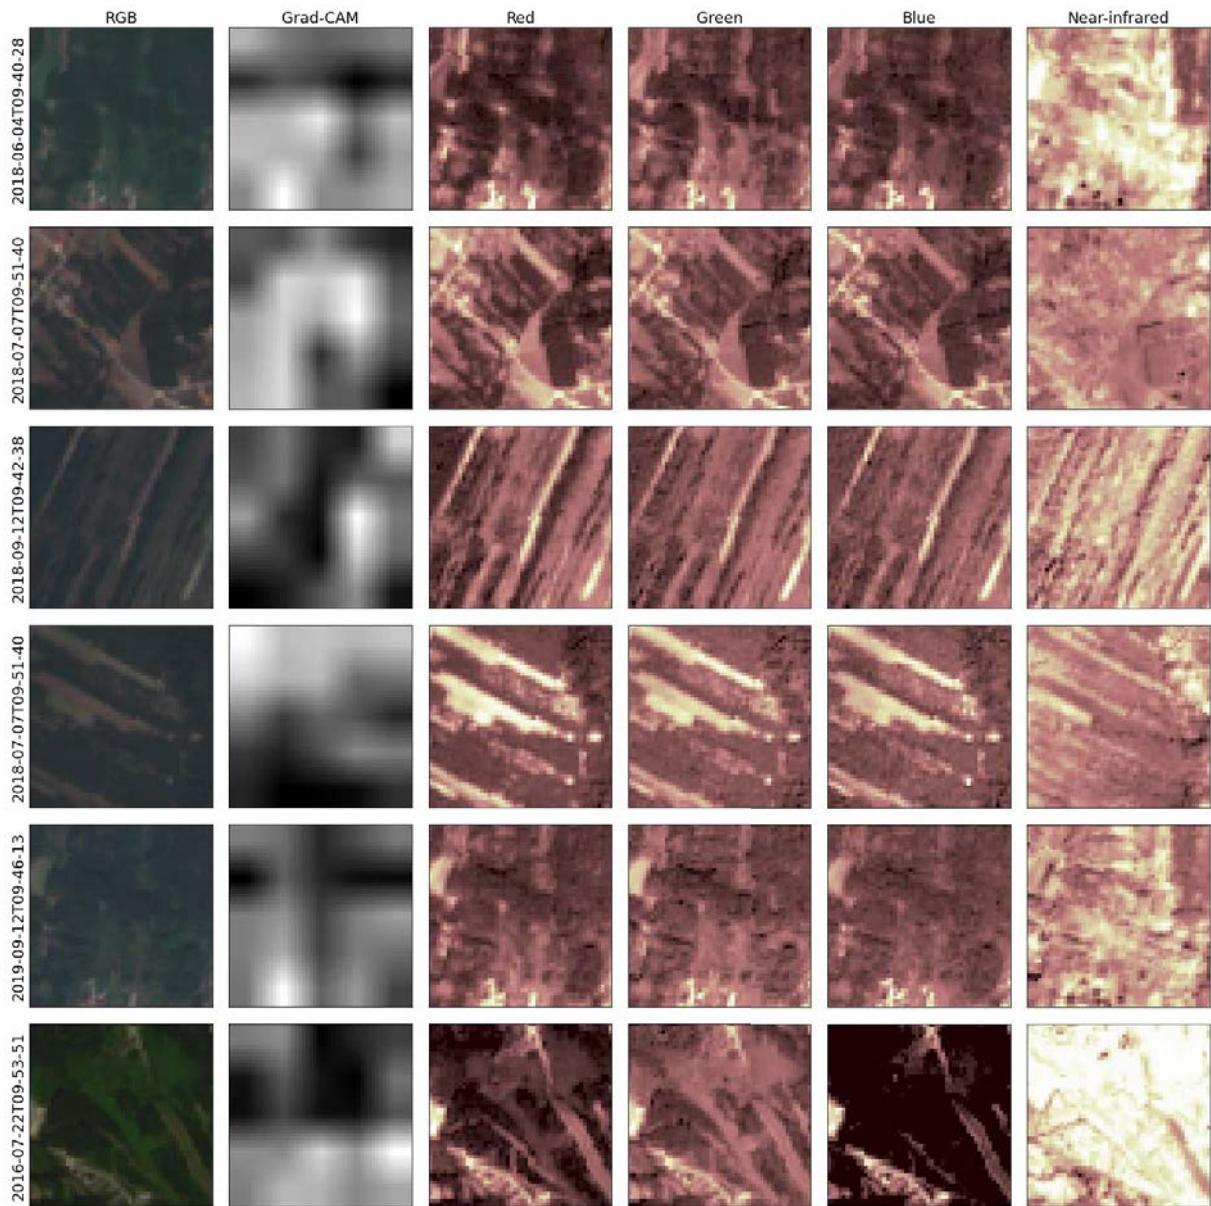
DCNN osiągnął na zbiorze testowym dokładność (ang. *accuracy*) na poziomie 0,78 oraz 0,855 AUC (ang. *area under curve*). Dodatkowo wykonano walidację działania modelu w trakcie badań terenowych, których celem była identyfikacja odłogów na wybranych obszarach testowych i porównanie z rezultatem wnioskowania przy użyciu modelu sieci neuronowej. Warstwy splotowe sieci neuronowej zostały poddane analizie z użyciem algorytmu Grad-CAM (Selvaraju i in., 2017). Stworzono w ten sposób wizualizację,

przedstawiającą dany wycinek wraz z oznaczonymi cechami przestrzennymi, mającymi największy udział w przypisaniu go do odpowiedniej klasy występowania odłogu. Grad-CAM jest narzędziem XAI (ang. *explainable artificial intelligence*) wspomagającym proces wyjaśniania działania modeli opartych na sztucznych sieciach neuronowych. Rycinę 1 oraz 2 przedstawiają rezultaty dla osobnych klas. W przypadku pól uprawnych model nie wykrył istotnego natężenia cech świadczących o istnieniu odłogu, stąd rezultatem jest przypisanie klasy 0. W drugim przypadku mamy do czynienia z wyraźnymi odłogami w różnej fazie dojrzałości. Model skutecznie lokalizuje cechy wskazujące na występowanie odłogu.

Wytrenowany model zastosowano do automatycznej klasyfikacji 96% obszaru województwa o powierzchni 17486,25 km². Otrzymany rezultat, będący mapą prawdopodobieństwa, że dany super piksel jest odlogiem, został użyty do obliczeń statystki Getis-Ord Gi*. Rezultatem jest mapa obszarów o dużym skupieniu odłogów i terenów od nich wolnych. Łącznie wyróżniono na niej 16 klastrów wartości wysokich (ang. *hot spot*) prawdopodobieństwa i 9 klastrów wartości niskich (ang. *cold spot*) o różnej wielkości. Na podstawie mapy klastrów rozpoczęto dyskusję na temat przyczyn rozkładu przestrzennego odłogów w województwie, celem dostarczenia nowego wglądu w genezę tego procesu. Na podstawie literatury wybrano szereg czynników przyrodniczych lub socjoekonomicznych, mających wpływ na występowanie odłogów w danej przestrzeni. Przykładowymi mogą być jakość gleb czy bliskość obszarów leśnych, zurbanizowanych lub wydobywczych. Każdy z czynników przypisano do 25 zidentyfikowanych klastrów, otrzymując w ten sposób informacje o procesach odłogowania oraz ich przyczynach na terenie województwa łódzkiego.



Ryc. 1. Pojedyncze wycinki badanej przestrzeni geograficznej zaklasyfikowane jako wolne od występowania odłogów w kompozycji RGB, rezultat pracy algorytmu Grad-CAM oraz osobno każdy z kanałów spektralnych;
źródło: opracowanie własne na podstawie (Krysiak i in., 2020)



Ryc. 2. Pojedyncze wycinki badanej przestrzeni geograficznej zaklasyfikowane jako odłogi w kompozycji RGB, rezultat pracy algorytmu Grad-CAM oraz osobno każdy z kanałów spektralnych; źródło: opracowanie własne na podstawie (Krysiak i in., 2020)

4.2. Segmentacja nadzorowana

Adamiak, M., Biczkowski, M., Leśniewska-Napierała, K., Nalej, M., Napierała, T. (2020). *Impairing Land Registry: Social, Demographic, and Economic Determinants of Forest Classification Errors*. Remote Sensing, 12(16), 2628, <https://doi.org/10.3390/rs12162628>

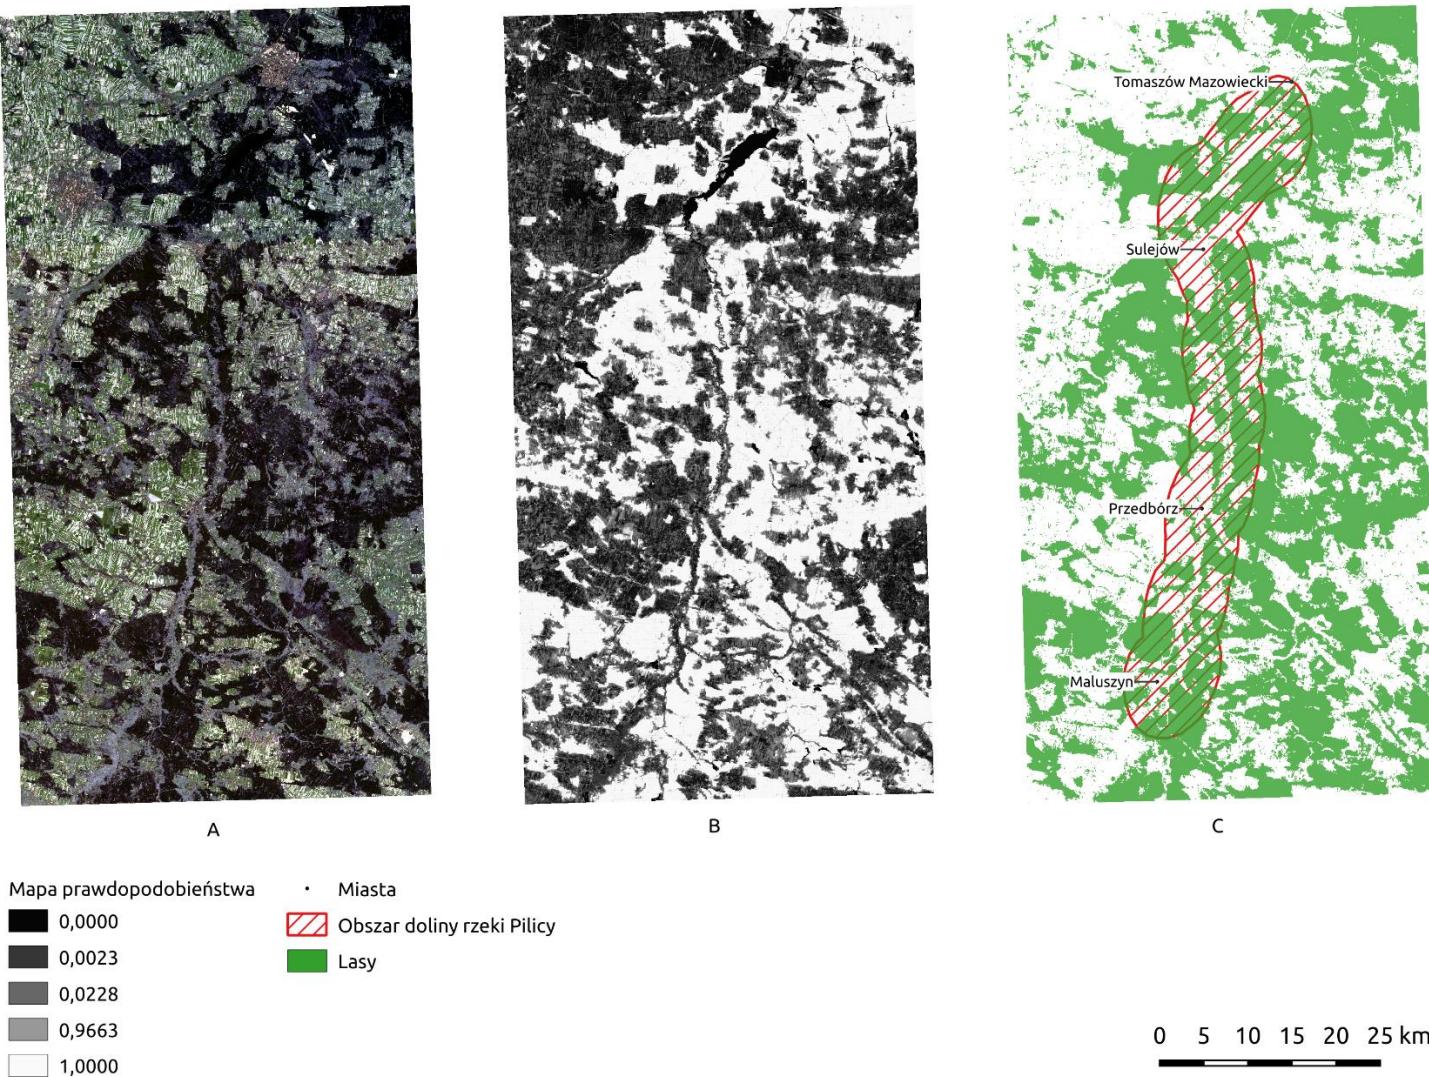
W pracy zbadano wpływ czynników społecznych, demograficznych i ekonomicznych na powstawanie różnic między identyfikacją lasu na podstawie technik teledetekcyjnych, uczenia maszynowego i ewidencji gruntów. Baza Danych Obiektów Topograficznych (BDOT) i obrazów satelitarnych Sentinel-2 z 2018 r. dla obszaru całej Polski została wykorzystana do trenowania nadzorowanego modelu uczenia maszynowego. Model umożliwiał segmentację lasów na podstawie wycinków $256 \text{ px} \times 256 \text{ px}$ czterokanałowych (RGB+NIR) zobrazowań satelitarnych. Badanie zakładało uzyskanie delimitacji obszarów leśnych kraju w postaci masek segmentacyjnych. Maski są wytworzonymi przez sieć jednokanałowymi rastrami $256 \text{ px} \times 256 \text{ px}$ powstały po progowaniu mapy prawdopodobieństwa wystąpienia w danym pikselu lasu. Następnie wszystkie wycinki scalono w całość tworząc mapę pokrycia lasem dla całej Polski. Rycina 3 przedstawia rezultat pracy modelu dla obszaru badawczego doliny rzeki Pilicy.

Wyniki zagregowane do poziomu gmin (NUTS-5) porównano z danymi z ksiąg wieczystych przekazanych do Banku Danych Lokalnych (BDL) przez Główny Urząd Statyczny (GUS). Zidentyfikowane różnice pomiędzy ww. źródłami zostały określone jako błędy ksiąg wieczystych. Następnie zastosowano regresję ważoną geograficznie, w celu wyjaśnienia przestrzennie zróżnicowanego wpływu determinant badanych błędów: procesów urbanizacyjnych, rozwoju społeczeństwa obywatelskiego, edukacji, własności gruntów oraz kultury i jakości planowania przestrzennego. Obszar badań objął całą Polskę.

Kluczowe w procesie uczenia sieci było nie tylko wybranie odpowiedniej architektury, ale również określenie jej głębokości oraz liczby filtrów splotowych w każdej z warstw. Związane było to z potrzebą detekcji różnorodności typów siedlisk leśnych oraz ich występowaniem w przestrzeni geograficznej kraju. Przestrzennie las jest niezmiernie złożoną strukturą. Opierając się na wynikach przeprowadzanych badań można stwierdzić, że najtrudniejszym elementem segmentacji jest dokładna delineacja granic lasu. W ramach przygotowań do opracowania modelu Autor zidentyfikował nieprawidłowości, które związane były z klasyfikacją starego odłogu lub sadu jako lasu.

Podczas eksperymentów wstępnych najlepsze rezultaty otrzymano przy zastosowaniu wyjątkowo głębokiej i złożonej sieci U-Net. W związku ze specyfiką tej sieci, jak również z zastosowaną konfiguracją, uczenie przy posiadanych zasobach byłoby niemożliwe. Zdecydowano się na sieć płytzą, ale o większej liczbie filtrów. Uzyskane wyniki były satysfakcjonujące, jednak pozostało wiele do poprawy. Na możliwość osiągnięcia lepszych rezultatów zwrócono uwagę podczas recenzji, co stanowiło motywację do podjęcia się kolejnej pracy, również umieszczonej w cyklu rozprawy.

W trakcie retrospekcji projektu badawczego, podjęto pracę z innymi typami pokrycia. Z badań pilotażowych nad segmentacją pokrycia terenu wynika, że delineacja obszarów leśnych, podobnie jak terenów uprawnych, stanowi doskonały problem wprowadzający w proces badawczy oparty o techniki teledetekcyjne wsparte uczeniem maszynowym. Związane jest to przede wszystkim z wysoką jakością utrwalanej w sieci splotowej reprezentacji cech przestrzennych, uzyskanych podczas analizy obrazu w świetle widzialnym (ang. *visible*, VIS) oraz bliskiej podczerwieni (ang. *near-infrared*, NIR), która klasycznie wykorzystywana jest w wyliczaniu wskaźników roślinności (Jarocinska i Zagajewski, 2008). Potwierdzają to również wcześniejsze badania związane z klasyfikacją odlogów. Niemniej jednak obszary zabudowane czy ciągi komunikacyjne okazały się większym wyzwaniem, zaś ich analiza pozwoli na lepsze rozumienie procesu segmentacji.



Ryc.3. Model semantycznej segmentacji obszarów leśnych zastosowany dla obszaru badawczego doliny rzeki Pilicy: A - wejściowy obraz satelitarny w kompozycji RGB, B – mapa prawdopodobieństwa, będąca rezultatem pracy modelu U-Net, C – wynikowa mapa segmentacyjna; źródło: opracowanie własne na podstawie (Adamiak i in., 2020).

Adamiak, M., Jaźdżewska I., Nalej M. (2021). *Analysis of Built-Up Areas of Small Polish Cities with the Use of Deep Learning and Geographically Weighted Regression*, Geosciences, 11(5), 223, <https://doi.org/10.3390/geosciences11050223>

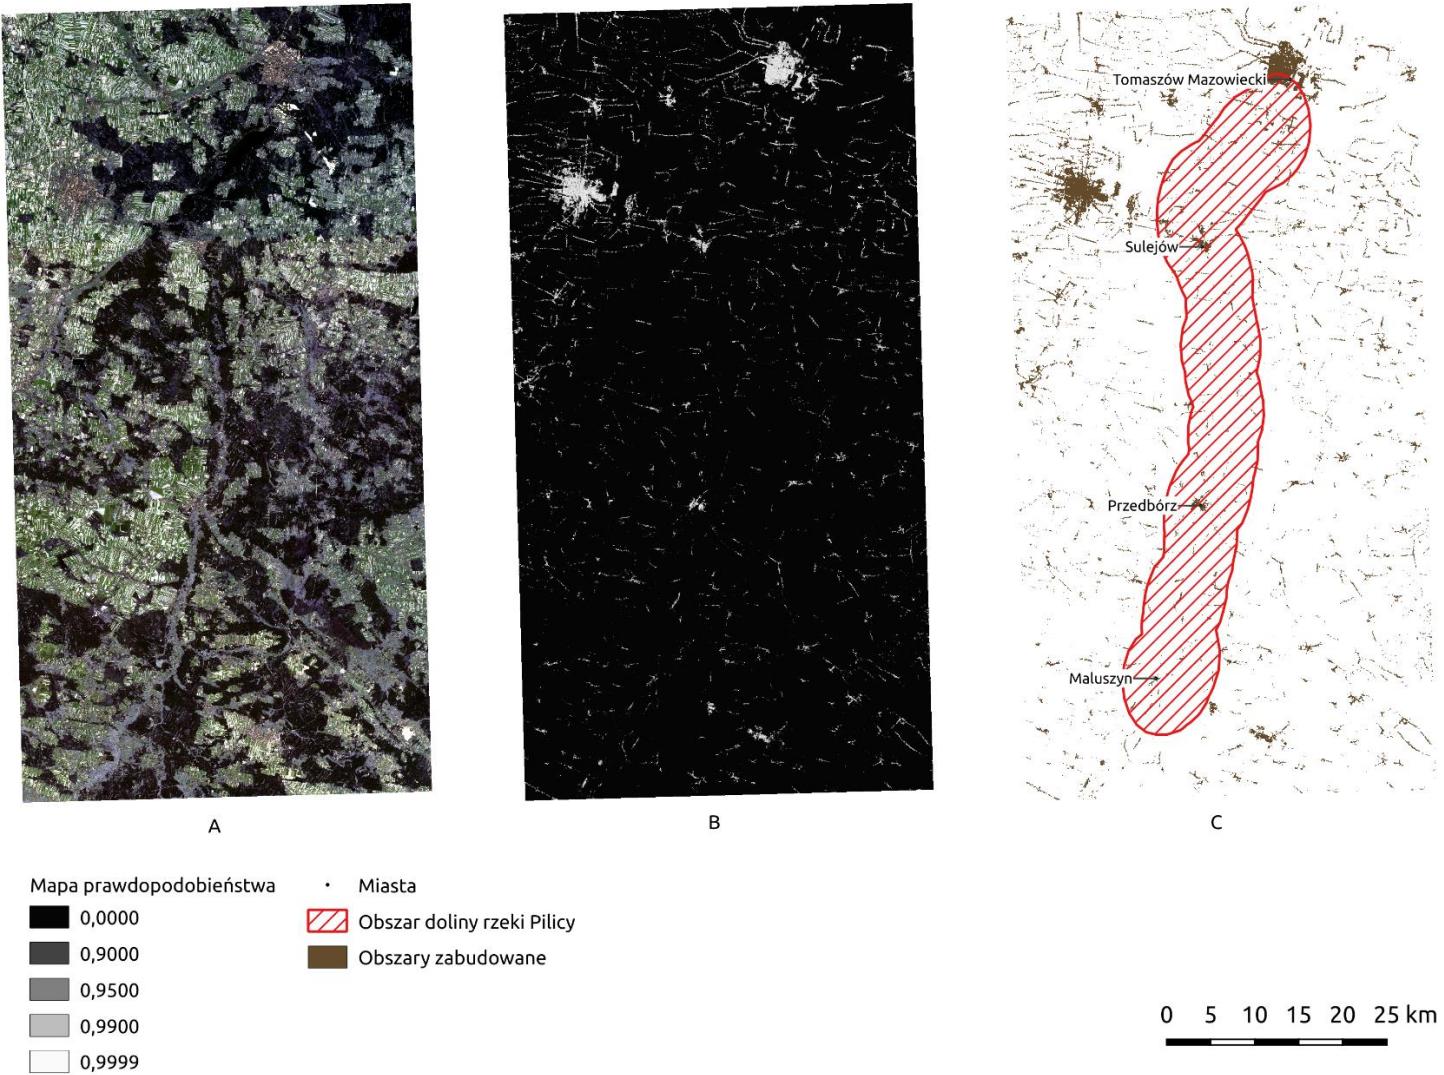
Celem projektu badawczego była weryfikacja wpływu wybranych czynników społeczno-ekonomicznych na udział obszarów zabudowanych w 665 małych miastach Polski w 2019 roku. Utworzono model zdolny do segmentacji wybranego typu pokrycia terenu. Rezultat został opracowany na poziomie gmin (NUTS-5) i posłużył do obliczenia wskaźnika zmian powierzchni zabudowy między 2015 - 2019 rokiem. Otrzymany wskaźnik wraz z danymi pobranymi z Banku Danych Lokalnych GUS (BDL) stanowił wejście do algorytmu regresji ważonej geograficznie i posłużył do wyjaśnienia przestrzennego zróżnicowania wpływu czynników, związanych z zaludnieniem, rozwojem przestrzennym i gospodarczym oraz poziomem życia, na udział obszarów zabudowanych na obszarze małego miasta.

Proces trenowania modelu nadzorowanej semantycznej segmentacji przebiegał analogicznie jak w przypadku obszarów leśnych. Zmianie uległo natomiast zadanie modelu, które skupiało się tym razem na delineacji terenów zabudowanych. Dane wejściowe stanowiły zobrazowania satelitarne Sentinel-2 oraz etykiety utworzone przez przetworzenie odpowiednich warstw BDOT. Wykorzystano bardziej zaawansowaną niż U-Net architekturę głębokiej sieci neuronowej DeepLabV3+. W trakcie trenowania czterokanałowe wycinki (RGB + NIR) $256 \text{ px} \times 256 \text{ px}$ poddawano losowym przekształceniom przez ich odwracanie, skalowanie, obracanie i rozciąganie. Miało to istotny wpływ na dokładność modelu, który ostatecznie osiągnął wartość indeksu Jaccarda (ang. *Jaccard index, intersection over union, IoU*) na poziomie 0,548 i 0,588. Rycina 4 przedstawia rezultat pracy modelu dla obszaru badawczego doliny rzeki Pilicy.

To, co Autor uznał za wynik projektu badawczego, w kontekście uczenia maszynowego, jest nie tylko poprawnie przeprowadzonym procesem segmentacji i poznaniem nowej wyjątkowo sprawnej architektury sieci. Wiedza, która pochodzi z tego badania, zawiera się w szerszym problemie badawczym, jakim jest wyznaczanie granic obszaru zabudowanego. Zwrócić uwagę na wartość IoU osiągniętą przez model na danych testowych. Wartość równa 1 wskazywałaby, że segmentacja jest wzorcowa i nie ma odchyleń między rezultatem działania sieci a segmentacją referencyjną. Odwrotnie jest w przypadku wartości 0 oznaczającej, że obie segmentacje są całkowicie rozbieżne. W praktyce osiągnięcie wyniku równego 1 jest niezmiernie rzadkie, zaś rezultat powyżej 0,5 jest już uznawany za dobry. W trakcie

projektowania rozwiązań i prowadzenia eksperymentów, Autorowi nie udało się osiągnąć wartości IoU powyżej 0,6. Po wielu testach stwierdzono, że problem nie stanowi konstrukcja modelu, ale jakość warstw dostępnych w BDOT. Mimo, że baza ta jest jednym z największych i najdokładniejszych źródeł informacji o terenach zabudowanych dostępnym w Polsce, nie jest wolna od wad. Podczas wnikliwej analizy można odkryć, że wiele poligonów wyznaczających obszary zabudowane w warstwach BDOT nie opisuje w sposób dokładny ich granic. Są one często za mało skomplikowane w stosunku do badanej struktury. Wbrew pozorom nie jest to przeszkodą dla modelu uczenia maszynowego, który przez dostarczenie mu odpowiedniej liczby przykładów i znacznej augmentacji próbek radzi sobie dobrze z delimitacją granic. Oczywiście taki model oferuje suboptimalne rozwiązanie problemu, ponieważ wewnętrznie jego funkcja kosztu jest nadal oparta na porównaniu rezultatów z niedoskonałym zbiorem referencyjnym. Rzutuje to również na niższą wartość miar ewaluacyjnych modelu, który nie będąc w stanie popełnić podobnego błędu jakiego dokonano podczas etykietowania, wykazuje niższą niż w rzeczywistości skuteczność.

Dla Autora badanie terenów zabudowanych było cennym doświadczeniem w pracy z wysokiej jakości danymi teledetekcyjnymi. Jednocześnie w połączeniu z wcześniejszymi zadaniami badawczymi, dotyczącymi segmentacji obszarów leśnych umożliwiło budowę szeregu rozwiązań z zakresu uczenia maszynowego, które wspierają proces interpretacji przestrzeni geograficznej. Przykładem takiego rozwiązania jest metoda segmentacji nienadzorowanej omówiona w kolejnym rozdziale pracy.



Ryc.4. Model semantycznej segmentacji obszarów zabudowanych zastosowany dla obszaru badawczego doliny rzeki Pilicy: A - wejściowy obraz satelitarny w kompozycji RGB, B – mapa prawdopodobieństwa, będąca rezultatem pracy modelu DeepLabV3+, C – wynikowa mapa segmentacyjna; źródło: opracowanie własne na podstawie (Adamiak, Jaźdżewska, i in., 2021)

4.3. Segmentacja nienadzorowana

Adamiak, M., Będkowski, K., Majchrowska, A. (2021). *Aerial Imagery Feature Engineering Using Bidirectional Generative Adversarial Networks: A Case Study of the Pilica River Region, Poland*. *Remote Sensing*, 13(2), 306, <https://doi.org/10.3390/rs13020306>

W trakcie projektu badawczego zaprojektowano i przetestowano nienadzorowaną procedurę semantycznej segmentacji zobrazowań satelitarnych i lotniczych. Opiera się ona o proces tworzenia sztucznych zobrazowań lotniczych oraz kodowanie cech przestrzeni geograficznej, opisanej przez ortofotomapę zakodowaną w warstwach ukrytych generatywnej sieci współzawodniczącej BigBiGAN.

Pierwszym zadaniem projektu badawczego było sprawdzenie możliwości generowania sztucznych, ale realistycznych wycinków obrazu przestrzeni geograficznej. Proces tworzenia metody rozpoczęto od rozwiązania problemu wzbogacania danych. Augmentacja to proces, którego rezultatem jest zwiększenie liczebności badanej próby przez generowanie w sposób losowy różnorodnych odmian obserwacji. Modele ML wymagają często tysięcy, a nawet setek tysięcy obrazów wejściowych, aby wyspecjalizować się w pewnym zadaniu, czy będzie to klasyfikacja, detekcja czy segmentacja. Wzbogacanie danych pozwala na wykorzystanie istniejących próbek jako wzorców do tworzenia nowych próbek. Model uczony na wzbogaconym zbiorze powinien lepiej się generalizować, czyli mieć wyższą skuteczność podczas pracy z nowymi danymi. Potwierdzono eksperymentalnie, że proces generowania sztucznych obrazów jest możliwy. Zastosowano w tym celu sieć BigBiGAN (ang. *big bidirectional generative adversarial network*).

Następnym krokiem było określenie sposobu kontrolowania mechanizmu tworzenia próbek, aby możliwy był wybór cech obrazu, które muszą pojawić się w nowym, syntetycznym zbiorze. Używanie prostych parametrów konfiguracyjnych programu komputerowego okazało się niewystarczające w przypadku tak skomplikowanej formy danych, jakimi są materiały teledetekcyjne. Zaproponowano prawdziwy obraz jako element konfiguracji, na podstawie którego tworzony będzie obraz sztuczny. W konsekwencji zdefiniowano zadanie sieci neuronowej, jakim było wytworzenie sztucznego obrazu podobnego do prawdziwego, wzorcowego obrazu ze względu na występowanie i kompozycję cech przestrzennych. Model zaimplementowanej sieci neuronowej podzielono na pięć osobnych modułów:

1. generator, którego zadaniem było tworzyć syntetyczne wycinki ortofotomapy na podstawie 120-to elementowego kodu liczbowego. Kod liczbowy to swojego rodzaju przepis na stworzenie obrazu o zadanych cechach;
2. enkoder, którego zadaniem było zapisanie każdego wejściowego obrazu, prawdziwego bądź sztucznego, do reprezentującego go 120-to elementowego kodu liczbowego. Należy podkreślić, że kod zawiera informacje o cechach obrazu oraz sile ich występowania, jednak nie posiada informacji o ich lokalizacji. Tym samym, kod liczbowy otrzymany w wyniku kodowania obrazu przez enkoder i wykorzystany jako przepis dla generatora nie zwróci identycznego obrazu wejściowego, lecz tylko do niego podobny pod względem cech przestrzennych;
3. pozostałe moduły modelu to trzy dyskryminatory, których zadaniem było rozstrzygać, czy mają do czynienia z obrazem syntetycznym czy prawdziwym oraz czy otrzymany kod powstał podczas kodowania prawdziwego obrazu albo czy jest on kodem losowym.

Wynikiem pracy był model GAN, który na podstawie wejściowego obrazu dokonywał rekonstrukcji tj.: sprowadzał obraz prawdziwy do kodu liczbowego i wykorzystywał ten kod, aby utworzyć obraz sztuczny. Danymi wejściowymi w procesie trenowania modelu były wycinki ortofotomapy pobrane z Geoportalu. Przedstawiały one obszar doliny Pilicy w regionie łódzkim między Maluszynem a Tomaszowem Mazowieckim.

Kody liczbowe przetrzymujące informacje o podobnej kompozycji cech również wykazywały podobieństwo i tworzyły klastry, co sprawdzono z użyciem algorytmu PCA i manualnej weryfikacji każdego z wyróżnionych skupień. Rezultaty przedstawione zostały na rycinach 5 - 8. W ostatnim etapie projektu badawczego przetestowano tę własność przez zastosowanie kodów, wytworzonych przez enkoder jako wejście do klasycznego algorytmu analizy przestrzennej, jakim jest metoda Warda. Wycinki pobrane z losowo wybranego arkusza ortofotomapy przedstawiającego obszar badawczy, poddano kodowaniu. Każdemu z otrzymanych 120-to elementowych kodów nadano georeferencję zgodnie z koordynatami geograficznymi środka odpowiadającego mu wycinka. Zbiór kodów został wykorzystany jako wejście do algorytmu grupującego, którego rezultatem jest przypisanie każdemu z kodów wartości liczbowej reprezentującej numer przypisanego krajobrazu. W wyniku przeniesienia informacji o numerach krajobrazów do QGIS, zgodnie z wcześniej przypisanymi koordynatami, otrzymano mapę segmentacji obszaru.



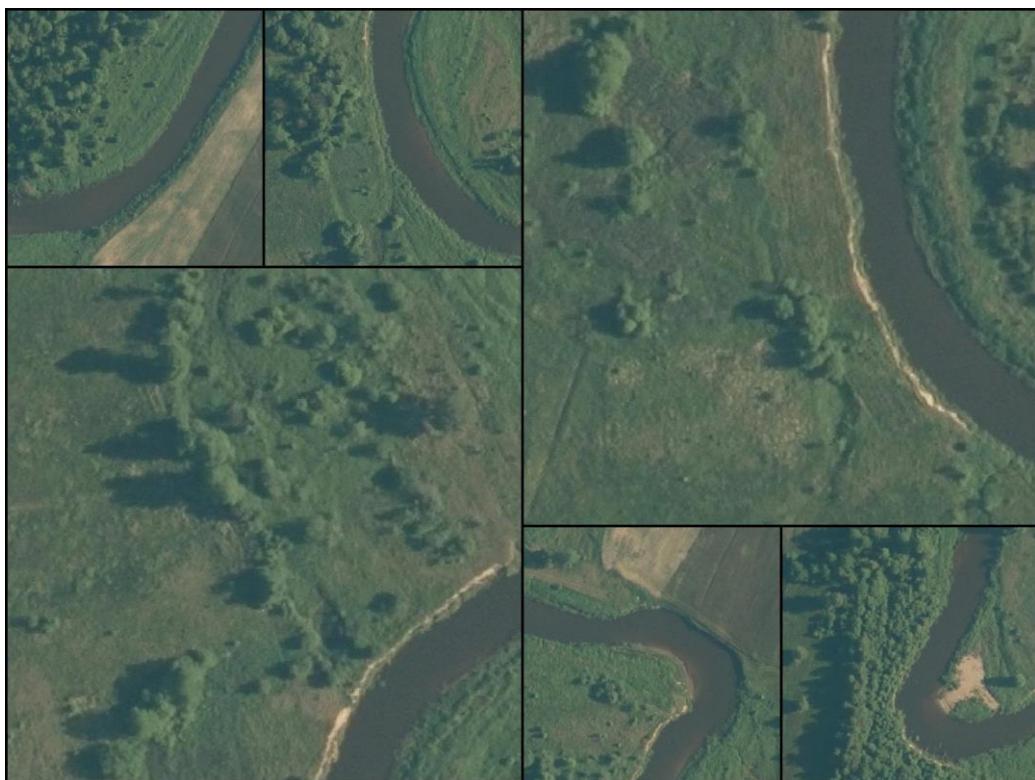
Ryc. 5. Wycinki ortofotomapy przedstawiające obszary posiadające podobne kody liczbowe – las z wycinką;
źródło: opracowanie własne na podstawie (Adamiak, Będkowski, i in., 2021; *Geoportal*, 2021)



Ryc. 6. Wycinki ortofotomapy przedstawiające obszary posiadające podobne kody liczbowe – łąka lub odlóg;
źródło: opracowanie własne na podstawie (Adamiak, Będkowski, i in., 2021; *Geoportal*, 2021)



Ryc. 7. Wycinki ortofotomapy przedstawiające obszary posiadające podobne kody liczbowe – las; źródło: opracowanie własne na podstawie (Adamiak, Będkowski, i in., 2021; *Geoportal*, 2021)



Ryc. 8. Wycinki ortofotomapy przedstawiające obszary posiadające podobne kody liczbowe – koryto rzeki, terasa zalewowa; źródło: opracowanie własne na podstawie (Adamiak, Będkowski, i in., 2021; *Geoportal*, 2021)

5. Dyskusja

Klasyfikacja oraz segmentacja to zadania stojące przed zespołami badawczymi, chcącymi wykryć pewne szczególne cechy badanej przestrzeni geograficznej lub dokonać jej podziału na jednorodne obszary. Zadania te mogą stanowić główną składową opracowywanego zagadnienia lub być tylko jednym z wielu kroków wymaganych, aby uzyskać odpowiedź na postawione pytania badawcze. Szczególnym przypadkiem zadań realizowanych przez zastosowanie klasyfikacji lub segmentacji jest analiza pokrycia terenu z wykorzystaniem zobrazowań lotniczych i satelitarnych. W celu uzyskania wiedzy odnośnie do pokrycia terenu, można zastosować różnorodne metody, w tym: wizualną fotointerpretację, klasyfikację obiektową lub uczenie maszynowe.

Fotointerpretacja wizualna wspomagana narzędziami GIS, mimo czasochłonności, zapewnia najdokładniejsze rezultaty. Jakość opracowań jest bezpośrednio zależna od umiejętności badacza w zakresie pracy ze zdjęciem satelitarnym lub lotniczym. Z drugiej strony manualne wprowadzanie informacji jest często, przy niewielkich zasobach czasu, ograniczone do niewielkiego wycinka przestrzeni geograficznej. Wpływa to na złożoność samego procesu badawczego, który w związku z niedostatecznym nasyceniem danymi badawczymi sprowadza się często do inwentaryzacji, wizualizacji czy opisu z pominięciem ilościowej analizy przestrzennej. Przykładem badań stosujących tę technikę może być analiza zmian pokrycia terenów na obszarze miejskim (Nalej, 2018).

Kolejnym sposobem analizy przestrzeni geograficznej w kontekście pokrycia terenu jest, posiadająca ugruntowaną pozycję i szeroko stosowaną, klasyfikacja obiektowa (ang. *object based image analysis*, OBIA). Algorytm segmentacji ma upodabniać swoje działanie do delineacji, jaką w tradycyjny sposób prowadziłby doświadczony operator podczas procesu interpretacji obrazu, posługując się różnymi barwnymi kompozycjami (Adamczyk i Będkowski, 2006; Wężyk i in., 2006). Innymi słowy, jest to automatyczna albo półautomatyczna odmiana fotointerpretacji wizualnej. Metoda klasyfikacji obiektowej odgrywa szczególną rolę podczas analizy wysokorozdzielczych zdjęć satelitarnych, których opracowanie metodami tradycyjnymi jest mało efektywne. Jest to wyjątkowo dobrze widoczne w przypadku klasyfikacji terenów zurbanizowanych charakteryzujących się wielką różnorodnością obiektów, związanych nie tylko z odwzorowaniem budynków, lecz także z ich cieniami oraz całą infrastrukturą miejską, w której skład wchodzi również roślinność (Lewiński, 2007).

Analiza przestrzeni geograficznej odbywa się również przy użyciu uczenia maszynowego. Często stosowanym algorytmem klasyfikacji pokrycia terenu są lasy losowe (ang. *random forest*, RF) lub maszyna wektorów nośnych (ang. *support vector machine*, SVM) (Grabska i in., 2020; Malinowski i in., 2020; Zagajewski i in., 2021). Rezultaty opracowań powstały z ich użyciem są wysokiej jakości. Sama technika ma jednak istotne ograniczenie widoczne w przypadku zastosowania jej na poziomie klasyfikacji pojedynczych pikseli. Pojawia się wtedy problem ograniczoności zasobów obliczeniowych w trakcie procesu trenowania modelu jak również wnioskowania z jego użyciem. Konsekwencją tego jest potrzeba ograniczenia zbioru badawczego i losowania pikseli biorących udział w badaniu, zamiast pracy z większym ciągłym wycinkiem obrazu. Zaletą stosowania klasycznych metod uczenia maszynowego jest możliwość wyjaśnienia sposobu powstania otrzymanego rezultatu poprzez interpretację parametrów modelu. Ma to kluczowe znaczenie w projektach badawczych, które wymagają ścisłej kontroli nad procesem analitycznym.

Wartym uwagi jest zastosowanie głębokich sieci splotowych w procesie analizy przestrzeni geograficznej. Wysoka dokładność klasyfikacji modeli głębokiego uczenia wynika bezpośrednio z wewnętrznej konstrukcji sieci konwolucyjnych. Działanie w zakresie cech przestrzennych obrazu, a nie pojedynczych pikseli, umożliwia poprawną klasyfikację nowych obserwacji. Nie do przecenienia są krótkie czasy wnioskowania, związane z prowadzeniem obliczeń opartych na koncepcji tensora, jak również przy zastosowaniu kart graficznych (ang. *graphical processing unit*, GPU) oraz możliwość pracy z dużymi zbiorami danych (ang. *big data*). Jednocześnie liczyć się trzeba z długim czasem trenowania modelu oraz potrzebą zgromadzenia znacznej ilości danych treningowych. Ciekawym zabiegiem dostępnym dla głębokiego uczenia jest transfer wiedzy między modelami odbywający się przez wymianę wag (ang. *transfer learning*, TL). Skraca to czas potrzebny do zrealizowania kolejnego i podobnego badania oraz często istotnie wpływa na dokładność opracowanego rozwiązania. Modele głębokiego uczenia charakteryzują się częściową możliwością interpretacji i wyjaśniania w ramach XAI (ang. *explainable artificial intelligence*). Większość rozwiązań należy uznać za czarne skrzynki (ang. *black box*), które co prawda oferują wysokiej jakości rezultaty, lecz nie dają możliwości określenia, w jaki sposób te rezultaty powstały. Istnieją co prawda algorytmy umożliwiające wyjaśnienie pracy modelu, czego doskonałym przykładem jest SHAP (ang. *SHapley Additive exPlanations*) lub Grad-CAM (Lundberg i Lee, 2017; Selvaraju i in., 2017), jednak stanowią odrębne rozwiązania, a nie cechy samych modeli. XAI jest rozwijającą się dyscypliną i należy spodziewać się wielu interesujących odkryć, umożliwiających poznanie

sposobu funkcjonowania nawet najbardziej złożonych modeli. Przykładami zastosowania sieci neuronowych w klasyfikacji i segmentacji przestrzeni geograficznej oraz jej elementów, oprócz publikacji wskazanych w niniejszej rozprawie, są choćby: klasyfikacja pokrycia dachów budynków (Krówczyńska i in., 2020), odkrywanie zmian w procesach deforestacji (Bem i in., 2020), lokalizowanie raf koralowych (Jaisakthi i in., 2019) i wiele więcej.

Proces interpretacji przestrzeni geograficznej z użyciem głębokiego uczenia przebiega podobnie, jak w przypadku poprzednich metod. Kluczowym zagadnieniem jest zdefiniowanie opracowywanego problemu badawczego oraz określenie zasobu danych pierwotnych. Kolejnym krokiem jest przypisanie poszczególnym celom badawczym metod dostępnych w ramach uczenia maszynowego, np.: analiza pokrycia terenu może zostać uznana za semantyczną segmentację. Następnie projektowana jest architektura sieci neuronowej, zdolnej przy posiadanych danych doprowadzić do realizacji określonego celu. Ostatnimi etapami są: implementacja rozwiązania w postaci programu komputerowego, jego testowanie, wnioskowanie przy jego pomocy, a następnie integracja z dalszymi etapami procesu badawczego. Zastosowana przez Autora procedura, obowiązująca w ramach wszystkich projektów badawczych zrealizowanych w trakcie przygotowania rozprawy, przedstawiona została na rycinie 9.



Ryc. 9. Procedura prowadzenia badań naukowych z zakresu nauk o Ziemi i środowisku w powiązaniu z metodami i technikami uczenia maszynowego oraz teledetekcji, zastosowana w trakcie przygotowywania rozprawy; źródło: opracowanie własne.

Głębokie uczenie swój sukces zawdzięcza mechanizmowi kodowania danych, a precyzyjniej wyodrębnianiu cech (ang. *feature extraction*). W opisywanym w cyklu rozprawy przypadku wejście do sieci stanowią dane teledetekcyjne. Postać rastrowa samodzielnie nie gwarantuje wysokiej jakości otrzymywanych rezultatów. Wymagany krokiem jest inżynieria cech (ang. *feature engineering*), która zagwarantuje uchwycenie istotnych z punktu prowadzonego badania atrybutów badanego obrazu. W głębokich sieciach neuronowych za inżynierię cech odpowiedzialne są warstwy ukryte (ang. *hidden layers*), tj. wszystkie warstwy w sieci między jej wejściem a wyjściem.

Wspomniano wcześniej, na podstawie definicji Adamczyk i Będkowskiego (2007), że wyróżnia się dwa typy danych przestrzennych: geometryczne i opisowe. Żadne z nich nie przystaje jednak do sposobu reprezentacji danych przestrzennych w sieci neuronowej. Należałyby poszerzyć definicję o dodatkowy typ, jakim są reprezentacje, czyli utrwalone w określonej formie rezultaty transformacji i przetworzenia pierwotnych danych geometrycznych bądź opisowych, ułatwiające wydobywanie przydatnych informacji podczas budowania klasyfikatorów (Bengio i in., 2014). Opisywanym przykładem reprezentacji danych geograficznych jest utrwalenie cech przestrzennych w warstwach ukrytych. W głębokiej splotowej sieci neuronowej warstwy ukryte to warstwy splotowe, które kodują cechy przestrzenne przy użyciu filtrów splotowych (ang. *convolutional filters*). Proces budowania reprezentacji w oparciu o wielokrotną nieliniową transformację zachodzącą w sieci neuronowej nazywamy uczeniem się reprezentacji (ang. *representation learning*), która stanowi jeden z głównych konceptów uczenia maszynowego.

Istotne jest, w jaki sposób powstaje reprezentacja zobrazowań w sieci neuronowej. W przypadku procesu nadzorowanego uczenia (ang. *supervised learning*) jest ona wynikiem procesu rekonfigurowania się modelu przez porównanie osiąganych przez niego chwilowych rezultatów z określonym przez badacza wzorcem. Reprezentacja dostraja się do postawionego przed siecią zadania. Inaczej jest w sytuacji, gdy brak jest wzorca i proces uczenia nie jest nadzorowany. Uczenie nienadzorowane (ang. *unsupervised learning*) wymaga zaprojektowania złożonego mechanizmu kontroli procesu tworzenia reprezentacji. Mechanizm kontroli powinien być automatyczny. Nie może angażować badacza i musi współpracować z operacją trenowania modelu. Tym samym, aby mieć wpływ na przebieg całego procesu, mechanizm kontroli musi posiadać możliwość dostosowywania się do zmian obserwowanych podczas uczenia reprezentacji. Problem ten rozwiązują generatywne sieci współzawodniczące (ang. *generative adversarial networks*, GAN).

GAN to architektura sieci neuronowej zbudowana z co najmniej jednego generatora i jednego dyskryminatora. Zadaniem generatora jest wytworzenie syntetycznej próbki o takich parametrach, aby jej odróżnienie od prawdziwych elementów zbioru referencyjnego było niemożliwe dla dyskryminatora. Dyskryminator, otrzymując informacje o popełnionych przez siebie pomyłkach, uczy się trafniej rozróżniać próbki syntetyczne od prawdziwych. Informacja o zdolnościach dyskryminatora jest propagowana do generatora, który w kolejnej iteracji dostosowuje swoje działanie. W trakcie procesu uczenia GAN obie sieci konkurują ze sobą tworząc z czasem coraz doskonalsze rezultaty (Goodfellow i in., 2014). Wytrenowana sieć GAN jest zdolna przy pomocy utrwalonej w niej reprezentacji danych produkować sztuczne i realistyczne obrazy. Potwierdzono możliwość takiego zastosowania GAN opartego na danych geograficznych przez zaimplementowanie rozwiązania generującego sztuczne wycinki przestrzeni geograficznej (publikacja 4).

Istotnym ograniczeniem GAN w procesie uczenia nienadzorowanego w interpretacji przestrzeni geograficznej był do niedawna fakt posiadania jedynie mechanizmu umożliwiającego tworzenie sztucznych próbek przy jednoczesnym braku rozwiązania oferującego operację odwrotną (Donahue i in., 2017). Faktem jest, że możliwość tworzenia sztucznych zbiorów danych i wzbogacenia materiału badawczego są nie do przecenienia. Jednak z punktu widzenia współczesnych badań nad przestrzenią geograficzną udział augmentacji w procesie badawczym jest niewielki i ograniczony do badań symulacyjnych lub wyszukanych zastosowań uczenia maszynowego. Interesująca jest dla badaczy przestrzeni geograficznej operacja odwrotna, polegająca na transformacji analizowanego wycinka do reprezentacji, a więc zakodowanego w sieci zbioru cech przestrzennych oraz umożliwienie dostępu do reprezentacji poprzez sprowadzenie jej do formy przystępnej do analiz. Przykładem może być zastosowany w badaniach Autora kod liczbowy, zawierający informacje o cechach badanej przestrzeni i sile ich występowania, który powstał w nienadzorowanym procesie uczenia GAN.

Ważnym zagadnieniem związanym z uczeniem reprezentacji, jest potwierdzenie jej zdolności do kodowania cech przestrzennych zawartych w analizowanym zbiorze danych. W przypadku uczenia nadzorowanego ocena jakości otrzymanej reprezentacji odbywa się bezpośrednio przez pomiar skuteczności modelu uczenia maszynowego w rozwiązywaniu postawionego przed nim zadania (publikacje 1-3). Zbieżność rezultatu do wzorca, zawartego w zbiorze testowym, implikuje poprawnie utworzoną reprezentację. W tym celu stosuje się znane ze statystyki metody, tj.: dokładność (ang. *accuracy*), precyzja (ang. *precision*), czułość

(ang. *recall* lub *sensitivity*), swoistość (ang. *specificity*), *F1-score*, AUC (ang. *area under curve*), IoU (ang. *intersection over union*) i inne. Im wartość tych miar na zbiorze testowym jest wyższa, tym lepsza musi być reprezentacja danych utrwalonych w sieci neuronowej. Zasada ta zachowana jest również dla danych pochodzących ze zobrazowań lotniczych i satelitarnych. Ocena jakości reprezentacji otrzymanej podczas uczenia nienadzorowanego jest trudniejsza. W przypadku rozwiązań opartych na GAN, miarą dokładności reprezentacji jest jakość wygenerowanej, sztucznej próbki (publikacja 4). Używa się w tym celu takich miar, jak FID (ang. *Fréchet inception distance*) czy HYPE (ang. *human eye perceptual evaluation*) (Heusel i in., 2018; Zhou i in., 2019).

Ocena jakości reprezentacji staje się jeszcze trudniejsza, gdy odbywa się ona z uwzględnieniem wzajemnej relacji między poszczególnymi składowymi wielomodułowej sieci neuronowej, przykładem której jest BigBiGAN. Architektura tej sieci zawiera pięć podsieci, z których jedna odpowiedzialna jest za generowanie obrazu, kolejna za kodu liczbowego. Pozostałe moduły to dyskryminatory tworzące mechanizm kontroli procesu uczenia. Ocenę jakości reprezentacji można przeprowadzić przez rekonstrukcję, tj.: sprowadzenie obrazu prawdziwego do kodu liczbowego i wykorzystaniu tego kodu, aby utworzyć obraz sztuczny, będący obrazem podobnym do wejściowego obrazu prawdziwego. Podobnie jak wcześniej istnieje możliwość zastosowania FID i HYPE do oceny sztucznego obrazu. W ograniczonych przypadkach można również zastosować błąd średniokwadratowy (ang. *mean square error*), SSIM (ang. *structural similarity index measure*), FSIM (ang. *feature similarity index measure*) lub PSNR (ang. *peak signal-to-noise ratio*) (Horé i Ziou, 2010; Wang i in., 2004; Zhang i in., 2011).

Zakodowanie informacji o cechach przestrzeni jako kombinacji filtrów powstaje w wyniku procesu uczenia w oparciu o dane pierwotne. W przypadku przeprowadzonych badań były to zobrazowania satelitarne i lotnicze. Przegląd literatury oraz przeprowadzone przez Autora badania potwierdzają, że zastosowanie tego typu reprezentacji danych jest nie tylko możliwe, ale również wskazane w interpretacji przestrzeni geograficznej. Po pierwsze, konstrukcja głębokiej splotowej sieci neuronowej umożliwia uchwycenie wystarczającej liczby różnorodnych cech przestrzennych, aby móc odróżnić różne typy pokrycia terenu bez wzgledu na to, czy opracowywane są odłogi (publikacja 1), obszary leśne (publikacja 2) czy miejskie (publikacja 3). Po drugie, bogactwo utrwalonych w sieci cech przestrzennych umożliwia otrzymywanie, w procesie syntezy, sztucznych, ale realistycznych zobrazowań, co dowodzi predyspozycji tego typu zapisu w rozwiązywaniu złożonych problemów badawczych. Analiza

pokrycia terenu jest tylko jednym z możliwych obszarów zastosowań. Współczesna literatura z zakresu teledetekcji wskazuje na mnogość innych zadań, jakie stoją przed głębokim uczeniem w analizie zobrazowań. Doskonałymi przykładami mogą być simulacja w oparciu o modele fizyczne (Camps-Valls i in., 2021), zwiększenie rozdzielczości zobrazowań (Ma i in., 2018), uzupełnianie braków wynikających z zachmurzenia (ang. *inpainting*) (Dong i in., 2019) i inne.

Reprezentacja utrwalona w warstwach splotowych sieci może zostać wykorzystana w procesie badawczym w sposób bezpośredni i pośredni. Najczęstszym zabiegem jest poprzedzenie szeregu warstw splotowych perceptronem wielowarstwowym (ang. *multilayer perceptron*, MLP) oraz wybraną funkcją aktywacji w celu otrzymania rezultatu będącego liczbą lub wektorem. Podejście pośrednie zastosowano we wszystkich publikacjach w cyklu rozprawy, zaś jego najprostszą odmianę czytelnik znajdzie w artykule dotyczącym nadzorowanej klasyfikacji odlogów (publikacja 1). Bezpośrednie użycie reprezentacji danych przestrzennych jest procesem trudniejszym. Przykładem może być komponowanie syntetycznych próbek przy użyciu utrwalanych, w cyklu uczenia, cech badanej przestrzeni geograficznej (publikacja 4).

Bez względu na wybrane podejście, badacz utrzymuje pełną kontrolę nad formatem wyjściowym opracowywanego rozwiązania. Może zdecydować się na przypisywanie każdej obserwacji wejściowej, będącej w formie geometrycznej lub opisowej, pojedynczej wartości liczbowej z pewnego określonego zakresu lub posługiwać się uporządkowanym zbiorem wartości, który następnie przetworzy do innego formatu. Jest to niezmiernie istotne z punktu widzenia wkomponowania metod oferowanych przez uczenie maszynowe w proces badawczy nauk o Ziemi i środowisku, który ze względu na złożoność poruszanych problemów badawczych, wypracowany i dojrzały warsztat oraz wysokie wymagania odnośnie do wizualizacji, wymaga znacznego przetworzenia rezultatów.

Prowadzone przez Autora badania wskazują, że istnieje możliwość powiązania rezultatów otrzymanych przy pomocy metod głębokiego uczenia z klasycznymi algorytmami, stosowanymi w analizie przestrzeni geograficznej, jakimi są statystyka Getis-Ord G*, regresja ważona geograficznie, współczynnik autokorelacji Morana czy metoda Warda. Możliwa jest również wizualizacja wyników pracy sieci neuronowej w postaci map, co ma kluczowe znaczenie w prowadzeniu dalszych analiz i wizualizacji. Wizualizacja, oprócz zachowania georeferencji, wymaga także stosowania algorytmów łączących wyniki częściowe. Sieć splotowa ze względu na swoją budowę nie jest w stanie poddać analizie całego zobrazowania przedstawiającego badaną przestrzeń. Wymagana jest w związku z tym praca na wycinkach

obrazu o stałym rozmiarze. Przykładem łączenia wyników cząstkowych jest tutaj algorytm *sliding window inference* (MONAI, 2022), którego zastosowanie w budowaniu map w oparciu o semantyczną segmentację jest wskazane.

Zastosowanie uczenia maszynowego, w tym głębokiego uczenia, w procesie teledetekcyjnej interpretacji przestrzeni geograficznej ma szereg ograniczeń. Pierwszym z nich jest wymaganie posiadania dużego i różnorodnego zbioru danych, dzięki któremu możliwe będzie wytrenowanie modelu wysokiej jakości. Nie stanowi to wyzwania dla teledetekcji, której trzon stanowią zobrazowania różnego typu, do których dostęp w dowolnej ilości jest współcześnie praktycznie nieograniczony. W przypadku innych dyscyplin sytuacja jest bardziej skomplikowana. Dla przykładu badania z zakresu geomorfologii, które bezsprzecznie zyskałyby na stosowaniu metod i technik DL, często odbywają się na małym obszarze, w związku z niewielkim rozmiarem opracowywanych form. Zastosowanie w tym przypadku zdjęć satelitarnych czy nawet lotniczych może okazać się niewystarczające. Z pomocą mogą przyjść materiały pochodzące z kartowania obszaru przy użyciu bezzałogowych statków powietrznych (ang. *unmanned aerial vehicle*, UAV).

Innym ograniczeniem stosowania uczenia maszynowego w interpretacji przestrzeni geograficznej jest trudność, wynikająca z potrzeby zaimplementowania oraz wdrożenia rozwiązania. Uczenie maszynowe wymaga opanowania warsztatu z zakresu matematyki i informatyki, pozwalającego na swobodne modelowanie problemu z użyciem współczesnych języków programowania. Jednocześnie doświadczenie Autora podpowiada, że zaaplikowanie zaawansowanych technik uczenia maszynowego nie jest możliwe bez znajomości problematyki badawczej geografii oraz teledetekcji. Jest to doskonała sposobność do tworzenia interdyscyplinarnych zespołów badawczych składających się ze specjalistów o różnych zainteresowaniach, w tym geografów fizycznych, społeczno-ekonomicznych i geoinformatyków. Przykładami takich badań są projekty składające się na niniejszą rozprawę.

Uczenie maszynowe, a w szczególności głębokie uczenie wsparte przez uczenie reprezentacji, pozwala na podejmowanie się interesujących zadań badawczych. Wśród dostępnych możliwości warte uwagi jest nienadzorowane uczenie reprezentacji, które w teledetekcji stosowane jest obecnie w procesie sztucznego zwiększania rozdzielczości obrazu (Ledig i in., 2017), transformacji obrazu w obraz umożliwiając chociażby tworzenie sztucznych obrazów na podstawie masek segmentacyjnych (Adamiak i Nalej, 2020; Isola i in., 2018). W kontekście wspomagania interpretacji przestrzeni geograficznej interesująca jest możliwość tworzenia syntetycznego obrazu o dużej rozdzielczości i o cechach podobnych, jak wybrany

przez badacza obraz wzorcowy. Rozwiązania tego problemu Autor podjął się w publikacji nr 4. Kontynuacja badań w tym obszarze wpłynie pozytywnie na jakość i liczność dostępnych zbiorów przez ich maszynową augmentację. Jednocześnie pozwoli zajmować się procesami lub zjawiskami spotykanymi epizodycznie w przestrzeni geograficznej, jakimi są ekstremalne zjawiska pogodowe. Reprezentacja wyuczona w trakcie nienadzorowanego procesu, opartego o niewielki zbiór, może w tym przypadku zostać wykorzystana do utworzenia liczniejszego zbioru przeznaczonego do wytrenowania kolejnego modelu.

6. Wnioski

Interpretacja procesów i zjawisk zachodzących w przestrzeni geograficznej może być skutecznie wspomagana przez zastosowanie modeli uczenia maszynowego. Szczególnie atrakcyjne w tym kontekście jest głębokie uczenie, które w związku z użyciem mechanizmu uczenia reprezentacji ma szerokie zastosowanie w analizie danych pochodzących ze zobrazowań lotniczych i satelitarnych.

Metody głębokiego uczenia są powszechnie wykorzystywane w teledetekcji, zwłaszcza w analizie pokrycia terenu. Fakt ten, wraz z wieloletnim doświadczeniu Autora w komercyjnej budowie oprogramowania, pozwolił zaplanować, a następnie zrealizować szereg projektów naukowych integrujących metodyki pracy badawczej, charakterystyczne dla geografii, geoinformacji, analizy przestrzennej, widzenia komputerowego (ang. *computer vision, CV*) oraz inżynierii oprogramowania.

Potwierdzono zasadność zastosowania mechanizmu utrwalania cech, charakterystycznego dla głębokich splotowych sieci neuronowych, w kodowaniu przestrzeni geograficznej – jej elementów składowych oraz procesów i zjawisk zachodzących w jej obrębie. Istotnym stało się nie tylko opracowanie modelu, spełniającego postawione przed nim zadania, ale również zrozumienie źródła pochodzenia rezultatu i pozyskanie umiejętności wskazywania cech analizowanego obrazu, które miały największe znaczenie dla sieci neuronowej, w modelowaniu danego zagadnienia.

Rezultaty otrzymane przy pomocy metod i technik uczenia maszynowego mogą z powodzeniem stanowić wejście do klasycznych algorytmów analizy przestrzennej, w tym tych opartych na analizie skupień. Proces ten wymaga jednak przygotowania i dokładnego zaplanowania całego projektu badawczego.

Utrwalona w sieci neuronowej reprezentacja przestrzeni geograficznej nie musi powstać w procesie uczenia nadzorowanego. Istnieje szereg technik umożliwiających automatyczną ekstrakcję cech przestrzennych, z których na szczególną uwagę zasługują generatywne sieci współzawodniczące. W tym miejscu warto dodać, że automatyzacja procesu tworzenia reprezentacji nie zmniejsza udziału badacza w całym procesie, a jedynie zmienia jego obowiązki. W przypadku uczenia nadzorowanego badacz jest odpowiedzialny za przygotowanie zbioru treningowego oraz pomiar skuteczności opracowanego rozwiązania. W efekcie model uczenia maszynowego powstaje z wykorzystaniem wiedzy badacza.

W uczeniu nienadzorowanym zbiór treningowy nie posiada etykiet i rezultat powstaje przy minimalnym udziale człowieka. W tym przypadku praca badacza polega na wyjaśnieniu rezultatu otrzymanego przez model oraz zinterpretowaniu wyniku. Zdaniem Autora proces nienadzorowany jest wartościowy z punktu widzenia badań podstawowych, ponieważ wraz z wiedzą i doświadczeniem naukowca ma potencjał do generowania nowej wiedzy. Przykładem jest opracowana w ramach rozprawy metoda nienadzorowanej semantycznej segmentacji przestrzeni geograficznej z wykorzystaniem ortofotomap. Oprócz mechanizmu autonomicznego podziału przestrzeni geograficznej ze względu na pokrycie terenu, umożliwia ona syntetyzowanie próbek na podstawie reprezentacji utrwalonej w sieci, a także sprowadzenie wielowymiarowego obrazu do prostszej formy w postaci wektora, co może być z powodzeniem zastosowane w miejsce klasycznie używanej metody składowych głównych (ang. *principal component analysis*, PCA), służyć jako mechanizm kompresji zachowujący jedynie informacje o występowaniu cech przestrzennych oraz umożliwiać analizę przestrzeni geograficznej pod kątem podobieństwa tworzących ją wycinków.

Podsumowując, przeprowadzenie wnioskowania w zakresie wybranych problemów badawczych, powiązanych ze sobą przedmiotowo, przestrzennie, czasowo oraz spójnych pod względem użytych danych, pochodzących ze zobrazowań satelitarnych i lotniczych, pozwoliło zapoznać się, scharakteryzować oraz rozwinąć metody klasyfikacji oraz semantycznej segmentacji pokrycia terenu i tym samym zrealizować nadzędny cel pracy.

Autor ma nadzieję, że niniejsza praca pomoże upowszechnić metody uczenia maszynowego, a zwłaszcza głębokiego uczenia w środowisku naukowym, związanym z dyscypliną nauk o Ziemi i środowisku, a przede wszystkim w geografii, która może wiele zyskać na wprowadzeniu opracowanych metod i technik do swojego warsztatu metodycznego. Jednocześnie Autor deklaruje kontynuowanie swoich badań w celu dostarczania badaczom nowych zaawansowanych technik przetwarzania i analizowania danych geograficznych z wykorzystaniem zaawansowanych metod informatycznych.

7. Literatura

- Adamczyk, J., Będkowski, K. (2006). *Analiza obiektowa jako metoda poprawy jakości klasyfikacji*. Roczniki Geomatyki, 4(4), 37–46.
- Adamczyk, J., Będkowski, K. (2007). *Metody cyfrowe w teledetekcji*. Digital Methods in Remote Sensing (wydanie 2), Wydawnictwo SGGW.
- Adamiak, M. (2021). *Głębokie uczenie w procesie teledetekcyjnej interpretacji przestrzeni geograficznej – przegląd wybranych zagadnień*. Czasopismo Geograficzne, 92(1), 49–72. <https://doi.org/10.12657/czageo-92-03>
- Adamiak, M., Będkowski, K., Majchrowska, A. (2021). *Aerial Imagery Feature Engineering Using Bidirectional Generative Adversarial Networks: A Case Study of the Pilica River Region, Poland*. Remote Sensing, 13(2), 306. <https://doi.org/10.3390/rs13020306>
- Adamiak, M., Biczkowski, M., Leśniewska-Napierała, K., Nalej, M., Napierała, T. (2020). *Impairing Land Registry: Social, Demographic, and Economic Determinants of Forest Classification Errors*. Remote Sensing, 12(16), 2628. <https://doi.org/10.3390/rs12162628>
- Adamiak, M., Jaźdżewska, I., Nalej, M. (2021). *Analysis of Built-Up Areas of Small Polish Cities with the Use of Deep Learning and Geographically Weighted Regression*. Geosciences, 11(5), 223. <https://doi.org/10.3390/geosciences11050223>
- Adamiak, M., Nalej, M. (2020). *Generative adversarial networks in satellite image datasets augmentation*. Medium. <https://blog.softwaremill.com/generative-adversarial-networks-in-satellite-image-datasets-augmentation-b7045d2f51ab>
- Bem, P. P. de, Júnior, O. A. C., Guimarães, R., Gomes, R. (2020). *Change Detection of Deforestation in the Brazilian Amazon Using Landsat Data and Convolutional Neural Networks*. Remote Sensing. <https://doi.org/10.3390/rs12060901>
- Bengio, Y., Courville, A., Vincent, P. (2014). *Representation Learning: A Review and New Perspectives*. arXiv:1206.5538 [cs]. <http://arxiv.org/abs/1206.5538>
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer-Verlag. <https://www.springer.com/gp/book/9780387310732>
- Brock, A., Donahue, J., Simonyan, K. (2019). *Large Scale GAN Training for High Fidelity Natural Image Synthesis*. arXiv:1809.11096 [cs, stat]. <http://arxiv.org/abs/1809.11096>
- Camps-Valls, G., Svendsen, D. H., Cortés-Andrés, J., Moreno-Martínez, Á., Pérez-Suay, A., Adsuar, J., Martín, I., Piles, M., Muñoz-Marí, J., Martino, L. (2021). *Physics-Aware Machine Learning for Geosciences and Remote Sensing*. 2021 IEEE International

- Geoscience and Remote Sensing Symposium IGARSS, 2086–2089. <https://doi.org/10.1109/IGARSS47720.2021.9554521>
- Chen, L.-C., Papandreou, G., Kokkinos, I., Murphy, K., Yuille, A. L. (2017). *DeepLab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs*. arXiv:1606.00915 [cs]. <http://arxiv.org/abs/1606.00915>
- Chojnicki, Z. (1999). *Pojęcie odległości w analizie przestrzeni społeczno-ekonomicznej*. W *Podstawy metodologiczne i teoretyczne geografii*. Bogucki Wydawnictwo Naukowe, 167–174.
- Chojnicki, Z. (2010). *Model empiryczno-naukowy geografii*. W *Koncepcje i studia metodologiczne i teoretyczne w geografii*. Bogucki Wydawnictwo Naukowe, 81–103.
- DeepLearning.AI. (2021). Coursera. <https://www.coursera.org/specializations/deep-learning>
- Donahue, J., Krähenbühl, P., Darrell, T. (2017). *Adversarial Feature Learning*. arXiv:1605.09782 [cs, stat]. <http://arxiv.org/abs/1605.09782>
- Donahue, J., Simonyan, K. (2019). *Large Scale Adversarial Representation Learning*. arXiv:1907.02544 [cs, stat]. <http://arxiv.org/abs/1907.02544>
- Dong, J., Yin, R., Sun, X., Li, Q., Yang, Y., Qin, X. (2019). *Inpainting of Remote Sensing SST Images With Deep Convolutional Generative Adversarial Network*. IEEE Geoscience and Remote Sensing Letters, 16(2), 173–177. <https://doi.org/10.1109/LGRS.2018.2870880>
- Dziewoński, K. (1967). *Teoria region ekonomicznego*. Przegląd Geograficzny, 39(1), 33–50.
- EO Browser*. (2021). <https://www.sentinel-hub.com/explore/eobrowser/>
- Facebook. (2021). *API documentation*. PyTorch. <https://pytorch.org/docs/stable/index.html>
- Geoportal. (2021). <http://geoportal.gov.pl>
- Goodfellow, I. J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., Bengio, Y. (2014). *Generative Adversarial Networks*. arXiv:1406.2661 [cs, stat]. <http://arxiv.org/abs/1406.2661>
- Google. (2021a). *API documentation, TensorFlow Core v2.7.0*. Tensorflow. https://www.tensorflow.org/api_docs
- Google. (2021b). *Tf.keras.layers.Layer, TensorFlow Core v2.7.0*. https://www.tensorflow.org/api_docs/python/tf/keras/layers/Layer
- Grabska, E., Frantz, D., Ostapowicz, K. (2020). *Evaluation of machine learning algorithms for forest stand species mapping using Sentinel-2 imagery and environmental data in the Polish Carpathians*. Remote Sensing of Environment, 251, 112103. <https://doi.org/10.1016/j.rse.2020.112103>

- Gron, A. (2019). *Hands-On Machine Learning with Scikit-Learn and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems* (wydanie 2). O'Reilly Media, Inc.
- Heusel, M., Ramsauer, H., Unterthiner, T., Nessler, B., Hochreiter, S. (2018). *GANs Trained by a Two Time-Scale Update Rule Converge to a Local Nash Equilibrium*. arXiv:1706.08500 [cs, stat]. <http://arxiv.org/abs/1706.08500>
- Horé, A., Ziou, D. (2010). *Image Quality Metrics: PSNR vs. SSIM*. 2010 20th International Conference on Pattern Recognition, 2366–2369. <https://doi.org/10.1109/ICPR.2010.579>
- ISO. (2021). TC 211 Multi-Lingual Glossary of Terms MLGT. <https://isotc211.geolexica.org/concepts/202/>
- Isola, P., Zhu, J.-Y., Zhou, T., Efros, A. A. (2018). *Image-to-Image Translation with Conditional Adversarial Networks*. arXiv:1611.07004 [cs]. <http://arxiv.org/abs/1611.07004>
- Jaisakthi, S. M., Mirunalini, P., Aravindan, C. (2019). *Coral Reef Annotation and Localization using Faster R-CNN*. CLEF.
- Jarocinska, A., Zagajewski, B. (2008). *Korelacje naziemnych i lotniczych teledetekcyjnych wskaźników roślinności dla zlewni Bystrzanki*. Teledetekcja Środowiska, 40, 100–124.
- Jaźdżewska, I. (2021). Od nauk geograficznych w kierunku nauki o geoinformacji. Wydawnictwo Uniwersytetu Łódzkiego. <https://doi.org/10.18778/8220-599-2>
- Krówczyńska, M., Raczkó, E., Staniszewska, i Wilk, E. (2020). *Asbestos–Cement Roofing Identification Using Remote Sensing and Convolutional Neural Networks (CNNs)*. Remote Sensing, 12, 408. <https://doi.org/10.3390/rs12030408>
- Krysiak, S., Adamczyk, J., Majchrowska, A., Papińska, E., Sieradzki, J. (2016). *Ekologiczna rola odlogów stref otaczających parki krajobrazowe w województwie łódzkim*. Wydawnictwo Uniwersytetu Łódzkiego.
- Krysiak, S., Papińska, E., Majchrowska, A., Adamiak, M., Koziarkiewicz, M. (2020). Detecting Land Abandonment in Łódź Voivodeship Using Convolutional Neural Networks. Land, 9(3), 82. <https://doi.org/10.3390/land9030082>
- Ledig, C., Theis, L., Huszar, F., Caballero, J., Cunningham, A., Acosta, A., Aitken, A., Tejani, A., Totz, J., Wang, Z., Shi, W. (2017). *Photo-Realistic Single Image Super-Resolution Using a Generative Adversarial Network*. arXiv:1609.04802 [cs, stat]. <http://arxiv.org/abs/1609.04802>
- Lewiński, S. (2007). *Obiektowa klasyfikacja zdjęć satelitarnych jako metoda pozyskiwania informacji o pokryciu i użytkowaniu ziemi*. W Biblioteka Instytutu Geodezji i Kartografii w Warszawie. Instytut Geodezji i Kartografii
- <http://bc.igik.edu.pl/dlibra/publication/27/edition/21>

- Lin, T.-Y., Dollár, P., Girshick, R., He, K., Hariharan, B., Belongie, S. (2017). Feature Pyramid Networks for Object Detection. arXiv:1612.03144 [cs]. <http://arxiv.org/abs/1612.03144>
- Lisowski, A. (2014). *Typy przestrzeni a geografia*. Prace Komisji Krajobrazu Kulturowego, 24. <http://yadda.icm.edu.pl/yadda/element/bwmeta1.element.baztech-1a3015c2-e179-4c18-9e51-a0567d18a035>
- Liszewski, S. (1995). *Przestrzeń turystyczna*. Turyzm, 5(2), 87–103.
- Lundberg, S. M., Lee, S.-I. (2017). *A Unified Approach to Interpreting Model Predictions*. *Advances in Neural Information Processing Systems*, 30. <https://proceedings.neurips.cc/paper/2017/hash/8a20a8621978632d76c43dfd28b67767-Abstract.html>
- Ma, W., Pan, Z., Guo, J., Lei, B. (2018). *Super-Resolution of Remote Sensing Images Based on Transferred Generative Adversarial Network*. IGARSS 2018 - 2018 IEEE International Geoscience and Remote Sensing Symposium, 1148–1151. <https://doi.org/10.1109/IGARSS.2018.8517442>
- Malinowski, R., Lewiński, S., Rybicki, M., Gromny, E., Jenerowicz, M., Krupiński, M., Nowakowski, A., Wojtkowski, C., Krupiński, M., Krätzschmar, E., Schauer, P. (2020). *Automated Production of a Land Cover/Use Map of Europe Based on Sentinel-2 Imagery*. Remote Sensing, 12(21), 3523. <https://doi.org/10.3390/rs12213523>
- Mitchell, T. M. (1997). *Machine Learning*. McGraw-Hill.
- Nalej, M. (2018). *Zmiany pokrycia terenu w zachodniej części miasta Zduńska Wola w latach 1933-2015*. Teledetekcja Środowiska, T. 58. <http://yadda.icm.edu.pl/yadda/element/bwmeta1.element.baztech-d281cd6f-eacf-45cc-8993-4c21f26db17c>
- Ney, B. (2007). *Informacja przestrzenna w naukach o Ziemi*. Roczniki Geomatyki, T. 5, z. 6, 119–124.
- NVIDIA. (2022). NVIDIA TITAN RTX. NVIDIA. <https://www.nvidia.com/en-us/deep-learning-ai/products/titan-rtx/>
- Open Access Hub. (2021). <https://scihub.copernicus.eu/>
- OpenStreetMap. (2021). OpenStreetMap. <https://www.openstreetmap.org/about>
- Papers with Code. (2021). <https://paperswithcode.com/area/computer-vision>
- Python.org. (2021). Python.org. Python.Org. <https://www.python.org/>
- Reichstein, M., Camps-Valls, G., Stevens, B., Jung, M., Denzler, J., Carvalhais, N., Prabhat. (2019). *Deep learning and process understanding for data-driven Earth system science*. Nature. <https://doi.org/10.1038/s41586-019-0912-1>

- Ronneberger, O., Fischer, P., Brox, T. (2015). *U-Net: Convolutional Networks for Biomedical Image Segmentation*. arXiv:1505.04597 [cs]. <http://arxiv.org/abs/1505.04597>
- Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., Batra, D. (2017). *Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization*. 2017 IEEE International Conference on Computer Vision (ICCV), 618–626. <https://doi.org/10.1109/ICCV.2017.74>
- Szaleniec, M., Tadeusiewicz, R. (2015). *Lexicon on Neural Networks*.
- Wang, Z., Bovik, A. C., Sheikh, H. R., Simoncelli, E. P. (2004). *Image quality assessment: From error visibility to structural similarity*. IEEE Transactions on Image Processing, 13(4), 600–612. <https://doi.org/10.1109/TIP.2003.819861>
- Węzyk, P., De Kok, R., Kozioł, K. (2006). *Application of the object-based image analysis of VHR satellite images in land-use classification*. Roczniki Geomatyki - Annals of Geomatics, IV(3), 227–238.
- Włodarczyk, B. (2014). *Przestrzeń w turystyce, turystyka w przestrzeni—O potrzebie definicji, delimitacji i klasyfikacji*. Turyzm, 24(z. 1), 25–35. <https://doi.org/10.2478/tour-2014-0003>
- Zagajewski, B., Kluczek, M., Raczkowski, E., Njegovec, A., Anca, D., Kycko, M. (2021). *Comparison of Random Forest, Support Vector Machines, and Neural Networks for Post-Disaster Forest Species Mapping of the Krkonoše/Karkonosze Transboundary Biosphere Reserve*. Remote Sensing, 13, 2581. <https://doi.org/10.3390/rs13132581>
- Zhang, L., Zhang, L., Mou, X., Zhang, D. (2011). *FSIM: A feature similarity index for image quality assessment*. IEEE Transactions on Image Processing: A Publication of the IEEE Signal Processing Society, 20(8), 2378–2386. <https://doi.org/10.1109/TIP.2011.2109730>
- Zhao, H., Shi, J., Qi, X., Wang, X., Jia, J. (2017). *Pyramid Scene Parsing Network*. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 6230–6239. <https://doi.org/10.1109/CVPR.2017.660>
- Zhou, S., Gordon, M. L., Krishna, R., Narcomey, A., Fei-Fei, L., Bernstein, M. S. (2019). *HYPE: A Benchmark for Human Eye Perceptual Evaluation of Generative Models*. arXiv:1904.01121 [cs]. <http://arxiv.org/abs/1904.01121>
- Żytkow, J. (1993). *Automation of Scientific Discovery: Its Present and Future*. Filozofia Nauki, 1(4), 37–54.

8. Kopie publikacji tworzących rozprawę doktorską

Publikacja nr 1:

Krysiak, S., Papińska, E., Majchrowska, A., Adamiak, M., Koziarkiewicz, M. (2020). *Detecting Land Abandonment in Łódź Voivodeship Using Convolutional Neural Networks*, Land, 9(3), 82. <https://doi.org/10.3390/land9030082>

MEiN: 70, IF'20: 3,398, CiteScore'20: 3,0.

Article

Detecting Land Abandonment in Łódź Voivodeship Using Convolutional Neural Networks

Stanisław Krysiak ^{1,†}, Elżbieta Papińska ^{1,†}, Anna Majchrowska ^{1,†}, Maciej Adamiak ^{2,*} and Mikołaj Koziarkiewicz ^{2,†}

¹ Department of Physical Geography, Faculty of Geographical Sciences, University of Łódź, 90-139 Łódź, Poland; stanislaw.krysiak@geo.uni.lodz.pl (S.K.); elzbieta.papinska@geo.uni.lodz.pl (E.P.); anna.majchrowska@geo.uni.lodz.pl (A.M.)

² SoftwareMill, 02-791 Warsaw, Poland; mikolaj.koziarkiewicz@softwaremill.com

* Correspondence: maciej.adamiak@softwaremill.com; Tel.: +48-785-624-665

† These authors contributed equally to this work.

Received: 6 February 2020; Accepted: 11 March 2020; Published: 13 March 2020



Abstract: The wide availability of multispectral satellite imagery through projects such as Landsat and Sentinel, combined with the introduction of deep learning in general and Convolutional Neural Networks (CNNs) in particular, has allowed for the rapid and effective analysis of multiple classes of problems pertaining to land coverage. Taking advantage of the two phenomena, we propose a machine learning model for the classification of land abandonment. We designed a Convolutional Neural Network architecture that outputs a classification probability for the presence of land abandonment in a given 15–25 ha grid element by using multispectral imaging data obtained through Sentinel Hub. For both the training and validation of the model, we used imagery of the Łódź Voivodeship in central Poland. The main source of truth was a 2009 orthophoto study available from the WMS (Web Map Service) of the Geoportal site. The model achieved 0.855 auc (area under curve), 0.47 loss, and 0.78 accuracy for the test dataset. Using the classification results and the Getis–Ord Gi* statistic, we prepared a map of cold- and hotspots with individual areas that exceed 50 km². This thresholded heatmap allowed for an analysis of contributing factors for both low and intense land abandonment, demonstrating that common trends are identifiable through the interpretation of the classification results of the chosen model. We additionally performed a comparative field study on two selected cold- and hotspots. The study, along with the high-accuracy results of the model’s validation, confirms that CNN-type models are an effective tool for the automatic detection of land abandonment.

Keywords: land cover; GIS; machine learning; convolutional neural networks; Łódź Voivodeship

1. Introduction

The rural landscape of the Łódź Voivodeship (Figure 1), as everywhere else in Poland, underwent massive structural and functional transformations because of the political upheaval of 1989–2000, followed by the country’s integration with the European Union [1,2]. However, this restructuring process was beset with contradictory phenomena. On the one hand, high-quality land was subjected to more intensive agriculture, resulting in more modern farming methods and the expansion of cultivated areas. On the other hand, mid- and poor-quality land experienced the emergence of substantial areas subject to agricultural abandonment [3]. Statistics Poland (GUS) reported an increase from 1.3 to 1.8 mln ha of fallow and abandoned lands in the year 1995 alone [4], further expanding, according to the official Agricultural Census of 2002, to 2.3 mln ha, or 17.6% of total arable land in Poland [5]. Reasons for the reduction in agricultural activity include the progressive urbanization of rural areas (most prominently in suburban zones), declining returns on agricultural production (primarily affecting

individual agricultural holdings operating in poor-quality areas), and the decline of cattle and sheep husbandry, leading to agricultural abandonment of meadows and pastures [6,7].



Figure 1. Research area in the geographic context of Poland.

With the availability of direct agricultural subsidies under the so-called Good Agricultural and Environmental Conditions (GAEC), many farmers decided to resume their activities, resulting in a marked decrease in abandoned lands. Currently, however, it is impossible to determine the scale of this phenomenon because of a lack of relevant statistical data. Specifically, in the Agricultural Census of 2010, fallow lands were folded into the category of “other farmlands”, while the Agricultural Census of 2010 report on Land Utilization [8] did not include the term “abandoned land”. Furthermore, by a 2001-03-29 ordinance of the Minister of Regional Development, neither abandoned nor fallow lands constitute a unique category; instead, they are incorporated into the category of “arable land” [9]. In consequence, it has become impossible to estimate the amount of abandoned or fallow lands at any level of administrative subdivision [10,11].

A limited number of publications do include up-to-date maps documenting land abandonment. These necessitate field survey based on aerial photography. The amount of required effort and time for utilizing the aforementioned methods has limited its utility to smaller surfaces, such as catchment areas [12,13], test research areas [3,14–16], and landscape parks [17]. Such land abandonment intensity identification processes were also utilized on a single area of several thousand km² on the basis of orthophoto analysis, supplemented by on-the-ground verification [18–22]. In recent decades, this approach to identifying land abandonment, in Poland and worldwide, has been increasingly augmented by the usage of satellite spectral imaging [23] and LIDAR data [24–26].

Abandoned fields, meadows, and pastures are subject to spontaneous plant regeneration and succession. According to J.B. Faliński [27], vegetation that grows in such a way can be described as “emancipated vegetation” or “liberated vegetation”, as in “freed” from the long-term influence of humankind. In other words, abandoned lands are areas regaining their vegetation coverage as a result of autonomous ecological processes. Frequently, abandoned lands become progressively floristically enriched with the passage of time, not infrequently including rare or endangered plant species [28]. From the conservationist point of view, postagricultural, spontaneously overgrowing areas factor in an increase in biological diversity,

structural heterogeneity, the formation of ecological corridors, and the enrichment of sustenance opportunities for diverse animal species [17]. In fact, in the environmental conditions of central Poland, some areas of land abandonment visually resemble a forest stand. According to botanical observations, spontaneously appearing, newly forested areas are characterized by age and species diversity, correlated to their local habitat and soil fertility [29,30]. Thus, emergent new plant communities provide a positive environmental influence and are a costless alternative to aorestation [10,19].

Regions of land abandonment, typically undergoing varying degrees of plant succession, intermingled with the open spaces of fields, meadows, and pastures, create vistas of considerable visual allure [31]. For this reason, as well as a societal interest in rural expanses as recreational spaces, these areas have found themselves under both sparse and dense “vacation settlements”. In addition, dubbed “tourist colonization”, the process was especially intensified along river valleys and in the vicinity of the shoreline of flood control reservoirs [32,33]. This was helped along by the progressive decline in crop- and livestock-related agricultural usage [34,35]. As a consequence, abandoned lands are often accompanied by seasonal homes and allotments [31].

The principal goal of our study is to evaluate the potential of deep learning, specifically Convolutional Neural Networks (CNNs), to accurately classify land abandonment and provide new insights into the origins of the process, especially in the context of the Łódź Voivodeship. The decision to utilize CNNs over traditional methods, such as Support Vector Machines (SVM) or fully connected artificial neural networks, is the former’s ability to encode complex image features. This capability is due to the use of convolutional filters that, in the process of training, gain the ability to detect the presence of specific patterns. Furthermore, the convolution operation, which is the backbone of CNNs, offers a performance gain when training the networks on Graphical Processing Units (GPUs). This, in consequence, offers the potential for training the model on larger datasets and feasibly experimenting with various hyperparameter values and network architectures. The application of CNNs to solve computer vision problems, particularly classification, has proven to be a valid and effective approach and become an industry standard. Because of their effectiveness in recognizing complex features and their usefulness when processing high-dimensional data, CNNs have also been successfully deployed in land coverage classification with satellite and aerial imagery [36–40]. We formulate the following hypothesis: an appropriately prepared Convolutional Neural Network (CNN) is able to detect land abandonment within the Łódź Voivodeship to a recognizable degree when compared with sources of truth, such as on-the-ground studies from various time periods.

2. Materials and Methods

2.1. Background

Deep learning in general and Convolutional Neural Network (CNN) architecture in particular have proven revolutionary in essentially all fields that can be assisted by computer vision, and the subfield of land use classification proves to be no different. CNN-based approaches do possess a major disadvantage in that they require a substantial amount of data for the training process. Fortunately, as noted in [36], considerable quantities of image data have become available in recent years thanks to deployments of satellites such as Landsat 8 and Sentinel-2 A/B. This temporal correlation becomes quite apparent when studying the relevant literature, as the bulk of published research concerning the usage of CNNs for land cover classification dates from 2017 or later, i.e., following the deployment of Landsat 8 [38] and Sentinel-2A [39]. Earlier works, however, exist in a limited number, and they have simply utilized other datasets, such as KSC/Pavia [40] and UC Merced [41].

In concert with the availability of data, the architecture has developed, as well. Earlier approaches favored a combination of established methods, such as Principal Component Analysis (PCA) and logistic regression [40] or Deep Convolutional Neural Network and Transfer Learning (DTCLE) [42]. Subsequent developments have favored the use of pure CNNs, with methods such as Random Forests (RF) and/or Support Vector Machines (SVM) only taken into account as baselines [36,43,44].

The majority of neural networks developed for the tasks of land classification appear to use a custom neuronal layer architecture. Very few exceptions exist, such as one solution based on AlexNet [45]. This focus on bespoke architectures can be explained by established network layer schemes that have been developed to handle generic object recognition tasks, such as various ImageNet editions [46,47]. Apart from the variability due to the number of convolutional layers, types of pooling, etc., three other network architectural trends can be distinguished.

The first is the split and/or filtering of spectral bands for the input vectors. This can range from over 180 [43] to 6 [44]. Generally, the preference seems to be to take both visible and infrared bands into account. This may be the result of data availability and the need to ensure interoperability between different data sources. A reduction in time and cost overheads is, in turn, a possible factor contributing to the selection of a limited set of bands with comparatively diverse characteristics.

The second categorization is closely related to the former, namely, the dimensionality of the neural networks. Most networks in the existing literature are either 1-D (e.g., [43]), where the focus is on the interaction of the spectral bands for a specific pixel, or 2-D (e.g., [48]), where the concentration is on the interplay between pixel values. Note that the “dimensionality” here pertains to the number of dimensions of a specific convolution kernel and not that of the input, which is 1 higher for a given value; i.e., a 2-D CNN receives a 3-D input that consists of $k \cdot k \cdot n$ sets of values, where k is the kernel size and n is the number of bands. One comparison of dimensionality vs. performance [36] determined that both approaches have comparable accuracies, with the 2-D CNN providing a slightly increased accuracy for the specific test dataset used.

The third distinction also deals with dimensionality but along the temporal axis, specifically to distinguish data that is time-invariant versus time-variable. Of special note here is the use of a Long Short-Term Memory (LSTM) network in [44]. LSTM networks have a deep learning architecture in which the antecedent output influences subsequent input, both over short and long intervals, in order to capture features variously localized in a given linear dimension, such as time (LSTMs also find use in natural language analysis). In particular, in [44], it was found that LSTMs can offer accuracy improvements over at least some variants of CNNs. On the other hand, it has been demonstrated that even a CNN can benefit from time-variable data [43].

An important portion of any machine learning experiment is data preprocessing and preparation. Deep learning networks allow for some simplifications in that regard, as they automatically handle several steps necessary in “classic” machine learning methods, such as feature extraction. However, some problems are unavoidable, even with this type of intrinsic automation. In the area of land cover classification, special relevance is placed on compensating for missing data, resulting mostly from cloud cover but also from factors such as intermittency of satellite coverage. Apart from situations in which a cloud mask is provided [36], methods range from applying a cleanup with Self-Organizing Kohonen Masks (SOM) [36], through using separate CNNs [49], to simply utilizing images of the same area, captured on multiple days, as supplementary input [43].

Finally, an aspect of the existing literature that is extremely relevant to our own research is the specifics of how land cover classification categories can be selected and delineated. In general, every deep-learning-based approach encountered was trained for multiple classes, ranging from 11 [36] to even 21 [41]. However, invariably, most of these classes were oriented toward crop types, and no classification corresponding to our definition of land abandonment could be found. Interestingly, multiple articles identified problems with noncrop classes, such as meadows, uncultivated areas, and fallow lands used for active farming [44,50,51]. In particular, the approach in [44] netted a precision of around 0.46 for LSTM and 0.25 for CNN for the fallow class, compared with ones exceeding 0.85+ for other classes. This demonstrates the existence of a niche for neural network models specializing in the classification of areas not under active agricultural cultivation.

2.2. Data and Model Preparation

As is standard with deep learning image classification, we divided the research area into grids. The fundamental grid element comprises a rectangle of variable dimensions, limited by the following constraints: a maximum area of 25 ha and a maximum edge length of 500 m. Grid elements are segmented by superimposing an EPSG:4326 square grid and defining the origin at the northwestern corner of the rectangle delineating the given research area. Subsequently, the grid is adjusted to conform to the source classification data for the chosen machine learning model, as well as to the collection and processing procedures that generate the input vector used for the learning and prediction process. These adjustments, in turn, effect the aforementioned deviations of edge length and area. The complete model training process is depicted in Figure 2.

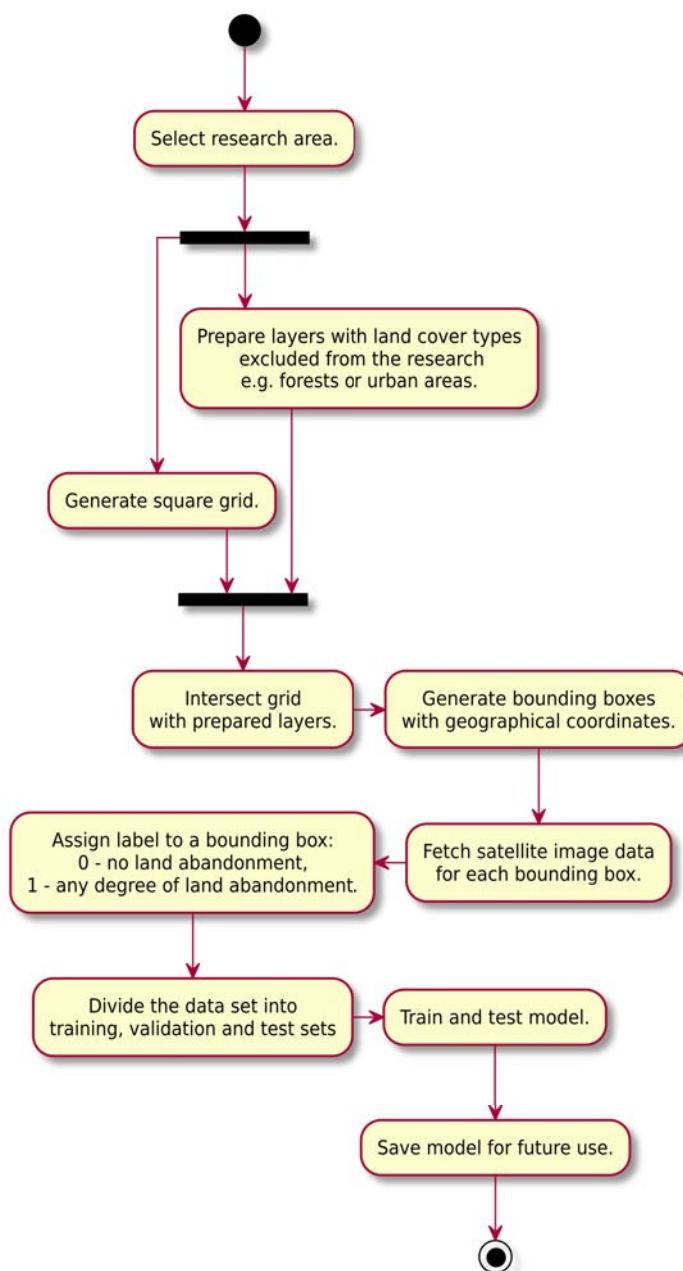


Figure 2. Model training flowchart.

The research proper was initialized by preparing a classification dataset, which is necessary when defining training, test, and validation data for the statistical learning system. The authors based their work on prior research efforts during “The ecological role of abandoned agricultural lands in buffer zones around landscape parks in the Łódź Voivodeship” project, financed by the Polish National Science Centre (1760/B/P01/2011/40).

As part of a preliminary study, the research team analyzed the buffer zones of the relevant landscape parks to categorize them into a 5-point scale of land abandonment intensity. In 25% intervals, the scale progresses from 0% (1) to 100% (5) of abandoned land that covers the given area. The classification process was based on a visual evaluation and interpretation of orthophotos dating from 2009, available through the WMS (Web Map Service) of the Geoportal site [52]. The resultant initial dataset contains 33,692 grid elements encompassing 8423 km², 46.2% of the voivodeship’s total area.

In practice, however, the research coverage was more limited, as a portion of the grid elements was located within the 10 km landscape-park buffer zones and/or intersected features, such as forests and inland waters. These factors limited the effective classification area of the relevant grid elements and resulted in the conversions of these areas from portions of a square grid to more complex and occasionally concave polygons. A related consequence is the degeneration of some grid elements, even to the point of reclassification as limited-area artifacts. The authors decided to overcome the outlined issues by, firstly, filtering areas to only include those in the range of 15–25 ha and, secondly, transforming complex polygon borders into their minimal bounding boxes (Figure 3).

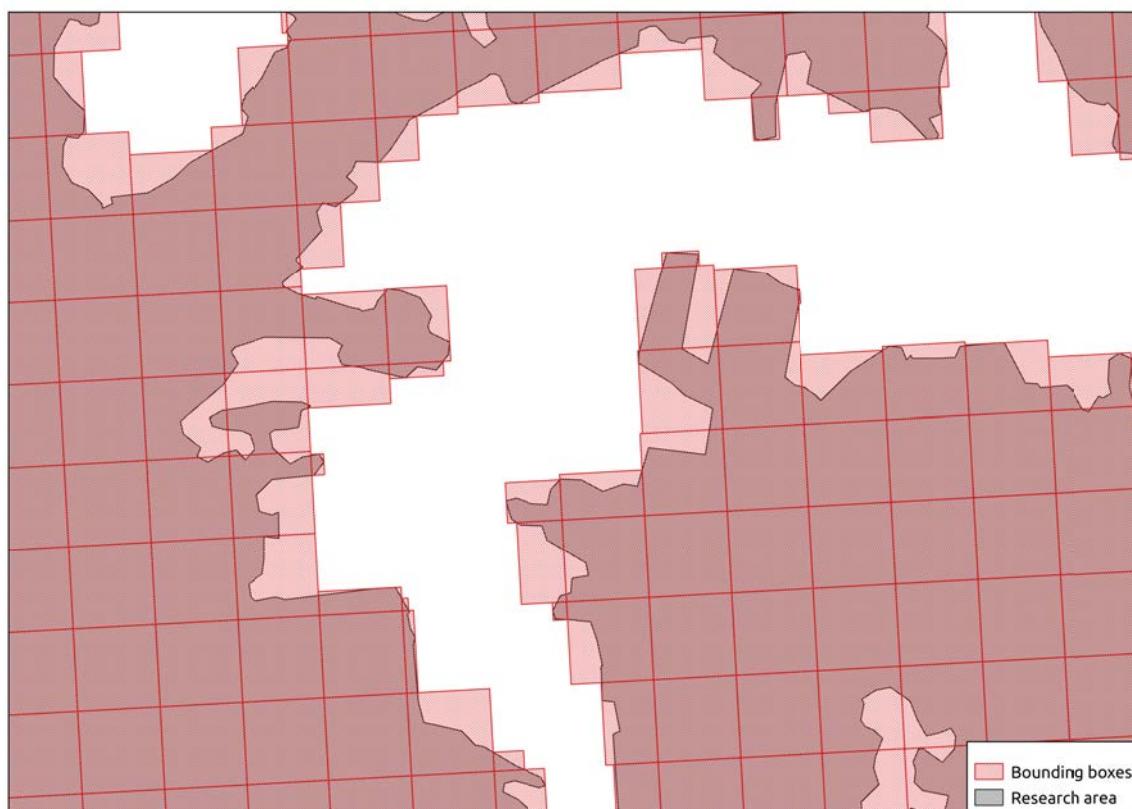


Figure 3. Sample portion of a research area. Bounding boxes are superimposed over their respective grid elements.

Using QGIS 3.8.3, every thus transformed research area had its bounding shape coordinates normalized to the geographic latitude and longitude. Simultaneously, the class label was reduced to a binary space: 0 denotes no land abandonment (the null class) and 1 denotes any degree of land abandonment in the given area. The final classification dataset encompasses 13,328 rectangles of

3073.05 km² in total, accounting for 16.87% of the total Voivodeship area. An average grid element measures 23 ha, with a standard deviation of 2.9 ha. The mode is 25 ha (half of all grid elements).

The classification dataset was enriched by imaging data from the Sentinel-2 satellite project by assigning a corresponding multiband TIFF file to each of the 13,328 grid elements (examples in Figures 4 and 5). Data ingestion was accomplished via the Sentinel Hub database [53] and the sentinel-py library [54]. The referenced image set encompasses satellite imagery from 2015 until 2019, with cloud cover per element lower than 5%. Each image includes the following emission channels: near-infrared, red, green, and blue (B08, B04, B03, B02). A 10 m by 10 m square corresponds to a single pixel. Boundary areas and areas with less than 90% of themselves within the scanning zone were rejected. Nearest resampling was used to upsample every grid element to 50 px by 50 px with the help of the rasterio library. In the end, 445,671 files were ingested into a numpy array labeled with the corresponding class. The data were subsequently split into training (361,337 units), test (44,599 units), and validation (39,735) sets while ensuring that all three were distinct w.r.t. subarea coverage.

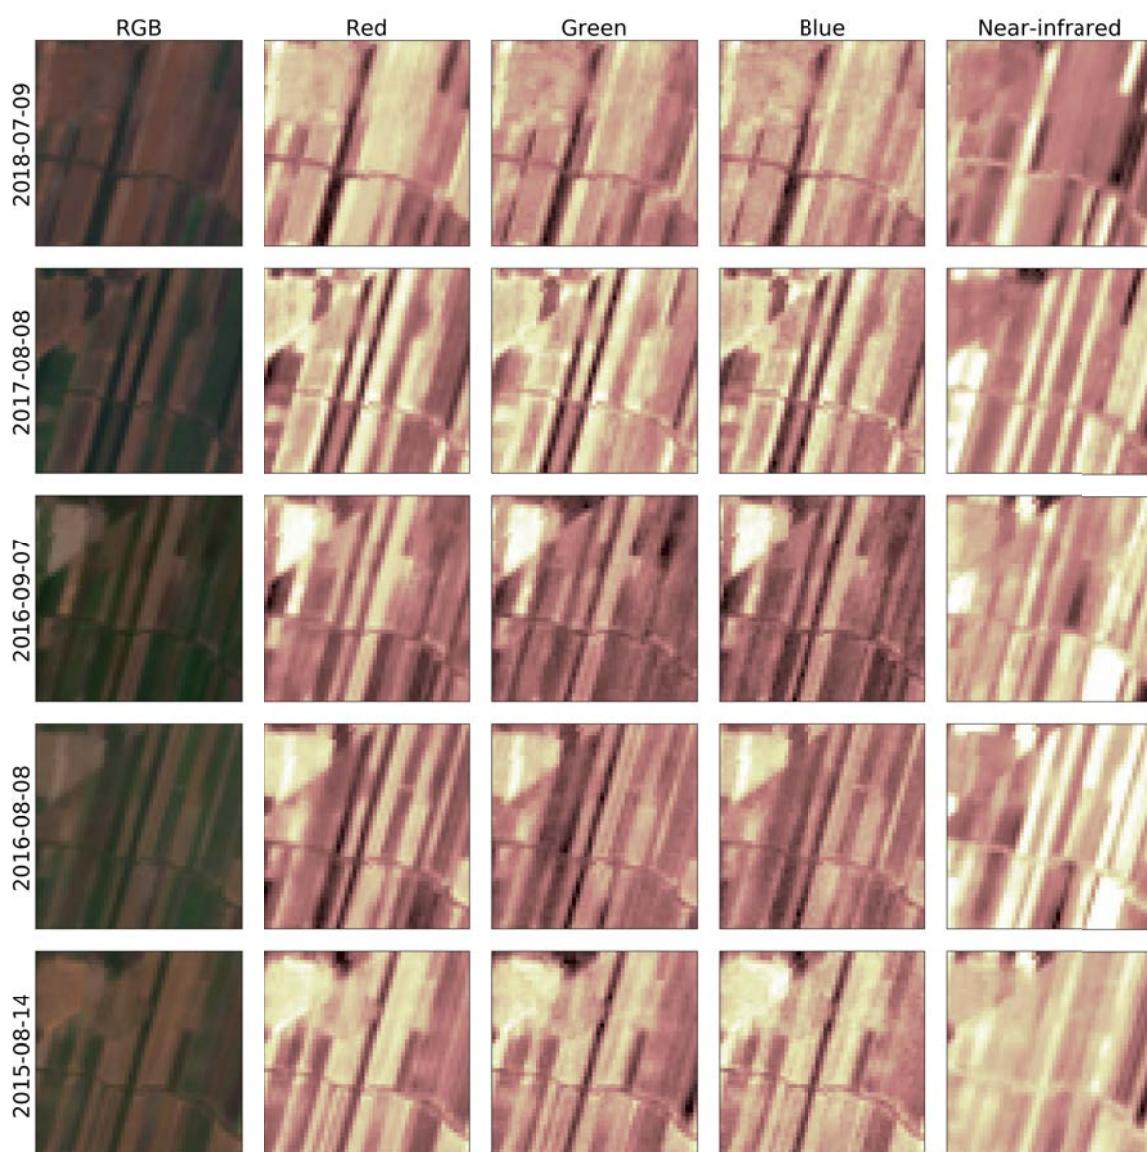


Figure 4. Time series of a single grid element classified as null-grade abandoned land. Original data class 0. The data sample is presented in RGB and near-infrared channels.

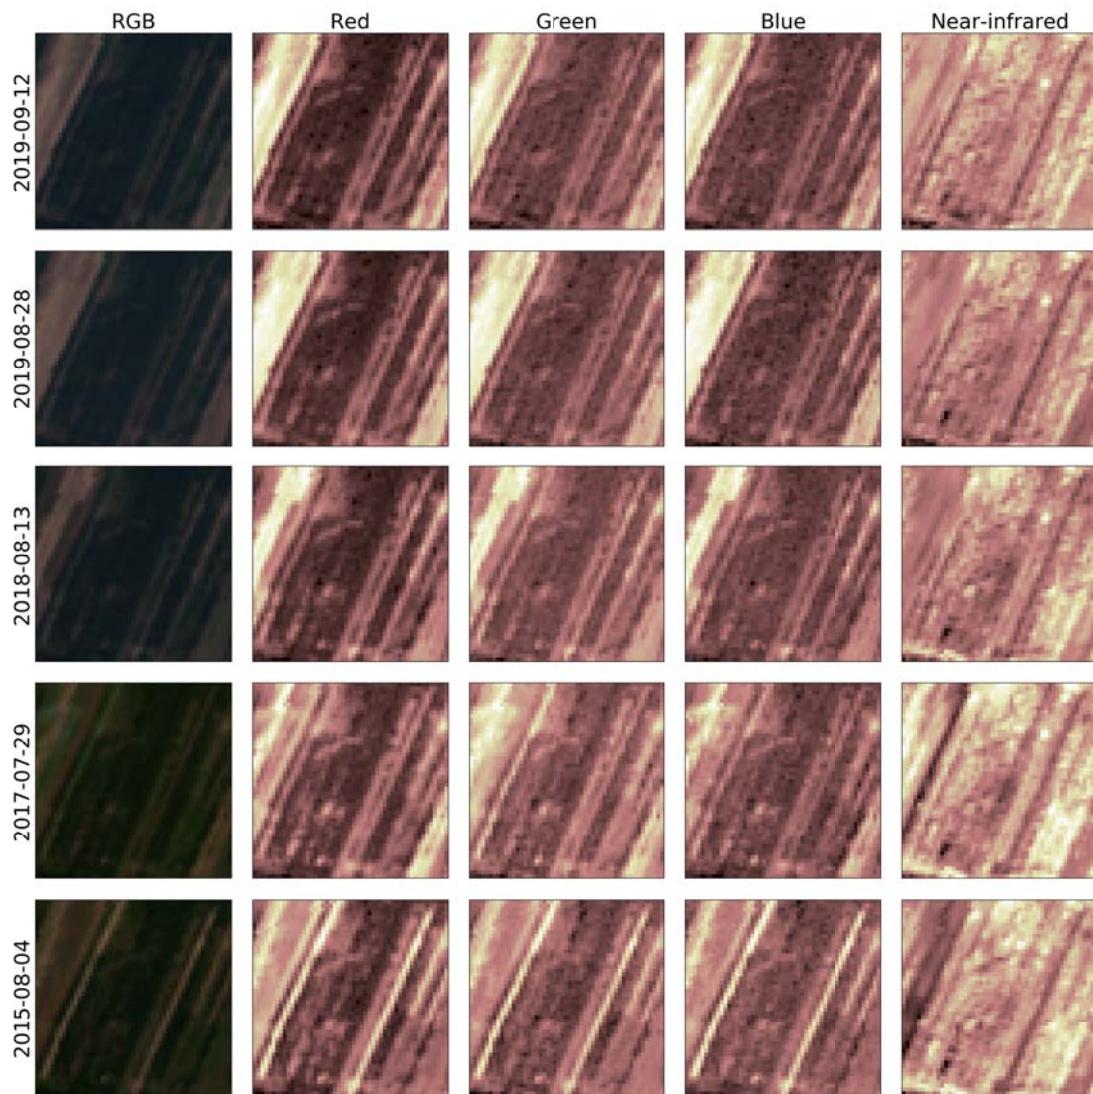


Figure 5. Time series of a single grid element classified as abandoned land. Original data class 4. The data sample is presented in RGB and near-infrared channels.

The chosen land abandonment binary classifier architecture is a convolutional neural network (CNN). The model was implemented using the Keras library, backed by TensorFlow. As is typical for a CNN, the base architectural unit is a sequence of convolutional, batch normalization, activation, pooling, and dropout layers with progressively decreasing throughput dimensionality (Figure 6). Hyperparameter tuning for the outlined layers was performed automatically via a grid search. Because of the class imbalance of abandoned lands compared with the null class, the output data were assigned weights according to the following formula:

$$\frac{n_{samples}}{n_{classes} \cdot \text{bincount}_{classes}}$$

where $n_{samples}$ is the number of samples, $n_{classes}$ is the number of classes, and $\text{bincount}_{classes}$ is a vector containing the occurrences of each class. The result was 0.852 for class 0 and 1.21 for class 1. The trained model attained 0.855 auc (area under curve), 0.47 loss, and 0.78 accuracy under testing. The confusion matrix Table 1 results indicate that the model achieved 0.659 precision and 0.777 recall, and therefore, its F_1 -score was 0.713. The model representation was subsequently persisted in an h5 file for the purpose of later prediction.

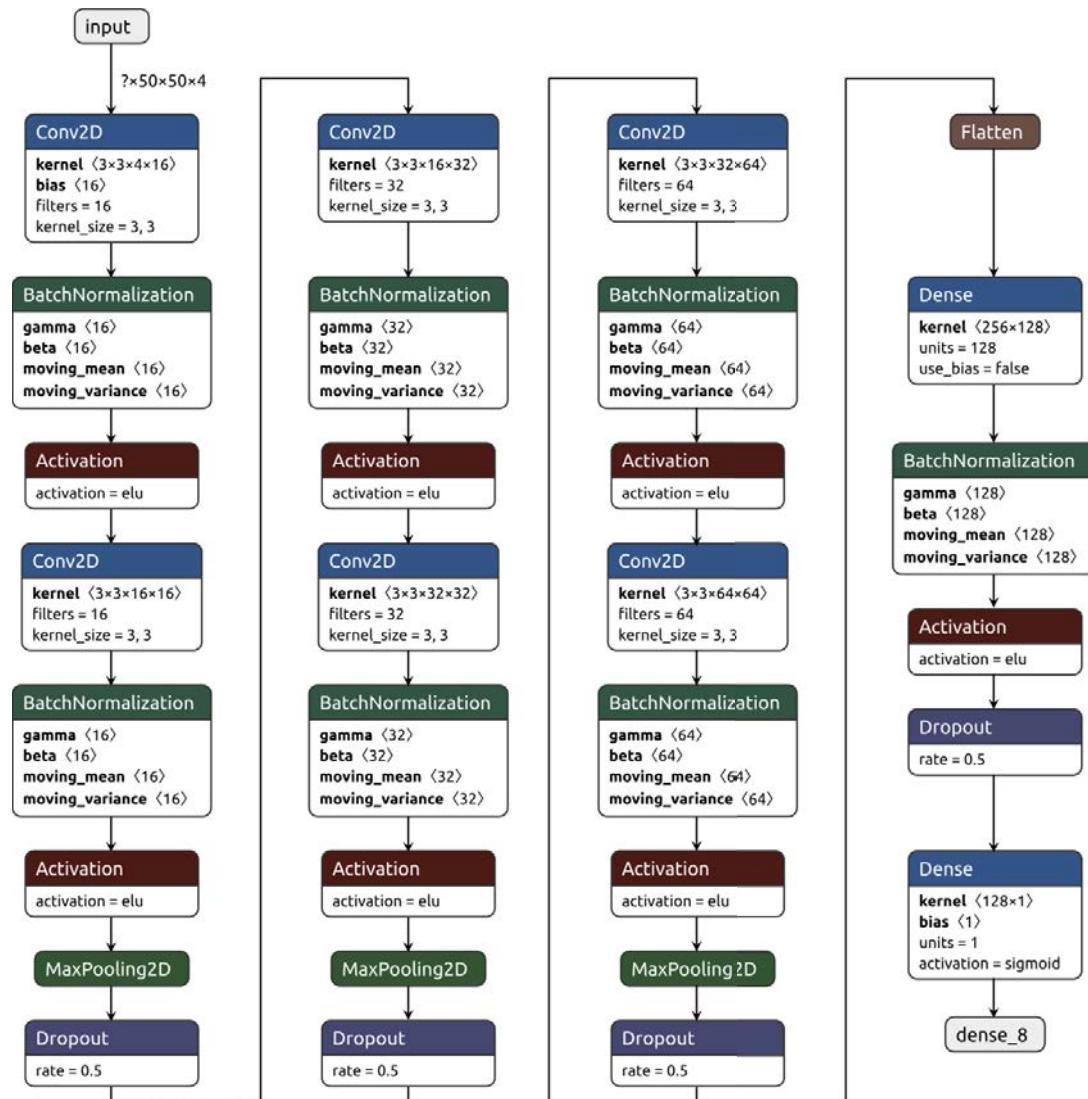


Figure 6. Convolutional network architecture for land abandonment classification.

Table 1. The confusion matrix under the test set.

Prediction/Classification	Nonabandoned	Abandoned
nonabandoned	22,556	3496
abandoned	6328	12,219

The prediction data were collected using Sentinel Hub data from August of 2018, with a 1:1 correspondence between imagery and data (i.e., a single photograph was selected for a given element). Image identifiers were collected in the form of a CSV file and can be found in the manuscript Supplementary data. Any discrepancies were corrected via resampling. The preprocessing of prediction data was conducted in an identical way to that performed during the training process. To be exact, the entirety of the Łódź Voivodeship was overlaid with a square grid. Image capture was conducted by maximizing the coverage area, i.e., even grid elements that were only partially within the voivodeship were taken into account. The final classification input dataset comprised 69,945 grid elements with a total area of 17,486.25 km², enclosing 96% of the voivodeship. Every element was classified through the generated model using a sigmoid activation function and, as mentioned previously, nominalization to land abandonment/no land abandonment according to the 0.5 activation threshold.

During fieldwork validation, our results were confronted with on-the-ground August 2018 surveys, covering 20 research areas of 16 km^2 each. Result maps were prepared using the QGIS suite, and auxiliary graphs and diagrams were generated with the help of matplotlib and seaborn Python libraries. Subsequently, a surface analysis of value distribution vis-à-vis per-element activation function values was conducted. The Getis–Ord Gi^* was used, which is a cluster detection technique distinguishing hot- and coldspots with respect to the activation function, corresponding to the appropriate land abandonment occurrence probability. ArcGis was used to prepare hotspot maps.

3. Results

The primary artifact of the described research approach is a probability distribution map of land abandonment across the Łódź Voivodeship as of 2018, represented as a heatmap (Figure 7). The final heatmap is the result of further postprocessing, specifically thresholding, in order to solely render cold- and hotspots (Figure 8), displaying clusters of low and high probability of land abandonment according to the Getis–Ord Gi^* statistic. The end result is characterized by contiguous areas of low and high probability, with a significance level of 99%. Further filtering was applied to only include contiguous, unconnected areas, with individual surfaces greater than 50 km^2 . Areas with the highest probability of land abandonment, shown on the map in red, comprise 16 sprawling hotspots (Figure 8, Table 2). The total surface of all hotspots in the Łódź Voivodeship is 4771.5 km^2 . Areas with the lowest probability of land abandonment, colored blue, comprise 9 coldspots displaying comparatively more compact shapes (Figure 8, Table 3). Coldspots are, overall, the most dominant feature, with a total surface area of 5011 km^2 , 27.5% of the voivodeship.

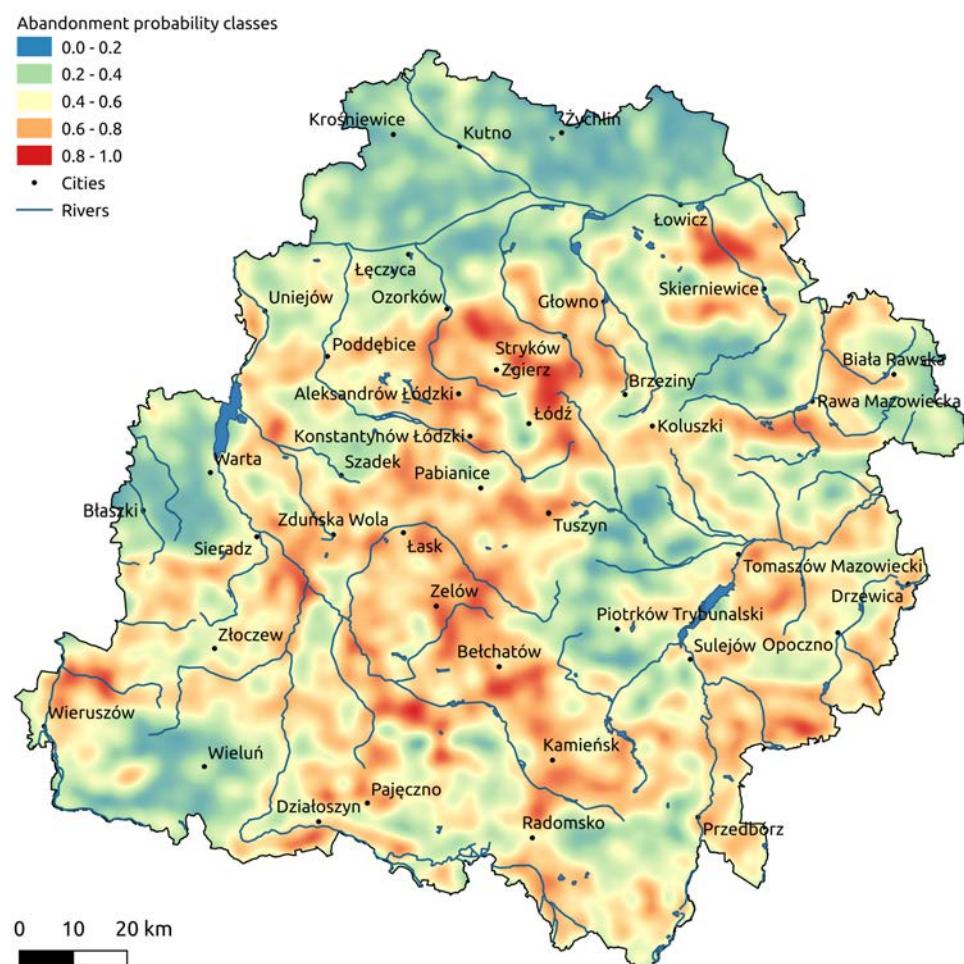


Figure 7. Probability distribution map of land abandonment across the Łódź Voivodeship.

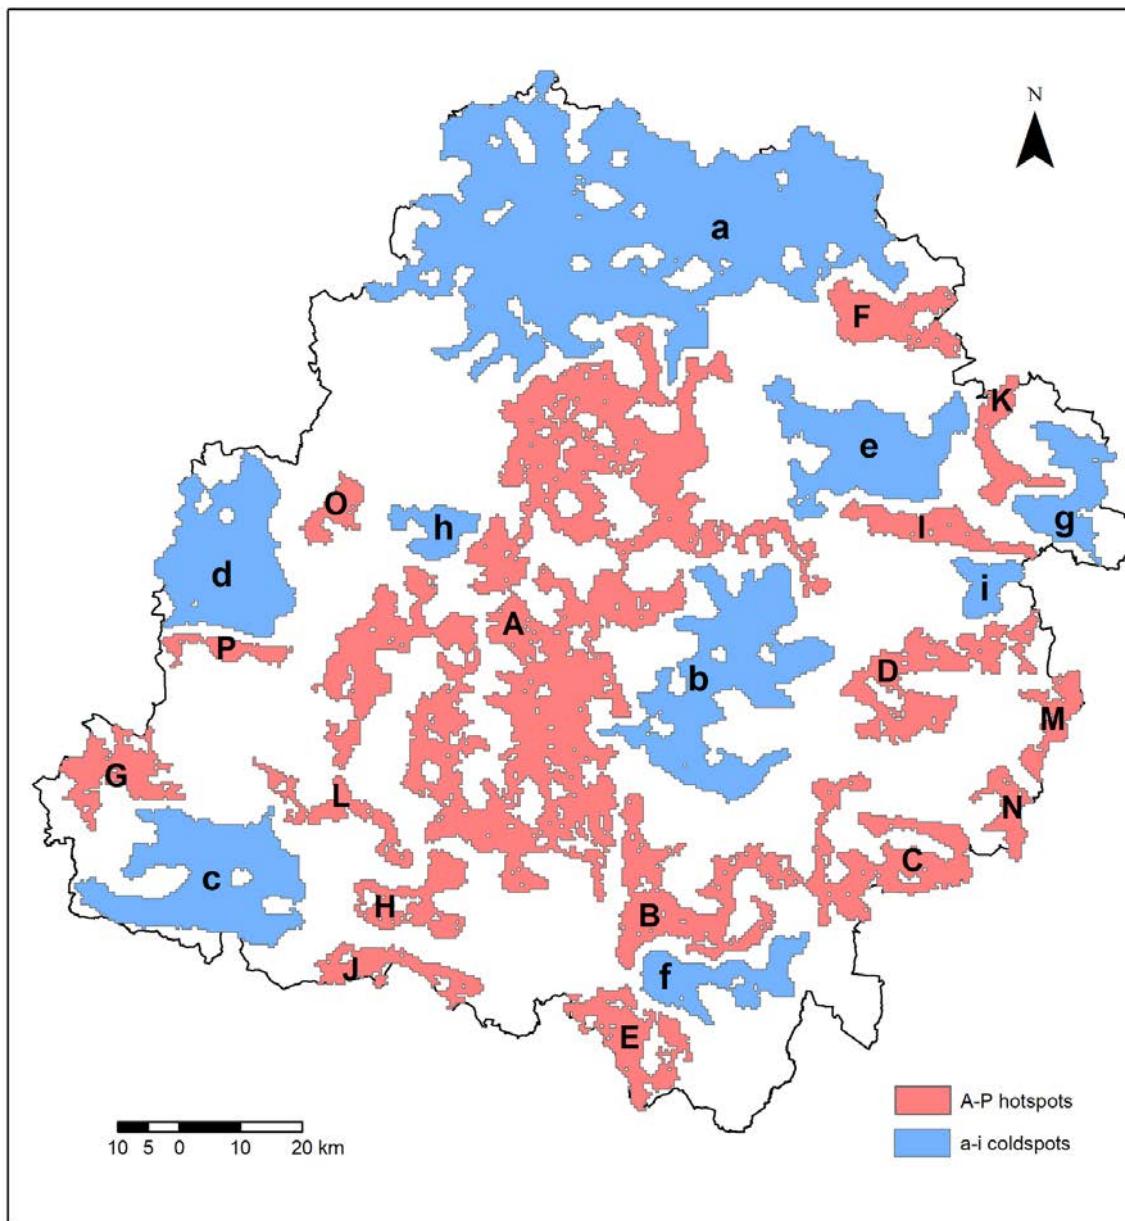


Figure 8. Heatmap with cold- and hotspots of a surface area greater than 50 km².

To the best of our knowledge, our study comprises the first comprehensive land abandonment probability distribution analysis for the entirety of the 18,218.95 km² area of the Łódź Voivodeship. Earlier attempts by a subset of the authors [55] were performed in the context of significantly smaller regions, thus limiting the discoverability of more universal trends influencing this phenomenon for both cold- and hotspots of the relevant probability distribution. Among the most critical factors for the occurrence of land abandonment coldspots are (Figure 9):

1. The presence of soil complexes assigned to the highest classes of arability (1,2,3,4,8) [52], applicable to all coldspots, i.e., (a–i);
2. The presence of soils with a high proportion of silt, a characteristic that affects their air-and-moisture-related properties, improves vegetation access to groundwater, and simultaneously retards rain- and meltwater infiltration. This feature is dominant in the following coldspots: (b), (c), (d), (e), (f), (g), and (i);

3. The presence of soils developed from till or clayey sand underlain by till. This occurs in all coldspots other than (f);
4. The presence of a relatively homogeneous landscape, dominated by plains and thus beneficial to agriculture. Coldspot (a) provides the steekest example with level terrain and a dominant, slightly southern slope, facilitating drainage of excessive melt- and rainwater towards the Bzura river valley. Plains also characterize the following coldspots: (b), (e), (h), and (i).

Table 2. Hotspots.

Symbol in Figure 8	Name	Location	Surface in km ²
A	Central	Surrounding Łódź, Zgierz, Zelów, Szczerców, and the Szczerców Field of Bełchatów Lignite Mine, areas along the Warta river from the vicinity of Stróñsk, through Chojne, until the southernmost suburbs of Sieradz and the vicinity of Hipolitów on the Pisia river	2025.25
B	Kamieńsk	East of Bełchatów, southwest of forest complexes and Gomunice, spanning along the railway from Radomsko towards Kamieńsk and subsequently northwards of the Widawka river valley	292.5
C	Grębienice	Southeast of the Łódź voivodeship, near Grębienice-Nowa Góra, and south of Żarnów	254.5
D	Tomaszów Mazowiecki	Along the Plica river valley and near the Spalski and Sulejowski Landscape Parks	238
E	Gidle	Southern Łódź voivodeship, stretches North–South along the Warta and Stara Wiercica river valleys	158
F	Skierniewice Interchange	Along the western border of the Bolimów Landscape Park and near sparsely forested areas, enveloping the A2 motorway	147.75
G	Struga Węglewska	SW portion of the Łódź Voivodeship, interfluve of Struga Kraszewicka, Struga Węglewska, and Prosna rivers. NE from Wieruszów	138.75
H	Ożegów-Rząśnia	Neighborhood of the Ożegów and Rząśnia localities, stretching east to west	117
I	Rawa	South of Rawa Mazowiecka and the upper Rawka and Rylka river valleys, stretching latitudinally	110.5
J	Działoszyn	South of the Warta river, chiefly east of Grabia river, extending towards Działoszyn and subsequently curving in the SE direction	101.25
K	Nowy Dwór	Stretching longitudinally on the E side of the Rawka valley and along the Białka valley	90.25
L	Strobin	Running NW–SE between the localities of Oleśnica and Osina	88
M	Drzewica	Extending alongside the eastern border of the voivodeship, between the Ossa and Rozwady villages, centered on the Drzewica locality	71.75
N	Petrykozy	Near the voivodeship's eastern border, SE of Opoczno, along the Mlynkowska and Drzewiczka river valleys, centered on Petrykozy	59.75
O	Grabina	Between the Pichna and Urszulinka rivers, westward of Zadzim	53.25
P	Kliczków	Stretches latitudinally between the Izabela and Kije localities	50.5

Table 3. Coldspots.

Symbol in Figure 8	Name	Location	Surface in km ²
a	Northern	Mostly within the northern part of the voivodeship, including the Warsaw-Berlin Urstromtal and the surroundings of Ozorków, Łęczyca, extending towards Łowicz	2055
b	Piotrków Trybunalski	Elongated along the N–S axis, bounded by the Piasecznica valley from the north and the Bogdanówka valley from the south, centered on the localities of Moszczenica and Wolbórz	554
c	Wieluń	SW portion of the voivodeship, near Wieluń	459.75
d	Błaszki-Warta	West of the Warta valley, in the vicinity of the Jeziorsko reservoir, delimited by the voivodeship's western border. Highly contiguous	429.75
e	Jeżów	Centered on Jeżów	372.75
f	Przedbórz-Radomsko	Elongated along the W–E axis, in the southern portion of the voivodeship, extending as far west as Radomsko and as far east as Przedbórz	169.5
g	Chodnów	Near Biała Rawskiego and Chodnów, to the east of the Central Rail Line, adjacent to the eastern border of the voivodeship	164.75
h	Szadek	Relatively compact, between the town of Szadek to the south and Poddębice to the north	70.07
i	Sadykierz	Bordering the Spalski Landscape Park's forests southward and the Luboczanka valley northward. Contains the localities of Sadykierz and Rzeczyca	66.50

The following natural, socioeconomic, and/or locational factors that contribute to the presence of hotspots were found:

1. Low-quality soil, usually of those qualified as (6), (7), (9) among arability complexes, as well as (very) poor meadowland and pastures “3z” [52]. The aforementioned complexes are common within all identified hotspots;
2. A significant presence of forest complexes, especially in the form of numerous sparse patches. A characteristic of abandoned land distribution is a higher occurrence on the peripheries of cultivated fields neighboring forests. This property is intrinsic to all identified hotspots;
3. The vicinity of expressways, motorways, and the associated interchanges. Present in hotspots (A), (B), and (F);
4. The presence of urbanization and suburbanization near major cities, e.g., Łódź and Zgierz for hotspot (A), as well as in hotspots (D) and (F);
5. The vicinity of sand, gravel, sandstone, and limestone extraction sites, as well as the presence of poor-quality soils bordering lignite strip mines. This exploitation of natural resources influences the scale of land abandonment in hotspots (A), (B), (C), (D), (H), (J), and (L);
6. The presence of forests and zones along riversides and around the shorelines of lakes and reservoirs, where natural assets have contributed to the development of vacation settlements. Recreational land use among abandoned lands is characteristic of hotspots (A), (B), (C), (D), (L), (O);
7. Undulating terrain, with an increased occurrence of hills to the point of hindering fieldwork and facilitating excessive drainage. This relationship arises in hotspots located in the southern portion of the Łódź Voivodeship, such as (L) and (J), and in the relevant part of the (A) hotspot;
8. Overgrowth of disused meadows and pastures located in river valleys. Present in all relevant areas but especially prominent in the following hotspots: (A), (B), (C), (D), (E), (J);
9. Frontier and periphery locations combined with low economic feasibility, apparent within the southeastern and southern borderlands of the voivodeship. These conditions are relevant to the following hotspots: (C), (E), (J), (M), (N).

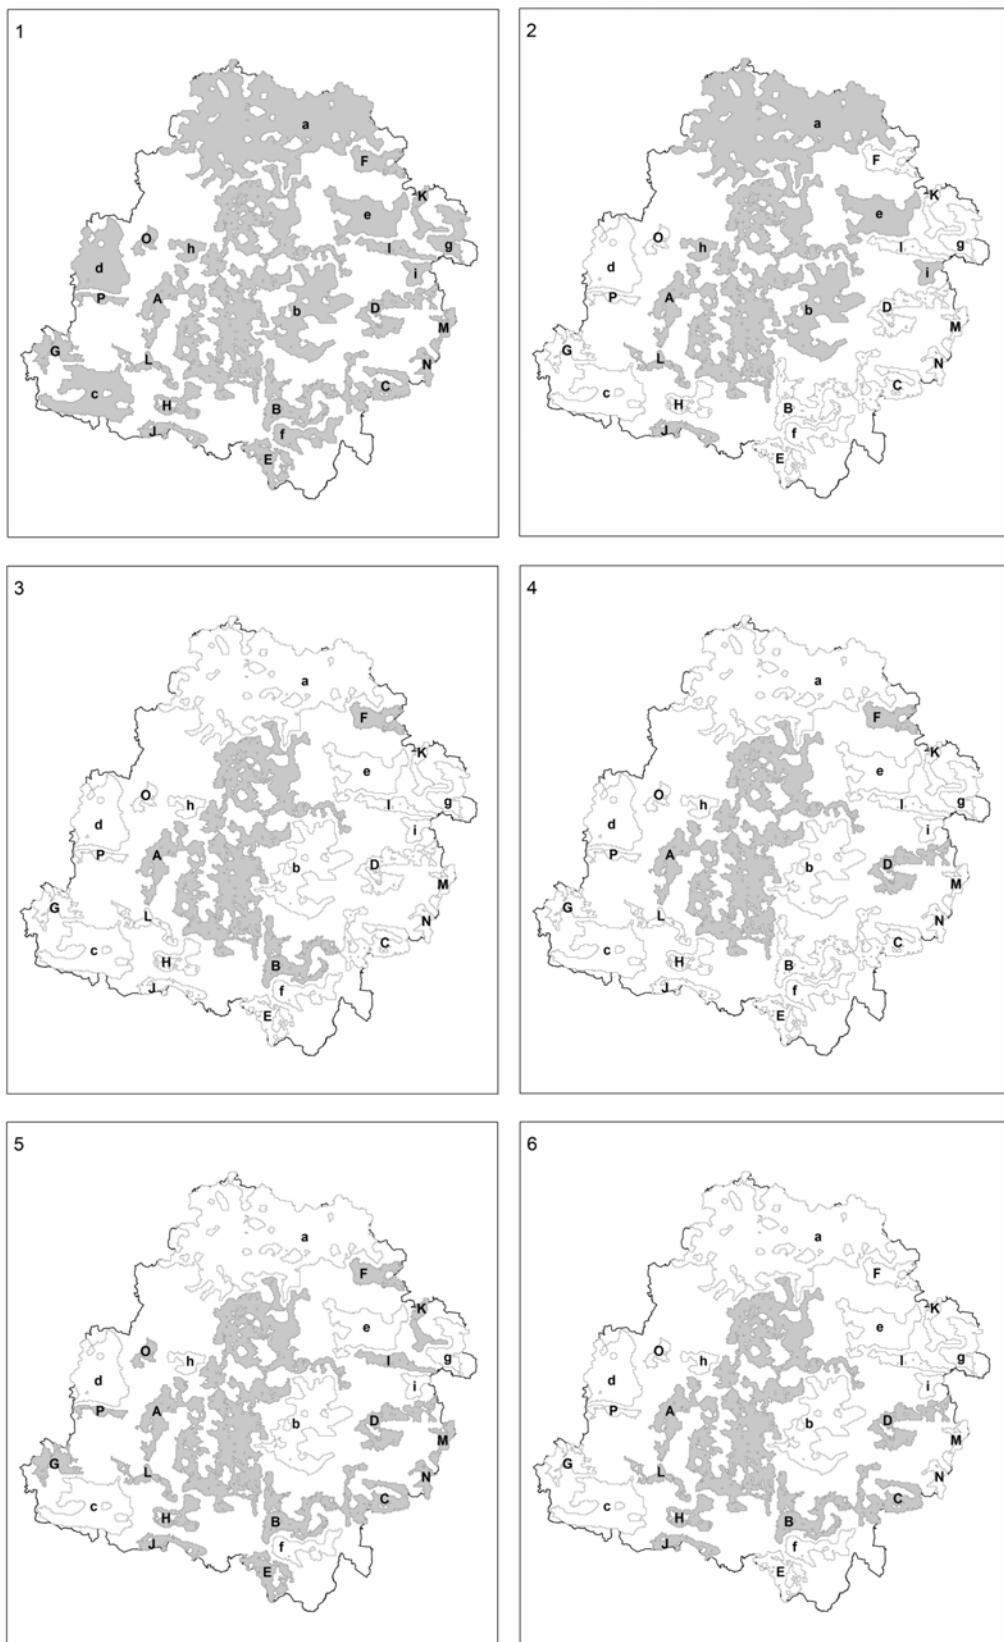


Figure 9. The occurrence of conditions of and contributing factors to the presence of identified land abandonment cold- and hotspots: 1—soil conditions; 2—landscape; 3—vicinity of roads and/or interchanges; 4—urbanization and suburbanization; 5—vicinity of forests; 6—surroundings of mineral exploitation sites.

4. Discussion

The resultant 2018 land abandonment probability distribution map of the Łódź voivodeship (Figure 7) displays a marked correspondence to 1996 and 2002 abandonment and fallow communal land maps of Poland, prepared using then-available statistical data [4,5]. Many communes (lowest administrative subdivisions) in the southeastern portion of the voivodeship are 20–40% abandoned lands, with this amount even exceeded locally. In the aforementioned historical reports, areas of considerable abandonment were also ones of so-called “cultivative problem zones”. The latter encompassed areas of the lowest agricultural utilization country-wide, unfavorable environmental conditions, and/or conflicting nonagricultural uses [56]. In fact, the indicated portions of the voivodeship were also within the peripheries of two cultivative problem zones: the Świętokrzyskie region and the Polish Jurassic Highland. The current distribution of abandoned lands (Figure 7) confirms the multiannual continuity of the abandonment process, as well as a potential for advanced, secondary plant succession in some regions. As witnessed through on-the-ground observations across the Łódź voivodeship, the contemporary degree of tree canopy cohesion over abandoned lands resembles juvenile-stage forestation.

In order to evaluate the veracity of the land abandonment probability distribution map in the Łódź Voivodeship (Figure 7), a comparative study was performed to assess the ground-level presentation of land coverage. Two representative research areas were chosen, each of 16 km^2 , named “Cieszanowice” and “Dmenin”. Both units are located outside of the landscape parks utilized to compose datasets for the machine learning models.

The “Cieszanowice” unit, encompassing the Cieszanowickie Lake and its vicinity, represents a high-land-abandonment area because it is found within the Kamieńsk hotspot (B). At the end of the spectrum, the “Dmenin” unit has been subject to intensive agricultural cultivation and is within the Przedbórz-Radom coldspot (f). The “Cieszanowice” unit, surveyed for land abandonment on 2018-07-25, represents areas with low biotic productivity. The area contains overly permeable glacial and fluvioglacial sands and gravels, eolian sands, as well as fluvial sands and gravels [57]. As evidenced through research on the physical and chemical soil properties of similar areas [18,21,22,58–64], these characteristics often render agricultural activity economically unviable and therefore lead to land abandonment. In the specific case of the “Cieszanowice” unit, the land abandonment process was augmented by the creation of a reservoir, as well as the recreational land usage associated with such a development [65]. The corresponding fragment of the probability distribution map is therefore verified (Figure 10).

The “Dmenin” unit, surveyed for land abandonment on 2018-07-02, represents a highly cultivated area. Present here are concentrations of tills, glacial and fluvioglacial sands, and gravels, as well as outcrops of Cretaceous sands and Jurassic limestones [66]. In addition, there is a series of aeolian, periglacial dusts, with a thickness of up to 1 m, a deciding factor of high arability. The silts cover virtually the entire surface of the unit, contributing to beneficial air-and-moisture-related properties, regardless of whether they coat tills or overly permeable sands and gravels. Another component advancing the favorable quality of the agricultural production space is the generation of a rich sorption complex [58,59,67]. The appropriate portion of the probability distribution map aligns with the above observations (Figure 11).

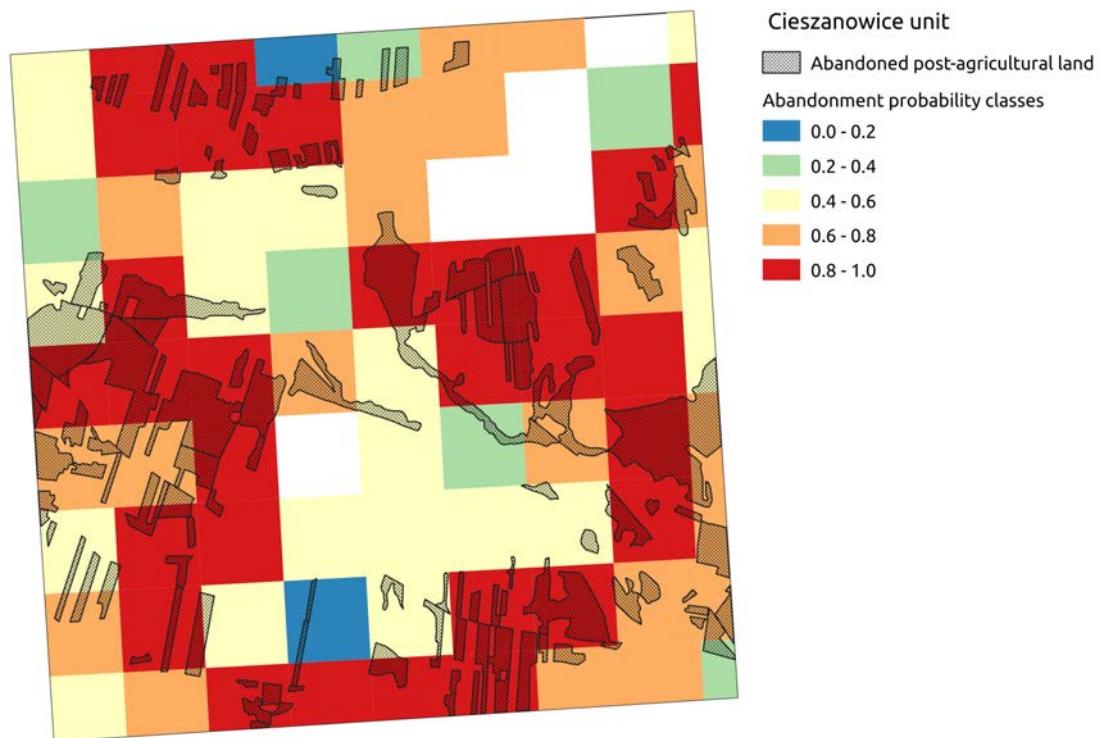


Figure 10. Abandoned postagricultural land in the “Cieszanowice” unit, superimposed over land abandonment probability classes (hotspot B).

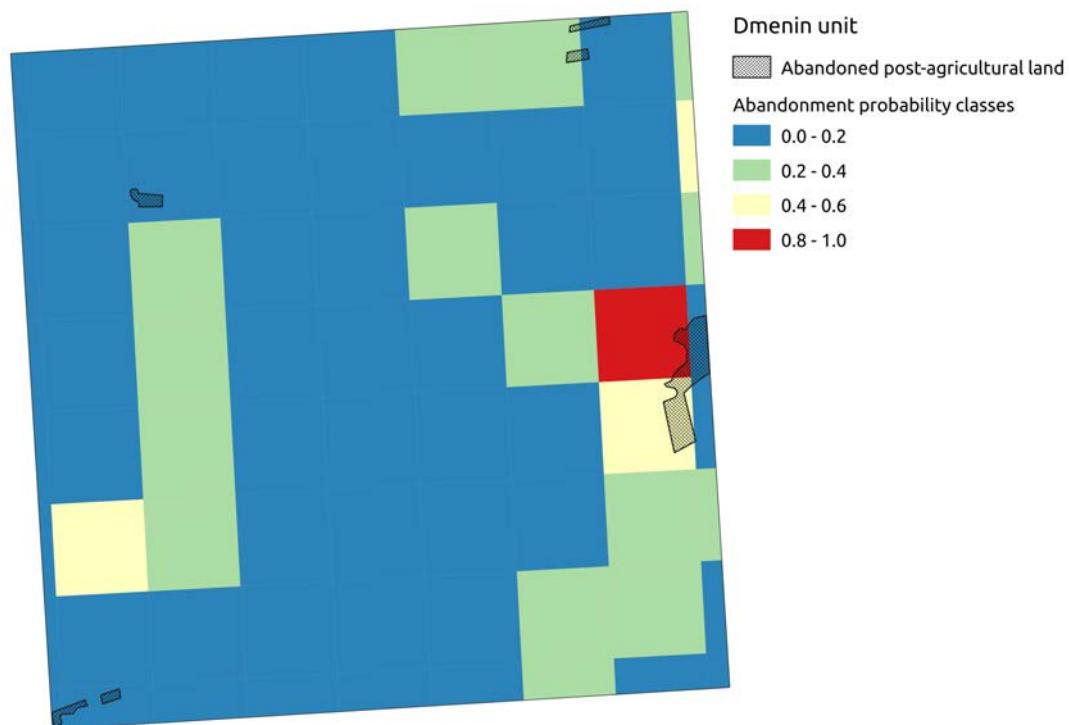


Figure 11. Abandoned postagricultural land in the “Dmenin” unit, superimposed over abandonment probability classes (coldspot f).

5. Conclusions and Future Work Opportunities

As evidenced by the performed comparative studies, automatic land abandonment detection based on the application of modern Convolutional Neural Networks via satellite imagery is indeed viable. The principal benefits of our proposed approach are both time-efficiency and cost-effectiveness. We were able to classify, designating land abandonment hotspots, an area in excess of 18,000 km² at a fraction of the cost and time that a human-run orthophoto analysis would consume. Complementary to the aforementioned advantage, 5011 km² of the studied area was located in coldspots. This provides an ancillary benefit to the possibility of deprioritizing verification fieldwork where it is possibly less pressing. A potential positive side effect of our proposed method is reduced human involvement in the classification process. Such increased independence might diminish deleterious factors such as confirmation bias or possible result tampering. Lastly, result-wise, the extraction of cold- and hotspots allowed for a high-level analysis of the environmental conditions accompanying sparse and intense land abandonment in the Łódź Voivodeship. This generates the potential for both further theoretical study and the refinement of future machine learning models.

Indeed, there are several possible areas of improvement in our approach to perfecting the current model. Preprocessing could be improved by using a separate CNN [49] or leveraging a specialized architecture, such as a Generative Adversarial Network (GAN) [68]. Compensating for any missing data in this way will possibly allow for greater model fidelity. An important subproblem of classifying abandoned lands is the evolution of vegetation as a given plot is overtaken by successive stages of overgrowth. This corresponds to the various grades of land abandonment denoted in the Methods and Materials section. Furthermore, solutions could be derived from the related study of deforestation analysis, such as that in [69]. As noted in the literature section, adding temporal information either implicitly through multiple images of the same area [43] or explicitly via encoding in the model structure [44] could also improve classification results. However, in our particular case, this could provide limited utility, as source-of-truth surveys are performed at specific times of the year, reducing the maximum possible temporal resolution of the classification.

Finally, transfer learning, i.e., training new models for different data on the basis of existing ones, could prove advantageous when classifying additional areas. In fact, this has already been verified as effective in at least one scenario for land cover classification [42].

Supplementary Materials: The following materials are available online at <https://github.com/softwaremill/land-abandonment-detection/tree/v1>: date timestamps for Sentinel Hub data (under “data”), data ingestion and prediction scripts (under “notebooks”), and trained Convolutional Neural Network architecture model (under “models”).

Author Contributions: Conceptualization, S.K., A.M., E.P.; methodology, S.K., A.M. and M.A.; software, M.A.; validation, S.K., A.M. and E.P.; formal analysis, M.A. and A.M.; investigation, S.K. and M.K.; resources, M.A. and M.K.; data curation, M.A.; writing—original draft preparation, S.K., A.M., E.P., M.K. and M.A.; writing—review and editing, M.K. and Majchrowska A.; visualization, M.A. and A.M.; supervision, S.K. and E.P.; project administration, M.A. All authors have read and agreed to the published version of the manuscript.

Funding: This research received no external funding

Acknowledgments: We would like to thank Małgorzata Orzechowska for an additional linguistic review as well as Tomasz Napierała, for the helpful remarks.

Conflicts of Interest: The authors declare no conflict of interest. The funders had no role in the design of the study; in the collection, analyses, or interpretation of data; in the writing of the manuscript, or in the decision to publish the results.

References

1. Borowska-Stefńska, M.; Leśniewska-Napierała, K.; Wiśniewski, S. Land cover changes in Poland between 1990 and 2012. *Geografie* **2018**, *123*, 63–89. [[CrossRef](#)]
2. Janus, J.; Bożek, P. Land abandonment in Poland after the collapse of socialism: Over a quarter of a century of increasing tree cover on agricultural land. *Ecol. Eng.* **2019**, *138*, 106–117. [[CrossRef](#)]

3. Krysiak, S. Współczesne tendencje zmian w użytkowaniu nadpilicznych krajobrazów rolniczych na tle potencjału siedliskowego geokompleksów. *Probl. Ekol. Kraj.* **2006**, *XV*, 228–241.
4. Bański, J. *Gospodarka Ziemią w Polsce w Okresie Restrukturyzacji*; IGiPZ PAN: Warszawa, Poland, 1998; pp. 1–117.
5. Bański, J. *Geografia Polskiej Wsi*; PWE: Warszawa, Poland, 2006; pp. 1–218.
6. Kucharski, L. Przemiany roślinności łąkowej w Polsce Środkowej w wyniku zmian metod gospodarowania. In *Problemy Ochrony I UżYtkowania Obszarów Wiejskich O DużYch Walorach Przyrodniczych*; Wydawnictwa Uniwersytetu Marii Skłodowskiej-Curie: Lublin, Poland, 2000; pp. 227–234.
7. Orłowski, G.; Nowak, L. Problematyka odłogowania gruntów w świetle wyników badań prowadzonych w krajach Europy Zachodniej i Stanach Zjednoczonych. (Artykuł przeglądowy). *Acta Sci. Pol. Agric.* **2004**, *3*, 27–36.
8. Statistics Poland. Land use. In *Rural Areas in Poland—National Agricultural Census 2010*; Statistics Poland: Warszawa, Poland, 2013; pp. 1–87.
9. Rozporządzenie Ministra Rozwoju Regionalnego i Budownictwa z dnia 29 Marca 2001 r. w sprawie Ewidencji Gruntów i Budynków (Dz. U. rok 2001, nr 38, poz. 454); Chancellery of the Prime Minister of Poland: Warsaw, Poland, 2001.
10. Krysiak, S. Odłogi w krajobrazach Polski środkowej—aspekty przestrzenne, typologiczne i ekologiczne. *Probl. Ekol. Kraj.* **2011**, *XXXI*, 89–96.
11. Czesak, B.; Cegielska, K.; Cherkes, B.; Różycka-Czas, R.; Salata, T. Fieldwork approach to determining the extent of agricultural land abandonment—Case study. *Geomat. Landmanag. Landsc.* **2016**, *3*, 21–31. [[CrossRef](#)]
12. Krysiak, S. Struktura użytkowania ziemi w dorzeczu Dzierżaznej – charakterystyka i aspekty hydrologiczne zagospodarowania zlewni. *Folia Geogr. Physic* **2000**, *5*, 83–92.
13. Matuszyńska, J. Zmiany użytkowania terenu jako element transformacji środowiska przyrodniczego na obszarze wybranych zlewni Poznania i jego strefy podmiejskiej. In *Prace Komisji Geograficzno-Geologicznej*; PTPN: Poznań, Poland, 2001; Volume 30, pp. 1–160.
14. Krysiak, S. Contemporary land-use changes in Central Poland. *Pap. Glob. Chang. IGBP* **2008**, *15*, 89–103.
15. Krysiak, S. Ekologiczne aspekty przemian użytkowania ziemi w wybranych typach krajobrazów naturalnych Polski Środkowej. *Probl. Ekol. Kraj.* **2008**, *XXI*, 299–310.
16. Krysiak, S. Ekologiczno-krajobrazowy wymiar odłogowanych gruntów porolnych—przykłady z województwa łódzkiego. In *Obszary metropolitalne we współczesnym środowisku geograficznym*; Oddział Łódzki PTG—Wydział Nauk Geograficznych Uniwersytetu Łódzkiego: Łódź, Poland, 2010; pp. 309–320.
17. Jermaczek, D. Analiza rozmieszczenia i struktury zadrzewień powstalych na odlogowanych gruntach porolnych w okolicach Lagowa w latach 1990–2007. *Przegląd Przyr.* **2007**, *XVIII*, 29–53.
18. Krysiak, S.; Papińska, E.; Majchrowska, A. Abandoned agricultural lands in buffer zones around landscape parks in the Łódź Voivodeship—habitat background, spatial distribution, scale of the phenomenon. In *The Ecological Role of Abandoned Agricultural Lands in Buffer Zones Around Landscape Parks in the Łódź Voivodeship*; Krysiak, S., Adamczyk, J., Eds.; Wydawnictwo Uniwersytetu Łódzkiego: Łódź, Poland, 2016. [[CrossRef](#)]
19. Majchrowska, A. Abandonment of agricultural land in central Poland and its ecological role. *Ekológia* **2013**, *32*, 320–327. [[CrossRef](#)]
20. Majchrowska, A. Odłogowanie gruntów w otoczeniu parków krajobrazowych. In *Studia Obszarów Wiejskich*; IGiPZ PAN: Warszawa, Poland, 2014; Volume XXXV, pp. 215–226.
21. Papińska, E. Abandoned lands around the Sieradz landscape parks (Załęcze Landscape Park, Warta–Widawka Interfluve Landscape Park). In *The Ecological Role of Abandoned Agricultural Lands in Buffer Zones Around Landscape Parks in the Łódź Voivodeship*; Krysiak, S.; Adamczyk, J., Eds.; Wydawnictwo Uniwersytetu Łódzkiego: Łódź, Poland, 2016; pp. 22–29.
22. Papińska, E. Siedliska terenów odłogowanych w otoczeniu Załęczańskiego Parku Krajobrazowego. *Probl. Ekol. Kraj.* **2016**, *XLI*, 147–159.
23. Szostak, M.; Hawryło, P.; Piela, D. Using of Sentinel-2 images for automation of the forest succession detection. *Eur. J. Remote Sens.* **2018**, *51*, 142–149. [[CrossRef](#)]
24. Kołecka, N.; Kozak, J.; Kaim, D.; Dobosz, M.; Ginzler, C.; Psomas, A. Mapping Secondary Forest Succession on Abandoned Agricultural Land with LiDAR Point Clouds and Terrestrial Photography. *Remote Sens.* **2015**, *7*, 8300–8322. [[CrossRef](#)]
25. Janus, J.; Bożek, P. Using ALS data to estimate afforestation and secondary forest succession on agricultural areas: An approach to improve the understanding of land abandonment causes. *Appl. Geogr.* **2018**, *97*, 128–141. [[CrossRef](#)]

26. Kołecka, N.; Kozak, J. Wall-to-wall parcel-level mapping of agricultural land abandonment in the Polish Carpathians. *Land* **2019**, *8*, 129. [[CrossRef](#)]
27. Faliński, J.B. Interpretacja współczesnych przemian roślinności na podstawie teorii synantropizacji i teorii syndynamiki. In *Prace Geograficzne*; IGiPZ PAN: Warszawa, Poland, 2001; Volume 179, pp. 31–52.
28. Kurus, J.; Podstawk-Chmielewska, E. Struktura flory po dziesięcioletnim odłogowaniu gruntu ornego na dwóch typach gleb [Structure of flora after ten years land lying fallow on two types of soil]. *Acta Agrobot.* **2006**, *59*, 365–376. [[CrossRef](#)]
29. Ratyńska, H. Wyspy środowiskowe jako element krajobrazu, próba typologii i zróżnicowanie szaty roślinnej. In *Wyspy Środowiskowe. Bioróżnorodność i próba Typologii*; Banaszek, J., Ed.; Wyd. Akademii Bydgoskiej im. K. Wielkiego: Bydgoszcz, Poland, 2002; pp. 239–260.
30. Matysiak, A. Porównanie roślinności terenów porolnych zalesionych i pozostawionych naturalnej sukcesji w Kampinoskim Parku Narodowym. *Przegląd Przyr.* **2007**, *XVIII*, 109–191.
31. Krysiak, S. Odłogi jako element potencjału rekreacyjnego w strefie nadpilicznych parków krajobrazowych. *Probl. Ekol. Kraj.* **2012**, *XXXIV*, 141–148.
32. Wiluś, R. Rozwój funkcji turystycznej w dolinie rzeki Warty na odcinku od Działoszyna do Uniejowa. In *Szlakami Nauki*; ŁTN: Łódź, Poland, 1997; Volume 24, pp. 1–218.
33. Wojciechowska, J. Kolonizacja turystyczna terenów nadpilicznych. In *Szlakami Nauki*; ŁTN: Łódź, Poland, 1998; Volume 26, pp. 1–159.
34. Krysiak, S. Transformacja krajobrazów wiejskich regionu łódzkiego pod wpływem rozwoju funkcji turystycznych. Transformation of rural landscapes in the Łódź region by influence of the tourist functions development. *Probl. Ekol. Kraj.* **2010**, *XXVII*, 231–237.
35. Krysiak, S. Rola odłogów i terenów rekreacyjnych we współczesnych przemianach krajobrazów wiejskich regionu łódzkiego. In *Studia Obszarów Wiejskich*; IGiPZ PAN: Warszawa, Poland, 2014; Volume XXXV, pp. 75–87.
36. Kussul, N.; Lavreniuk, M.; Skakun, S.; Shelestov, A. Deep Learning Classification of Land Cover and Crop Types Using Remote Sensing Data. *IEEE Geosci. Remote Sens. Lett.* **2017**, *14*, 778–782. [[CrossRef](#)]
37. Kamilaris, A.; Prenafeta-Boldú, F.X. A review of the use of convolutional neural networks in agriculture. *J. Agric. Sci.* **2018**, *156*, 312–322. [[CrossRef](#)]
38. NASA. Landsat 8. Landsat Science. Available online: <https://landsat.gsfc.nasa.gov/landsat-8/> (accessed on 11 November 2019).
39. ESA. Sentinel-2—ESA Operational EO Missions—Earth Online—ESA. Available online: <https://earth.esa.int/web/guest/missions/esa-operational-eo-missions/sentinel-2> (accessed on 11 November 2019).
40. Chen, Y.; Lin, Z.; Zhao, X.; Wang, G.; Gu, Y. Deep Learning-Based Classification of Hyperspectral Data. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2014**, *7*, 2094–2107. [[CrossRef](#)]
41. Luus, F.P.S.; Salmon, B.P.; van den Bergh, F.; Maharaj, B.T.J. Multiview Deep Learning for Land-Use Classification. *IEEE Geosci. Remote Sens. Lett.* **2015**, *12*, 2448–2452. [[CrossRef](#)]
42. Lu, H.Z.; Fu, X.; Liu, C.; Li, L.; He, Y.X.; Li, N.W. Cultivated land information extraction in UAV imagery based on deep convolutional neural network and transfer learning. *J. Mt. Sci.* **2017**, *14*, 731–741. [[CrossRef](#)]
43. Guidici, D.; Clark, M.L. One-Dimensional Convolutional Neural Network Land-Cover Classification of Multi-Seasonal Hyperspectral Imagery in the San Francisco Bay Area, California. *Remote Sens.* **2017**, *9*, 629. [[CrossRef](#)]
44. Rußwurm, M.; Körner, M. Multi-Temporal Land Cover Classification With Long Short-Term Memory Neural Networks. *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci.* **2017**, *42*, 551.
45. Li, C.; Yang, S.X.; Yang, Y.; Gao, H.; Zhao, J.; Qu, X.; Wang, Y.; Yao, D.; Gao, J. Hyperspectral Remote Sensing Image Classification Based on Maximum Overlap Pooling Convolutional Neural Network. *Sensors* **2018**. [[CrossRef](#)]
46. Krizhevsky, A.; Sutskever, I.; Hinton, G.E. ImageNet Classification with Deep Convolutional Neural Networks. *Commun. ACM* **2012**, *60*, 84–90. [[CrossRef](#)]
47. Szegedy, C.; Liu, W.; Jia, Y.; Sermanet, P.; Reed, S.E.; Anguelov, D.; Erhan, D.; Vanhoucke, V.; Rabinovich, A. Going deeper with convolutions. In Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Boston, MA, USA, 7–12 June 2015; pp. 1–9.

48. Carranza-García, M.; García-Gutiérrez, J.; Santos, J.C.R. A Framework for Evaluating Land Use and Land Cover Classification Using Convolutional Neural Networks. *Remote Sens.* **2019**, *11*, 274. [CrossRef]
49. Wu, P.; Yin, Z.; Yang, C.; Wu, Y.; Ma, X. Reconstructing Geostationary Satellite Land Surface Temperature Imagery Based on a Multiscale Feature Connected Convolutional Neural Network. *Remote Sens.* **2019**, *11*, 300. [CrossRef]
50. Torbick, N.; Huang, X.; Ziniti, B.; Johnson, D.; Masek, J.; Reba, M.L. Fusion of Moderate Resolution Earth Observations for Operational Crop Type Mapping. *Remote Sens.* **2018**, *10*, 1058. [CrossRef]
51. Windrim, L.; Melkumyan, A.; Murphy, R.J.; Chlingaryan, A.; Ramakrishnan, R. Pretraining for Hyperspectral Convolutional Neural Network Classification. *IEEE Trans. Geosci. Remote Sens.* **2018**, *56*, 2798–2810. [CrossRef]
52. Geoportal of Łódzkie Region, “Maps of Soil and Agricultural and Geological Portal”. 2019. Available online: <https://geoportal.lodzkie.pl/imap/?locale=en> (accessed on 1 October 2019).
53. Sinergise Ltd.. Modified Copernicus Sentinel Data 2019/Sentinel Hub. Available online: <https://www.sentinel-hub.com/> (accessed on 3 October 2019).
54. sentinelhub-py. 2019. Available online: <https://github.com/sentinel-hub/sentinelhub-py> (accessed on 3 October 2019).
55. Majchrowska, A. Abandoned lands around the Łódź Hills Landscape Park and the Bolimów Landscape Park. In *The Ecological Role of Abandoned Agricultural Lands in Buffer Zones Around Landscape Parks in the Łódź Voivodeship*; Krysiak, S., Adamczyk, J., Eds.; Wydawnictwo Uniwersytetu Łódzkiego: Łódź, Poland, 2016; pp. 30–41.
56. Bański, J. *Obszary Problemowe W Rolnictwie Polski*; IGiPZ PAN: Warszawa, Poland, 1999; pp. 1–128.
57. Kurkowski, S.; Popielski, W. Gorzkowice sheet. In *Szczegółowa Mapa Geologiczna Polski 1:50000*; Wydawnictwa Geologiczne: Warszawa, Poland, 1986.
58. Krysiak, S. Typy geokompleksów i kierunki ich użytkowania w środkowej części dorzecza Pilicy. *Acta Geogr. Lodz.* **1999**, *75*, 1–214.
59. Krysiak, S. Waloryzacja geokompleksów Polski Środkowej na podstawie badań krajobrazowych i badań właściwości fizycznych i chemicznych utworów powierzchniowych. *Zesz. Probl. Postępów Nauk Rol.* **2005**, *507*, 295–306.
60. Papińska, E. Cechy siedlisk terenów odlegowych w strefie otaczającej Park Krajobrazowy Międzyrzecza Warty i Widawki. *Probl. Ekol. Kraj.* **2014**, *XXXVII*, 121–130.
61. Adamczyk, J.; Krysiak, S.; Sieradzki, J. Abandoned land study plot groups in the buffer zone around landscape parks on the Pilica River. In *The Ecological Role of Abandoned Agricultural Lands in Buffer Zones Around Landscape Parks in the Łódź Voivodeship*; Krysiak, S., Adamczyk, J., Eds.; Wydawnictwo Uniwersytetu Łódzkiego: Łódź, Poland, 2016; pp. 42–71.
62. Krysiak, S. Abandoned lands around landscape parks on the Pilica River (Przedbórz Landscape Park, Sulejów Landscape Park, Spała Landscape Park). In *The Ecological Role of Abandoned Agricultural Lands in Buffer Zones Around Landscape Parks in the Łódź Voivodeship*; Krysiak, S., Adamczyk, J., Eds.; Wydawnictwo Uniwersytetu Łódzkiego: Łódź, Poland, 2016; pp. 15–21.
63. Majchrowska, A.; Adamczyk, J.; Sieradzki, J. Abandoned land study plot groups in the buffer zones around the Bolimów Landscape Park and the Łódź Hills Landscape Park. In *The Ecological Role of Abandoned Agricultural Lands in Buffer Zones Around Landscape Parks in the Łódź Voivodeship*; Krysiak, S., Adamczyk, J., Eds.; Wydawnictwo Uniwersytetu Łódzkiego: Łódź, Poland, 2016; pp. 99–126.
64. Papińska, E.; Adamczyk, J.; Sieradzki, J. Abandoned land study plot groups in the buffer zone around the Sieradz landscape parks. In *The Ecological Role of Abandoned Agricultural Lands in Buffer Zones Around Landscape Parks in the Łódź Voivodeship*; Krysiak, S., Adamczyk, J., Eds.; Wydawnictwo Uniwersytetu Łódzkiego: Łódź, Poland, 2016; pp. 72–98.
65. Szymczyk, M.; Krysiak, S. Przemiany krajobrazu doliny Luciąży i jej otoczenia po utworzeniu zbiornika retencyjnego Cieszanowice. *Acta Univ. Lodz. Folia Geogr. Phys.* **2018**, *17*, 41–50. [CrossRef]
66. Wągrowski, S. Rzejowice sheet. In *Szczegółowa Mapa Geologiczna Polski 1:50000*; Wydawnictwa Geologiczne: Warszawa, Poland, 1983.
67. Krysiak, S. The influence of periglacial cover deposits upon aeration and moisture conditions of geocomplexes. *Biul. Peryglac.* **1996**, *35*, 87–120.

68. Isola, P.; Zhu, J.Y.; Zhou, T.; Efros, A.A. Image-to-Image Translation with Conditional Adversarial Networks. *arXiv* **2018**, arXiv:1611.07004.
69. Huynh, D.N.T.; Neptune, N. Annotation automatique d’images: Le cas de la déforestation. *CORIA* **2018**. [[CrossRef](#)]



© 2020 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0/>).

Publikacja nr 2:

Adamiak, M., Biczkowski, M., Leśniewska-Napierała, K., Nalej, M., Napierała, T. (2020). *Impairing Land Registry: Social, Demographic, and Economic Determinants of Forest Classification Errors*. Remote Sensing, 12(16), 2628, <https://doi.org/10.3390/rs12162628>

MEiN: 100, IF'20: 4.848, CiteScore'20: 6,6.

Article

Impairing Land Registry: Social, Demographic, and Economic Determinants of Forest Classification Errors

Maciej Adamiak ¹, Mirosław Biczkowski ², Katarzyna Leśniewska-Napierała ^{3,*},
Marta Nalej ³ and Tomasz Napierała ³

¹ SoftwareMill, 02-791 Warsaw, Poland; maciej.adamiak@softwaremill.com

² Faculty of Earth Sciences and Spatial Management, Nicolaus Copernicus University in Toruń, Lwowska 1, 87-100 Toruń, Poland; miroslaw.biczkowski@umk.pl

³ Faculty of Geographical Sciences, University of Łódź, Kopcińskiego 31, 90-142 Łódź, Poland;
marta.nalej@geo.uni.lodz.pl (M.N.); tomasz.napierala@geo.uni.lodz.pl (T.N.)

* Correspondence: katarzyna.lesniewska@geo.uni.lodz.pl; Tel.: +48-426-354-573

Received: 30 June 2020; Accepted: 12 August 2020; Published: 14 August 2020



Abstract: This paper investigates the social, demographic, and economic factors determining differences between forest identification based on remote sensing techniques and land registry. The Database of Topographic Objects and Sentinel-2 satellite imagery data from 2018 were used to train a forest detection supervised machine learning model. Results aggregated to communes (NUTS-5 units) were compared to data from land registry delivered in Local Data Bank by Statistics Poland. The differences identified between above mentioned sources were defined as errors of land registry. Then, geographically weighted regression was applied to explain spatially varying impact of investigated errors' determinants: Urbanization processes, civic society development, education, land ownership, and culture and quality of spatial planning. The research area covers the entirety of Poland. It was confirmed that in less developed areas, local development policy stimulating urbanization processes does not respect land use planning principles, including the accuracy of land registry. A high education level of the society leads to protective measures before the further increase of the investigated forest cover's overestimation of the land registry in substantially urbanized areas. Finally, higher coverage by valid local spatial development plans stimulate protection against forest classification errors in the land registry.

Keywords: land cover; forest; convolutional neural networks; machine learning; land registry errors

1. Introduction

The last several years have brought a significant increase of interest in research connected with changes in land use, particularly changes in forest coverage, due to the high dynamics of changes taking place in the geographical environment [1–7]. These issues, at various spatial and time scales, were discussed in many publications on selected regions of Europe, including Belgium [8], Czech Republic [9,10], Germany [11], Great Britain [12], Italy [13,14], Poland [15–22], Romania [23,24], and Spain [25–27]. This intensive development of research results from a large extent of advanced Geographic Information System (GIS) technologies implementations, which make precise quantitative analysis of the land changes possible in any taxonomic units: Administrative, physical-geographical, hydrographic, and others [28–32]. This allows verification of the records in the land registers with the real land functions.

The paper is organized as follows. The section “Literature Review and Hypotheses” briefly presents the review of previous works on the cause of errors in the land registration. The subsequent section, “Methods and Data Collection,” contains a description of the research design, applied methods,

data collection process, and research area. The “Results and Discussion” section presents and interprets the findings of our research. The paper is closed by “Conclusions,” summarizing the main findings regarding relations between the scale of the errors in land registry and impact of considered factors: Urbanization processes, civic society development, education, land ownership, and culture and quality of spatial planning.

2. Literature Review and Hypotheses

In the literature related to the assessment of the quality of data contained in land registers and factors affecting errors appearing, there has been much attention paid to formal, legal, organizational, and administrative factors, and to technical issues as well. However, socioeconomic factors have rarely been discussed in this context, especially regarding demography and urbanization, the condition of civic society, education, land ownership, and the quality of spatial planning.

2.1. Urbanization Processes Influencing Classification Errors in Land Registers

Demographics and unplanned, unsystematic, and rapid urbanization also have important implications for changes in transformation of the physical landscape, land cover, and forest loss and fragmentation [33–35]. Changing patterns of land use and the impact of socioeconomic factors have brought about major changes in ecosystems and forest land use [36]. Understanding of the dynamics of urbanization-induced land cover change is therefore necessary to acknowledge differences between the land register and the actual land functions.

Forests near large cities are subject to a strong anthropogenic pressure related to suburbanization. Migration and population growth in urban agglomerations stimulate the demand for land, including areas of high natural quality [37]. This contributes to the progressing fragmentation of forests [38] and the successive reduction of forest areas and their transformation into residential areas [39]. The local and regional sequences of natural connections are being cut. Therefore, it seems logical that the degree of forest fragmentation affects the number of errors [40] occurring both on maps [41] and in land registrations. Research conducted on the example of the Warsaw agglomeration confirms that the spontaneous development of buildings often occurs in suburban forests [42], which are bought for single-family housing. This is confirmed by the high dynamics of applications for changes in the use of these lands for construction purposes. In addition, buildings on forest plots often exceed acceptable standards or norms [43]. There are often cases of noncompliance with the provisions of local spatial development plans by owners of newly built residential buildings regarding the minimum share of forested area on a plot. Then, there is the situation in which the area occupied for development significantly exceeds the permissible size, which means that the forested area of such a plot remains fictional [44]. On the other hand, abandoned farmland, particularly in central and northern Europe, is undergoing a process of colonization by trees [45]. All this translates into irregularities between the actual state and records in the land registries.

2.2. Impact of the Condition of Civic Society on Data Quality in Land Registers

Knowledge is scarce over how the public sphere, and civic society in particular, engage with building data infrastructure including land registry data. Gray & Lammerhirt [46] partly tried to fill the research gap in this respect, but mainly in the context of urban areas. Meanwhile, in the literature, the social factor (people) has often been indicated as one of the most significant in Spatial Data Infrastructures (SDI) components next to data, legal, access and technology, standards, policy, and institutional arrangement [47,48].

Poland is still in the construction phase and maturation of civic society [49–51]. Among Polish citizens, there is a common attitude of unwillingness to cooperate with the authorities, which is also due to experience in the functioning of the previous political and economic system, which is why residents do not trust public authorities and show a low degree of involvement in sociopolitical issues [52,53]. This translates into a high degree of ignorance of formal and legal issues because of, e.g., difficult and

unclear language of official documents and legal acts, complexity of procedures, inconsistent judicial and administrative rules, low level of spatial planning awareness, and the lack of interest in controlling of local authorities and institutions [54]. Insufficient legal awareness of the society in relation to the obligations and rights of owners and to the state's obligations regarding the protection of property rights to land causes a lack of fulfilling the obligations incumbent on residents (e.g., not updating records of land registration dictated by financial and tax issues), as well as proper supervision by public institutions [55,56]. Meanwhile, "good practices" in the quality of land registry data depend very strongly on the local social and cultural context of the particular land administration system [57].

Civic society, created thanks to voluntary organizations, associations, and contacts, is one of the foundations of the democratic system [51,58], shaping proper social and political relations [59,60] and achieving public goals [61]. The active participation of residents in spatial management (e.g., spatial planning, land records updating, etc.) is a characteristic of a developed democracy and an already formed civic society [62–64]. In Poland, the development of civic activity and the increase of social expectations are progressing slowly but steadily. A participatory approach in consulting planning arrangements is becoming more and more common [65–69]. Citizens' initiatives and associations are in the interests of various social groups participating in democracy procedures and common actions. Civic participation can be measured, e.g., by the level of election attendance [70–73] or participation in various types of nongovernmental organizations (NGOs), associations, or clubs [74–77]. It can be expected that the more developed the civic society institutions are, the better the control of the land registry should be, and as a consequence, the differences between the land registry and the real land functions should be smaller.

2.3. Education Level and Its Influence on Errors in Land Registers

The level of education is also important, because the higher the share of people with higher education in society is, the higher the expected level of activity and interest in sociopolitical matters. People with higher education, compared to people without, work and sit on the boards of NGOs more often and actively participate in volunteering [78]. It can be assumed that the better educated the society, the better the control over matters related to records of the land registry is. In addition, significant differences in social activity are observed in the urban-rural relationship, which almost entirely comes from twice the percentage of people with secondary and higher education in the urban population [79–81]. Hence, in more urbanized areas, residents show greater interest in local matters, and there, greater compliance of the formal status (land registry) with the actual status can be expected.

2.4. Land Ownership and Land Registry Classification Errors

The percentage of ownership of the forest by the State Forests underwent major changes over the years, especially in the period immediately after World War II, when there was a significant increase in forest areas managed by the State Forests. In the 1990s, the boundaries of real estate began to be disclosed in land and mortgage registers, when they were established for the State Forests' land [82]. Currently, they are established for the majority of the State Forests' land, and care for the state of ownership has become a priority for the State Forests [82–84].

2.5. Relation between Culture of Spatial Planning and Data Quality in Land Registers

Land management and economic development activities stimulate demands for comprehensive information about social-economic and governance conditions in combination with other land-related data [85]. They all contribute to the establishment of multifunctional information systems, incorporating, among others, structure and forms of land use, land tenure and land value, land development, and other useful data. The institutional evolution in the field of cadaster differs from one European country to another due to the influences of culture, history, economic environment, and social level [86].

Social expectations, associated with the institution of the cadaster, do not mean that this register actually fulfills the functions which are attributed to it. The quality of the data collected in the cadaster,

resulting both from the adopted formal and legal, and technological solutions, negatively verifies this assumption and, largely in its current shape, does not meet the expectations of society [87]. We often face the situation of inability to unambiguously identify the extent of the rights to cadastral parcels and the actual form of land use, which remains incomprehensible for the public and makes the institution of real estate cadaster lose its significance.

In Poland, there is now no significant political, social, or economic pressure to tidy up entries in the land registry system. The public good nature of a national land administration infrastructure is not fully understood by citizens. Meanwhile, a fully complete and up-to-date infrastructure for land administration would radically improve social inclusion by providing better awareness and service delivery for citizens [88]. The Polish state and quality of the data contained in the records of the land does not fully reflect the actual state, because the records are in most cases carried out in a passive way. This causes irreversible outdatedness of registration data, leading to a lack of credibility [56]. Recently, attempts have been made to assess the quality of registration data regarding the indication of indicators for assessing the quality of cadastral data at the local [89,90] and regional [91] levels.

The Polish land and building register is identified with a real estate cadaster, which was specified by Geodetic and Cartographic Law [92]. The method of establishing and keeping the land and buildings register is specified in the Regulation of the Minister of Regional Development and Construction [93]. The land and building register for Poland is an information system that provides the collection, updating, and sharing, in a uniform manner of information on land, buildings, and premises, their owners and other entities that own or manage these land, buildings, or premises [94].

2.6. Hypotheses

Summing up the conclusions of previous studies, the following hypotheses about the impact of various factors on differences between actual and evidenced forest cover can be stated:

Hypothesis 1 (H1). *The greater the anthropopression occurs, the greater chance of forest classification errors in the land registry is. In the areas where forest cover evidenced in the land registry is underestimated, susceptibility for recording forest areas as other land use forms in the land registry is stimulated by urbanization processes. Advance changes of the land registry are evidenced. On the other hand, urbanization processes in the areas where forest cover in land registry is overestimated are hypothesized to have negative impact on the difference between the actual and the evidenced forest cover. Adjustments of the land registry cannot keep up with real changes observed.*

Hypothesis 2 (H2). *The more developed the civic society institutions are, the better the control over the land registration records is expected. As a consequence, the discrepancies between the land registration records and the actual state should be smaller. Thus, within the areas characterized by the forest cover overestimated in the land registry, the influence of civic society development is expected to be positive. On the other hand, within the regions of underestimated forest cover in the land registry, the impact of civic society development should be negative.*

Hypothesis 3 (H3). *The better educated the society is, the better the control over the land registry records. As a consequence, the discrepancies between the land registry records and the actual state identified by remote sensing techniques application should be smaller. Thus, within the areas characterized by the overestimated forest cover in the land registry, the influence of education level of the society is expected to be positive. Consequently, within the areas of underestimated forest area in the land registry, the impact of education should be negative.*

Hypothesis 4 (H4). *The higher the percentage of forests managed by the State Forest is, the smaller the differences between the land registration records and the actual state. As a consequence, within the areas characterized by the overestimated forest cover in the land registry, the influence of percentage share of forests managed by the State Forest is expected to be positive. On the other hand, within the regions of underestimated forest cover, the impact of investigated determinant should be negative.*

Hypothesis 5 (H5). *The higher culture and quality of spatial planning is, the smaller the differences between the land registration records and the actual state. Hence, within the communes characterized by the overestimated land registry, the influence of culture and quality of spatial planning is hypothesized to be positive. Consequently, within the regions of underestimated forest cover in the land registry, the impact of the considered variable is expected to be negative.*

3. Methods and Data Collection

3.1. Research Design

The focus of this research was on identification of spatially varying social, demographic, and economic determinants of differences between forest identification based on remote sensing techniques and land registry (see Figure 1).

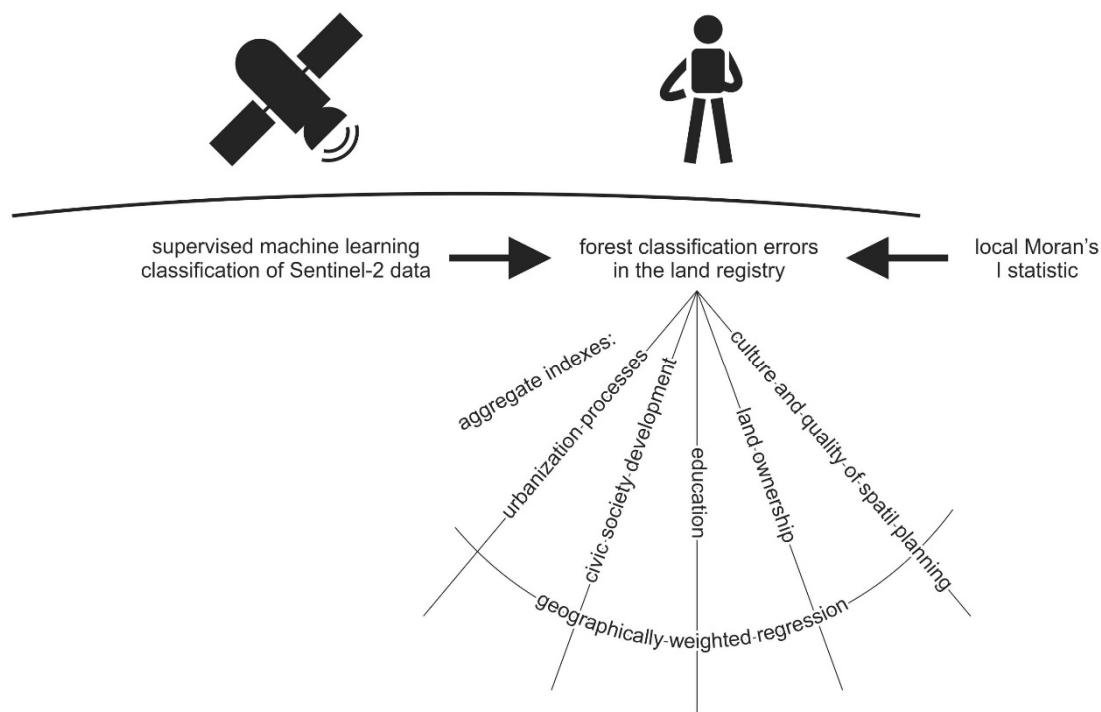


Figure 1. Methodological framework of the research on social, demographic, and economic determinants of forest classification errors in the land registry. Source: Own elaboration.

The research area covers the entirety of Poland divided into 2478 communes (NUTS-5 units). First, forest cover was detected by utilizing supervised machine learning classification of Sentinel-2 data in the year 2018. Then, the results were compared to forest cover reported in the land registry delivered in Local Data Bank by Statistics Poland. In consequence, forest classification errors in the land registry were identified and analyzed. Spatial analysis of forest classification errors included the local Moran's I statistic. Application of the mentioned statistic allowed to identify spatial clusters where forest cover in land registry is underestimated or overestimated. Finally, geographically weighted regression (GWR) was applied to estimate spatial patterns of impact of various social, demographic, and economic factors on occurrence of forest classification errors in the land registry. The following factors described by aggregate indexes were considered: Urbanization processes, civic society development, education, land ownership, and culture and quality of spatial planning.

3.2. Data Sources

Three different data sources were used to identify forest detection errors of land registry. On the one hand, data from land registry delivered in Local Data Bank by Statistics Poland and Head Office of Geodesy and Cartography were applied. On the other hand, the Database of Topographic Objects was used to prepare a forest detection machine learning classification model of Sentinel-2 data in the year 2018.

The data concerning forests defined as forest areas and land related to forest management of all ownership forms in 2018 for communes (NUTS-5 units) were obtained from Local Data Bank provided by Statistics Poland. The Sentinel-2 images were downloaded from Copernicus Open Access Hub. Sentinel-2 images used in the study were acquired from 20 April to 5 December 2018. The extended timespan was applied to acquire nonclouded satellite images, although materials with a maximum cloud coverage of 1% of images were also accepted. Sentinel-2 data bands: 4 (red), 3 (green), 2 (blue), and 8 (near infrared), all with a pixel resolution of 10 m, were combined into four-band rasters. The main source of forest spatial data was the Data Base of Topographic Objects valid for 2016, obtained from the Head Office of Geodesy and Cartography of Poland. This data covered the entire area of Poland and its accuracy corresponded to a map on a scale of 1:10,000 with a minimum area of land coverage patch of 0.1 ha. The information scope of the Data Base of Topographic Objects is based on three levels of detail. The database contains 9 object classes divided into 57 object categories, which contain 244 types of topographic objects. Two types of objects were used in the study—Forests and Coppices, belonging to the category of Forest and Wooded Areas, which are included in the Land Cover class of objects.

Separate process of data collection was conducted for variables describing social, demographic, and economic determinants of land registry errors: Urbanization processes, civic society development, education, land ownership, and culture and quality of spatial planning. Three following data sources were considered: Local Data Bank provided by Statistics Poland, the Database of Topographic Objects, and State Electoral Commission in Poland (see Table 1).

3.3. Methods of Analysis

There is strong evidence that automatic land cover classification is viable in terms of accuracy, cost, and time-efficiency. Several studies have confirmed that remote sensing can greatly benefit from utilizing modern methods offered by machine learning (ML), especially deep learning (DL), to tackle a wide range of problems related to processing satellite imagery. Among numerous examples, we can find successful attempts of crop types classification [95], utilizing DL in agriculture [96], urban land cover classification [97], and identifying land abandonment [98]. Thus, the use of machine learning in the context of forest areas detection in Poland is justified.

Semantic segmentation is a machine learning task of detecting a specific region of an image and assigning it a label to make this region distinguishable from different discovered regions and thus facilitating the process of image content interpretation. Segmentation, in terms of remote sensing and satellite imagery handling, is a process of classifying pixels, originating from satellite images, into categories representing, e.g., different land cover types. Due to high complexity of land cover features, size, and variety of information offered by satellite imagery, the task of training a model capable of determining belonging to a specific category should be considered nontrivial. Traditionally, such classification could be approached using classifiers such as Support Vector Machine (SVM) or Maximum Likelihood Classification (MLC). However, the above-mentioned classifiers lack accuracy and, what is equally important, the time needed to train a model based on them is far from desirable. On the contrary, classifiers based on convolutional neural networks (CNN) exhibit better performance than traditionally used SVM or MLC [99].

Table 1. Variables and measures related to various contexts of errors in the land registry in Poland.

Variable (Abbreviation)	Hypothesis	Measure	Data Source [2018]
Urbanization processes (URBAN)	H1	• Population density	BDL
		• Number of buildings per 1 km ²	BDOT
		• Number of NGOs per 10,000 population	BDL
Civic society development (CIVIC)	H2	• Number of club and artistic groups members operating per 10,000 population	BDL
		• Turnout in local government elections in 2018	PKW
Education (EDU)	H3	• Municipal expenditures on education per capita	BDL
		• Percentage of councilors with higher education in a commune	BDL
Land ownership (LDOWN)	H4	• Share of public forests managed by the State Forests	BDL
Culture and quality of spatial planning (SPPLAN)	H5	• Share of area covered by valid local spatial development plans	BDL

Source: Own elaboration. The following abbreviations describing data sources were used: BDL—Local Data Bank, BDOT—Database of Topographic Objects, PKW—State Electoral Commission in Poland.

There are multiple semantic segmentation models architectures available. In the preliminary study, covering 20% of original data, researchers tested four architectures: U-Net [100], FPN [101], Linknet [102], and PSPNet [103]. Among those U-Net and PSPNet were elected as architectures capable of reaching the highest intersection over union (IoU) scores (above 70%). After hyperparameter tuning, comparing the scores and manual checking visualized inference results PSPNet model was abandoned. This was mainly due to issues related in properly inferring the forest area boundaries. Therefore, the authors built a neural network model based on the U-Net architecture (see Figure 2). U-Net is especially well suited for semantic segmentation. It consists of two paths: Contracting and expansive. The contracting path follows the typical architecture of a convolutional network, that is, a repeated application of two convolutions. Every step in the expansive path consists of an upsampling of the feature map [100]. The basic building block of the U-Net architecture, a two-dimensional convolutional neural network layer, has been frequently used in remote sensing activities. CNN's main purpose is to extract from processed images common spatial features [104]. Those features can later be used in the inference phase to classify new images, i.e., describing them by relevant label or labels. The basic U-Net architecture has been adjusted to enable the processing of multiband satellite images. The adjustments were related to increasing the input size to treat images in RGB and near infrared channels, changing the kernel size from 3×3 to 5×5 , increasing the depth of the contraction phase and tuning relevant hyperparameters. The model was evaluated using a loss function being a sum of binary cross entropy loss and Jaccard index loss. The accuracy of the model was monitored using the IoU metric. The model has been implemented in Python using Tensorflow and Keras frameworks. Overall, the model reached a 0.765 IoU score, 0.867 f1-score, and 0.922 binary accuracy (pixel-wise) on the test set (5% of the dataset). For all of the mentioned metrics, a range from 0 to 1:0 means that the model is a complete failure, while 1 indicates a perfect model.

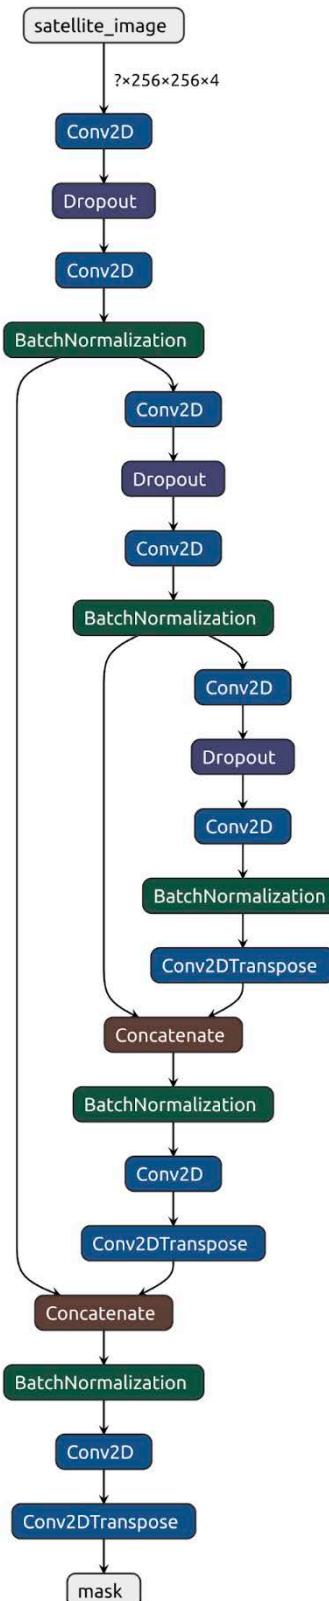


Figure 2. Simplified U-Net architecture applied in the research. Source: Own elaboration. Simplified U-Net architecture is composed of three conv2D + dropout blocks. Originally authors used a network that had six such blocks.

U-Net training phase requires a dataset composed of images and their segmentation maps (see Figure 3). Segmentation map holds information about interesting regions in the described image. There are multiple techniques of creating such regions, e.g., bounding boxes or polygons. Authors opted for masks. Mask is a grayscale image composed of pixels that correspond to a single input image. Each mask pixel value represents a different label. In case of this research, “1” was used to indicate that the pixel represents a forest and “0” otherwise.

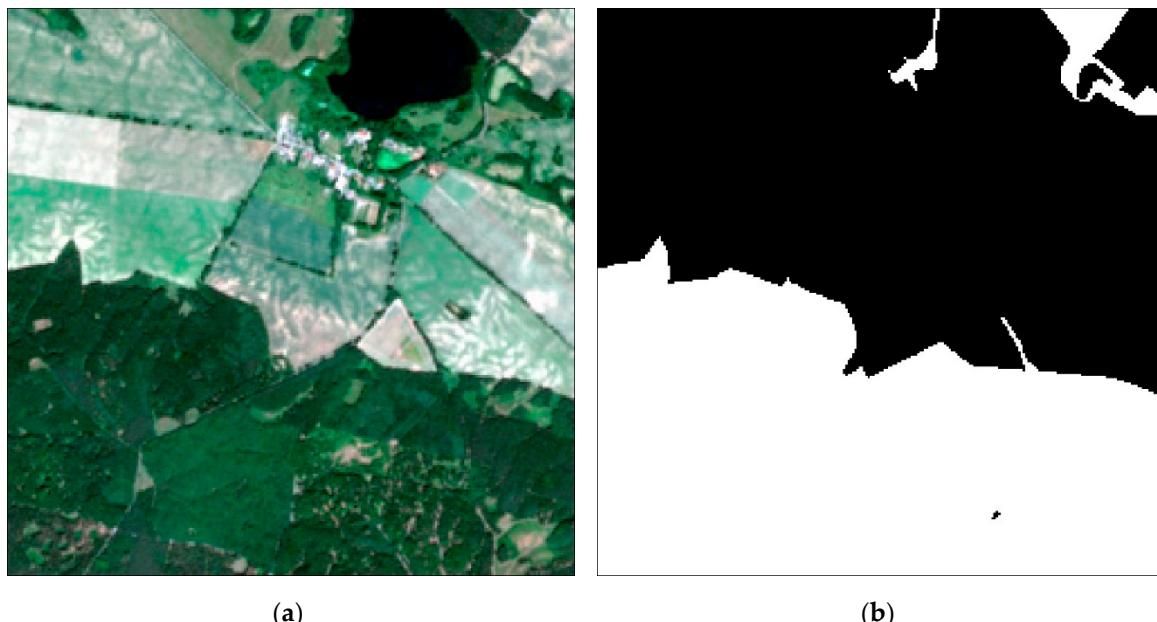


Figure 3. Example of image (a) and segmentation (b) map. Source: Own elaboration.

The results of supervised machine learning classification were aggregated to communes (NUTS-5 units), and then compared to data from land registry delivered in Local Data Bank by Statistics Poland. Forest cover (forest cover indicator), defined as the percentage ratio of the forest area to the total geodesic area of the commune, was calculated, and the forest areas in communes were analyzed for both types of data. The difference identified between forest cover indicators calculated based on application of remote sensing techniques and reported in the land registry was increased by 100% and defined as forest classification error of the land registry (FORESTCE). The dependent variable FORESTCE equals 100% when the results of remote sensing techniques application and land registry data are equal, exceeds 100% when forest cover identified by application of remote sensing techniques is larger than value recorded in land registry, and is lower than 100% when higher forest cover was reported in land registry compared to forest cover identified through remote sensing techniques application.

In the land registry, forest areas were defined as a homogeneous surface of at least 0.10 ha covered with forest vegetation like trees, bushes, and undergrowth (forested area), or temporarily devoid of it (nonforested area), but intended for forest production or being a nature reserve, a part of national park, or registered as nature monuments. The forest areas also included land connected with forest management, occupied by buildings and structures, water drainage facilities, forest spatial division lines, forest roads, areas under power lines, forest nurseries, wood storage facilities, and also forest car parks and tourist facilities [105,106]. The mask in supervised machine learning classification was representing forest defined as areas of at least 0.10 ha with a dense tree cover. These included forests, as well as other wooded areas, e.g., land adjacent to surface waters or recreational areas [107].

The method of land cover errors detection has some limitations. The first refers to the limitations of the remote sensing technique applied. It is the occurrence of cloud cover on satellite images, which disturb or prevent recognition of objects and data generation. It enforced the application of nonclouded satellite images coverage for the whole study area. The second limitation is the inconsistencies in the

definition of forest area, which may affect the occurrence of errors of land registry. Small systemic overestimation of forest cover in the land registry might be identified. However, the incompatibility concerns areas associated with forest production and management that are mostly spatially related to forest areas and did not affect the results of the analysis in the adopted scale of the study.

The spatial volatility of land registry errors was analyzed in detail. Spatial clusters of the investigated phenomenon were identified by calculating the local Moran's I statistic, the popular indicator of local spatial autocorrelation. This technique of exploratory spatial data analysis is based on analysis of the investigated phenomenon differing over space in every considered unit as well as in its surroundings [108]. The calculation of local Moran's I statistic in every j considered spatial unit should be expressed by the following equation [16,109]:

$$I_j = \frac{(\text{FORESTCE}_j - \overline{\text{FORESTCE}}) \cdot \sum_{i=1}^k w_{ij} (\text{FORESTCE}_i - \overline{\text{FORESTCE}})}{\sum_{i=1}^k (\text{FORESTCE}_i - \overline{\text{FORESTCE}})^2 / k} \quad (1)$$

where FORESTCE_j represents a value of forest classification errors in land registry identified in j commune, FORESTCE_i equals the value of the same variable in every i of k considered surrounding units, and w_{ji} is the element of weight matrix of neighborhood between communes j and i . Neighborhood is a dummy variable which takes "1" when j and i communes are identified as neighbors, and "0" otherwise [16,109]. When local Moran's I statistics range between 0 and +1, either high values (or low ones) are spatially clustered around a commune characterized by a similar value. The hot spot is identified when the high value is surrounded by high ones, and the cold spot when the low value is surrounded by low ones. On the other hand, when the considered statistics range between -1 and 0, the neighboring values are dissimilar to the value at the particular spatial unit. The spatial outlier is identified when the high value is surrounded by low ones, or the low value surrounded by high ones [108].

Aggregate indexes related to social, demographic, and economic determinants of land cover errors (urbanization processes, civic society development, education, land ownership, and culture and quality of spatial planning) were considered as independent variables. Each aggregate index equals the average of normalized values of measures describing each investigated determinant of land cover errors. It must be underlined that calculation of normalized values z based on real values x , depended on the contribution of particular measures to determinants, and was different for stimulants:

$$z = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \cdot 100\% \quad (2)$$

Compared to destimulants:

$$z = \left(1 - \frac{x - x_{\min}}{x_{\max} - x_{\min}}\right) \cdot 100\% \quad (3)$$

However, in this research, all considered measures had stimulus contributions to aggregate indexes, further investigated as independent variables. Aggregate index URBAN describing urbanization processes covers the stimulus contributions of both population density and the number of buildings per 1 km². The aggregate index CIVIC, referring to civic society development, consists of the following stimulus measures: Number of NGOs per 10,000 population, number of club and artistic groups members operating per 10,000 population, and turnout in local government elections in 2018. Then, the education (EDU) aggregate index includes stimulus measures of municipal expenditures on healthcare per capita, and percentage of councilors with higher education in a commune. The index LDOWN refers to land ownership and is equal to the normalized value of the share of public forests managed by the State Forests. Finally, the culture and quality of spatial planning (SPPLAN) is calculated as normalized share of area covered by valid local spatial development plans. The list of all measures

contributing to considered independent variables might be found in Table 1. However, limitations of using aggregate indexes should be emphasized. Most of all, selection of measures contributing to indexes could be contested. Moreover, aggregate indexes consider only quantitative information and might invite a simplistic image of investigated phenomena [110].

GWR was applied to explain spatially varying impact of various social, demographic, and economic determinants on investigated forest classification errors. However, GWR application should be preceded by Ordinary Least Square (OLS) modelling to identify global, spatially constant impact of investigated social, demographic, and economic factors on land registry errors [111]. Linear, global impact of considered determinants on investigated forest classification errors should be expressed as follows:

$$\text{FORESTCE} = \beta_0 + \beta_1 \cdot \text{URBAN} + \beta_2 \cdot \text{CIVIC} + \beta_3 \cdot \text{EDU} + \beta_4 \cdot \text{LDOWN} + \beta_5 \cdot \text{SPPLAN} + \varepsilon \quad (4)$$

where FORESTCE refers to forest classification errors identified in land registry. URBAN, CIVIC, EDU, LDOWN, and SPPLAN describe aggregate indexes characterizing various social, demographic, and economic factors influencing investigated land registry errors. In particular, the URBAN abbreviation refers to urbanization processes, CIVIC—civic society development, EDU—education, LDOWN—land ownership, and SPPLAN—culture and quality of spatial planning. Detailed characteristics of independent variables were presented in Table 1. Finally, β_0 refers to intercept, β_1 to β_5 refer to coefficients, and ε —to statistical bias.

GWR was successfully applied in various researches concerning land cover or land use, as well as its changes, impacts, and results. Brown et al. [111] tested the potential of the method in examining local variations of relationship between land cover, rainfall, and surface water habitat in southeast Australia. Spatial volatility of landscape fragmentation and its many different anthropogenic influences were investigated by enabling GWR for the case of Shenzhen City in China [112]. By GWR application, Leśniewska-Napierała et al. [16] described local spatial patterns of European Union funds impacts on land cover changes in Poland. Identification of driving forces of deforestation in the state of Mexico was enabled by the discussed method as well [2]. Shariff et al. [113] applied GWR to model urban land use changes in Penang Island in Malaysia. The discussed method allowed for the investigation of the spatially varying relation between groundwater quantity changes, and land use and land cover changes in the Khanmirza Plain of southwestern Iran [114]. GWR allowed Huang et al. [115] to identify the role of forest areas in decreasing water pollution in the urban sub-watersheds, which was more significant compared to rural ones.

In this research, GWR was designed to estimate local spatial patterns of various social, demographic, and economic impacts on errors of forest identification in land registry. The main goal of GWR application was to explore spatial variations in relationships between investigated variables [115]. Local models for every j Polish commune described by geographical coordinates Long, and Lat were estimated and analyzed. As a result, it was possible to identify the areas where forest classification errors were significantly influenced by each considered aggregate index referring to investigated social, demographic and economic factors. The mentioned spatially varying impact might be expressed as follows:

$$\begin{aligned} \text{FORESTCE}_j = & \beta_0(\text{Long}_j, \text{Lat}_j) + \beta_1(\text{Long}_j, \text{Lat}_j) \cdot \text{URBAN} + \beta_2(\text{Long}_j, \text{Lat}_j) \cdot \text{CIVIC} \\ & + \beta_3(\text{Long}_j, \text{Lat}_j) \cdot \text{EDU} + \beta_4(\text{Long}_j, \text{Lat}_j) \cdot \text{LDOWN} \\ & + \beta_5(\text{Long}_j, \text{Lat}_j) \cdot \text{SPPLAN} + \varepsilon \end{aligned} \quad (5)$$

The selection of neighboring spatial units to be included in estimation of local models in every j commune, weighted distance decay function (or kernel function), w , is applied to find the h bandwidth for every k commune spatially distributed around the j spatial unit [111,116]. Corrected Akaike information criterion was utilized to delimit the adaptive (smaller for dense located spatial units, and larger for sparse ones) bandwidth, offering a more desirable assessment than the fixed one [111,114]. Weight applied for each local model depends on the Euclidean distance d between the polygons'

centroids of considered j , and every k surrounding commune [112]. Weight of units located out of the bandwidth from considered commune is equal to zero [116,117]:

$$w_{jk} = \left(-\frac{d_{jk}^2}{h^2} \right)^e \quad (6)$$

The results of GWR implementation were presented on the following maps: (1) Map of local coefficients of determination—to identify goodness of fit of local models to empirical observations, (2) maps of values of estimated local parameters of independent variables—to identify spatial patterns of investigated social, demographic, and economic impacts on forest classification errors in land registry, and (3) maps of values of t-Student tests for mentioned parameters—to detect statistical significance of identified impacts [112,118,119].

4. Results and Discussion

4.1. Forest Cover

Based on data obtained as the result of supervised machine learning classification of Sentinel-2 satellite images, the forest cover of Poland was 32.8% (see Figure 4). The areas located in the center of Poland, including the south part of the Kuyavia-Pomerania province, north part of the Łódź province, Masovia, Greater Poland, and the Lublin province in the east, were characterized by less forest cover. The greater forest cover occurred in the north and west regions of Poland, especially in the Lubusz province, where forest cover was over 50% of its area.

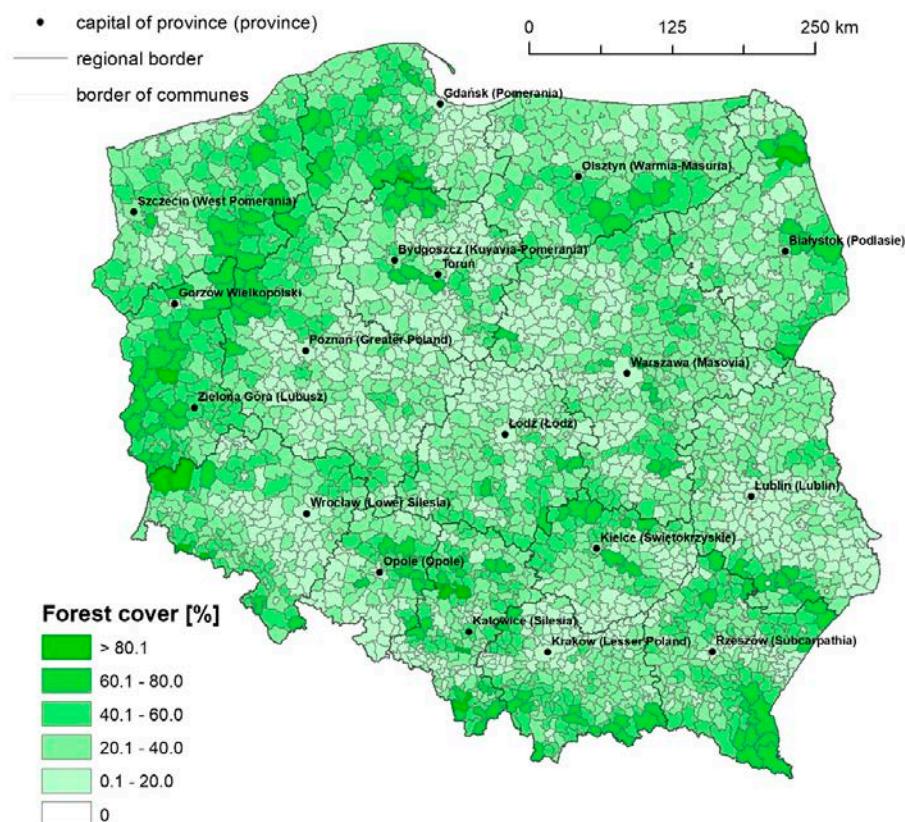


Figure 4. Forest cover of Poland in 2018 based on supervised machine learning classification of Sentinel-2 satellite images. Source: Own elaboration.

The forest cover analysis carried out for communes (NUTS-5 units) showed that average forest cover was characterized by high variability reaching 63.7%. A complete lack of forests (0.0% of forest cover), was found only for 4 out of 2478 communes. Communes with forest cover of 0.1–20.0% accounted for 36.0% of all. These communes were located mainly in the central part of Poland, but their clusters are also visible in the south and south-east of the country. A significant number of communes—37.5%—had forest cover in the range of 20.1–40.0%, whereas communes with forest cover of 40.1–60.0% constituted 19.4% of all analyzed units and were situated mainly in western and northern part of Poland. The percentage share of communes with significant forest cover of 60.1–80.0% was 6.3%. They stretched in the form of a strip from the south to west through the Lubusz province to the north through the West Pomerania and Pomerania province. Their cluster was also visible on the southeastern edges of the Subcarpathia province. Only 0.7% of communes had forest cover equal 80.1% or above. The largest forest cover of 95.1% was recorded for the Krupski Młyn commune located in the southern part of Poland (Silesia province).

4.2. Errors of Forest Identification in the Land Registry

The variable FORESTCE depicting forest classification errors in land registry was introduced based on relative comparison of both forest identification resulting from remote sensing techniques application and land registry analysis. It should be recalled that FORESTCE index equals 100% when the results of remote sensing techniques application and land registry data are equal, exceeds 100% when forest cover identified by application of remote sensing techniques is larger than value recorded in the land registry, and is lower than 100% when value of forest cover value is overestimated in the land registry.

The values of FORESTCE index for every particular commune in Poland are presented on Figure 5. It must be emphasized that in 70.7% of the investigated communes, the values of forest cover identified by remote sensing techniques application and reported in the land registry were similar, and the difference did not exceed 5%. Interestingly, the lowest value of FORESTCE index (52.5%) was evidenced in the Białowieża rural commune in the Podlasie province. In the mentioned commune, the forest area identified by remote sensing techniques covered only 39.9% of the investigated unit, while the forest cover reported in the land registry was 87.4%. This is the area on the edge of Białowieża Forest (UNESCO World Heritage Site), where controversial cutting of the stand on a large scale was reported in 2017. On the contrary, the largest value of FORESTCE index was diagnosed in the city of Łęknica in the Lubusz province, on the Polish-German border. It must be emphasized that the largest English-style landscape garden in Central Europe called Muskau Park (UNESCO World Heritage Site) is located in the mentioned city. Summarizing. On one hand, updating the land registry cannot keep up with the effects of forestry. On the other hand, the pretend forest is the category of land cover which might somehow affect the results of forest identification based on remote sensing techniques.

Applying local Moran's I statistics enabled identification of regions of spatial concentration of investigated forest classification errors in land registry. The results of spatial autocorrelation analysis are visualized on Figure 6. HH abbreviation refers to spatial clusters where forest cover in the land registry is underestimated. Four large spatial clusters, where identified forest areas exceed reported ones, should be emphasized: (1) Metropolitan area of Warsaw—the capital city of Poland; (2) a large and wide strip stretching from mountain areas in the southern part of Poland, covering Silesia province, western Lesser Poland, and the south part of the Łódź province; (3) mountain areas located in Lower Silesia province—one of the top tourist destinations in Poland; and (4) large area covering central-west part of Subcarpathia province, and the east edge of Lesser Poland.

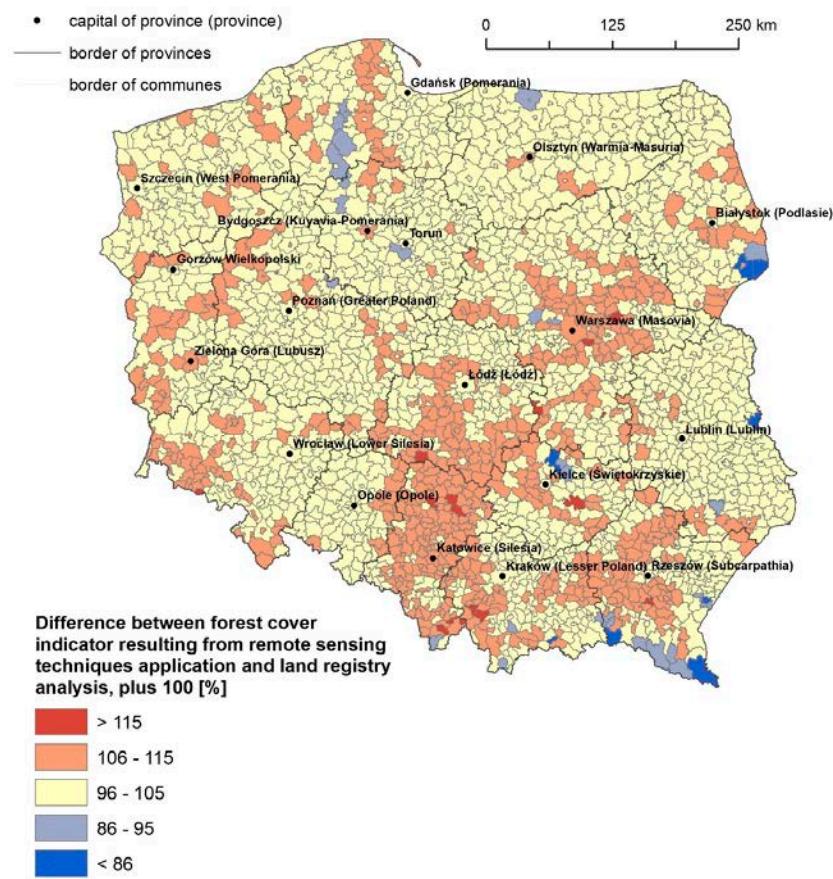


Figure 5. Forest classification errors in the land registry of Poland in 2018. Source: Own elaboration.

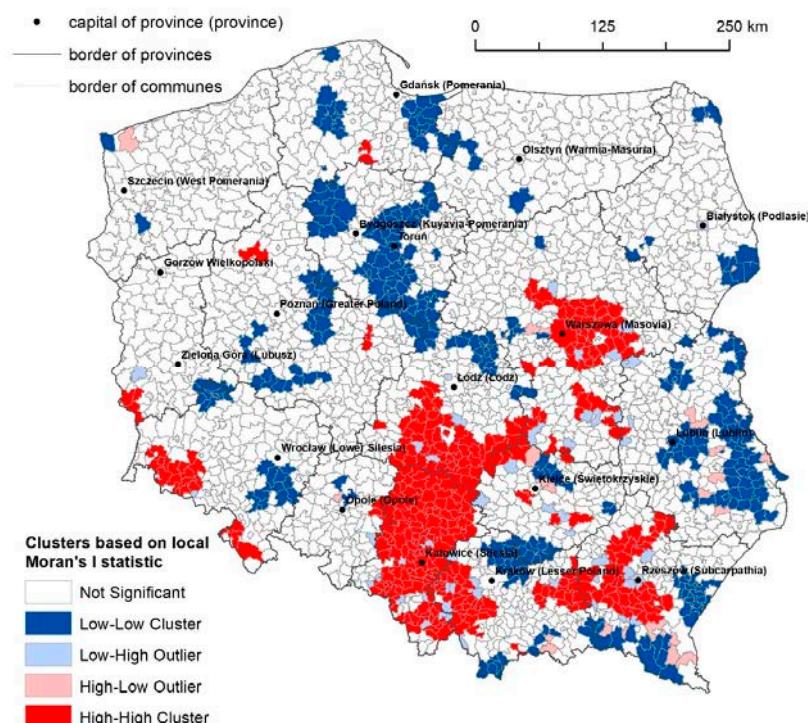


Figure 6. Spatial clusters of forest classification errors in the land registry of Poland in 2018. Source: Own elaboration.

On the other hand, LL describes spatial clusters where forest evidenced in land registry is larger than identified by remote sensing techniques application. The areas of spatial concentration of overestimated forest cover in the land registry are as follows: (1) Areas located in the trail of the violent gale that passed in August of 2017 over the provinces Greater Poland, Kuyavia-Pomerania, and Pomerania; (2) a wide strip stretching along the A1 and A2 highways starting from western edge of Warsaw metropolitan area, running latitudinally toward Łódź, and then longitudinally north, covering eastern parts of the provinces Kuyavia-Pomerania and Pomerania; (3) areas located on western edge of Białowieża Forest in the Podlasie province; and (4) the greater part of the Lublin province.

4.3. Determinants of Land Registry Errors

Urban performance, civic society development, education, and land ownership, as well as culture and quality of spatial planning, were introduced as aggregate indexes describing investigated social, demographic, and economic factors determining forest classification errors in the land registry of Poland. The descriptive statistics and global impact of the mentioned independent variables are presented in Table 2. It must be underlined that the global model estimated by applying OLS regression does not explain volatility of forest classification errors: The coefficient of determination was equal to 2.4%. However, all predictors but urbanization processes were recognized as statistically significant. Regarding the goal of this research, it must be underlined that spatially varying value and direction of impact of considered determinants of forest classification errors confirmed OLS as a completely ineffective method.

Table 2. Descriptive statistics and coefficients of global model estimating impact of aggregate indexes related to urbanization processes, civic society development, education, land ownership, and quality and culture of spatial planning on difference between actual and evidenced forest cover in Poland, in 2018.

Variable	Average	Standard Deviation	Minimum	Maximum	Coefficient	p-Value
FORESTCE	103.48	4.10	52.50	128.44	—	—
Intercept	—	—	—	—	103.703	→0
URBAN	4.24	5.07	0.02	65.90	-0.004	0.843
CIVIC	34.30	5.16	2.69	68.13	-0.033	0.036
EDU	26.63	10.75	1.67	73.33	0.033	→0
LDOWN	63.52	30.57	0.00	100.00	-0.005	0.080
SPPLAN	35.99	39.84	0.00	100.00	0.010	→0

Source: Own elaboration.

When analyzing models estimating the impact of particular factors (urbanization processes, civic society development, education, land ownership, and culture and quality of spatial planning) on the variable referring to forest classification errors, the main focus needs to be on the areas where the discrepancies between the land registry records and actual state identified by remote sensing techniques application are the largest. This means that both LL and HH clusters of FORESTCE variable need to be investigated with particular attention. Additionally, the greatest emphasis should be placed on areas where impact of particular factors is recognized as most significant. This means that t-Student values calculated for local coefficients describing impact of each separately discussed factor are expected to be equal or higher than 1.96.

A significant relation between urbanization processes and occurrence of forest classification errors was diagnosed in a few areas in Poland (see Figure 7). However, only in the Lublin province, the negative impact of urbanization corresponds to the spatial concentration of areas characterized by forest cover overestimated in the land registry. This is the only region where hypothesis H1 was confirmed. When considering this peripheral, relatively less developed region of Poland, it must be stated that the more intensive urbanization processes are, the bigger difference between actual

forest cover and reported one occurs. It should be emphasized that in less developed areas, local development policy stimulating urbanization processes does not respect land use planning. Actual deforestation carried out for the purposes of, e.g., developmental investment projects and initiatives, is not reflected in the land registry.

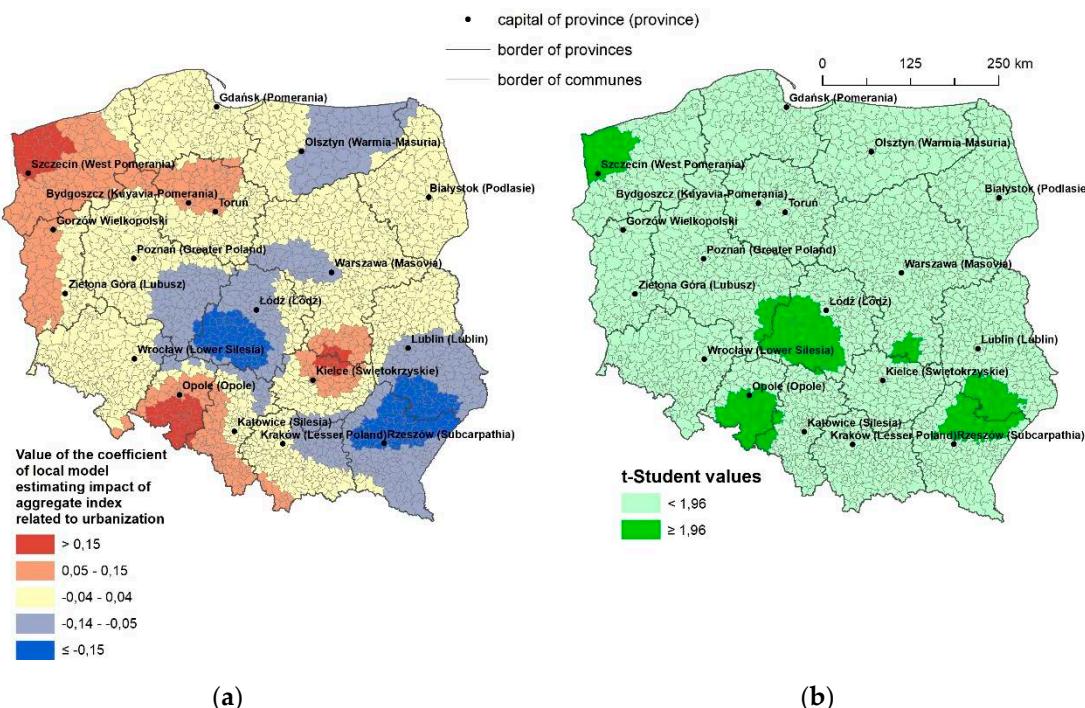


Figure 7. Value (a) and significance (b) of impact of urbanization processes on difference between actual and evidenced forest cover in Poland, in 2018. Source: Own elaboration.

The negative and significant impact of civic society development on the variable describing discrepancy between forest classification based on remote sensing techniques and forest cover reported in the land registry is evidenced in large areas in southeast and northeast part of Poland (see Figure 8). Moreover, in many border communes concentrated in the mentioned areas, the actual forest cover significantly exceeds the value reported in the land registry. This is contrary to hypothesis H2 and means that local civic societies are organized in opposition to state principles and institutions, including the land registry of Poland. Thus, the problem of inconsistencies in the development of borderland communities should be emphasized. It must be underlined that the land and building registry system should be re-engineered to better serve the needs of users, including citizens. As Williamson et al. [85] suggested, engagement of the society and good governance in decision-making and implementation is crucial. This requires building the necessary capacity in individuals, organizations, institutions and wider society so that they can perform their functions effectively, efficiently and sustainably. To provide spatial integrity of the cadaster and identification of every land parcel, it should be updated on a regular basis. In addition, a cadaster should ideally include all land in a jurisdiction: Public, private, communal, and open space.

The significant relation between education and land registry errors is evidenced in a strip covering the provinces of Lesser Poland, Silesia, and Łódź (see Figure 9). However, hypothesis H3, related to the impact of education level of the society on forest classification errors in the land registry, of Poland was confirmed only in the northeast part of the metropolitan area of Kraków in the Lesser Poland province. In the mentioned area, forest cover is significantly overestimated in the land registry. However, the increase of the education level of the society enables better understanding of the land registry importance. In consequence, it reduces the difference between actual and evidenced forest

cover. It can be concluded that the northeast part of the metropolitan area of Kraków is the only region in Poland where increasing education level of the society protects urbanized areas from overestimation of forest cover in the land registry. On the other hand, the results evidenced for the Silesia province and the south part of the Łódź province substantially contradict hypothesis H3. In these areas, the higher the education level of the society is, the greater the overestimation of forest cover in the land registry. Some indirect influence of education on the difference between actual and evidenced forest cover was expected. Moderating role of urbanization processes might be the explanation. However, GWR application does not enable analysis of indirect effects of investigated factors. Thus, in-depth analysis of the impact of education on forest classification errors in the Silesia province and the south part of the Łódź province is demanded.

The influence of share of public forests managed by the State Forests on forest classification errors in the land registry of Poland is presented in Figure 10. It needs to be emphasized that hypothesis H4 was confirmed for both areas characterized by significantly overestimated and underestimated forest cover in the land registry. Within the areas where actual forest cover is less than the evidenced one, the State Forests' policy and forest management was confirmed as a factor stimulating land registry update. The situation is evidenced in the Kuyavia-Pomerania and Pomerania provinces, as well as in small clusters of overestimated forest cover in the land registry detected in the West Pomerania province. Moreover, the Silesia province is the region where actual forest cover is larger than reported in the land registry. However, the investigated factor related to the land ownership was also confirmed as influencing the decrease of the difference between forest cover identified and evidenced. In contrary, the higher the percentage of forests managed by the State Forest in communes located on the western edge of the Białowieża Forest is, the bigger the differences between the land registration records and the actual state are. This confirms serious problems diagnosed in the eastern part of Poland, which the state-owned company managing forests have to face with.

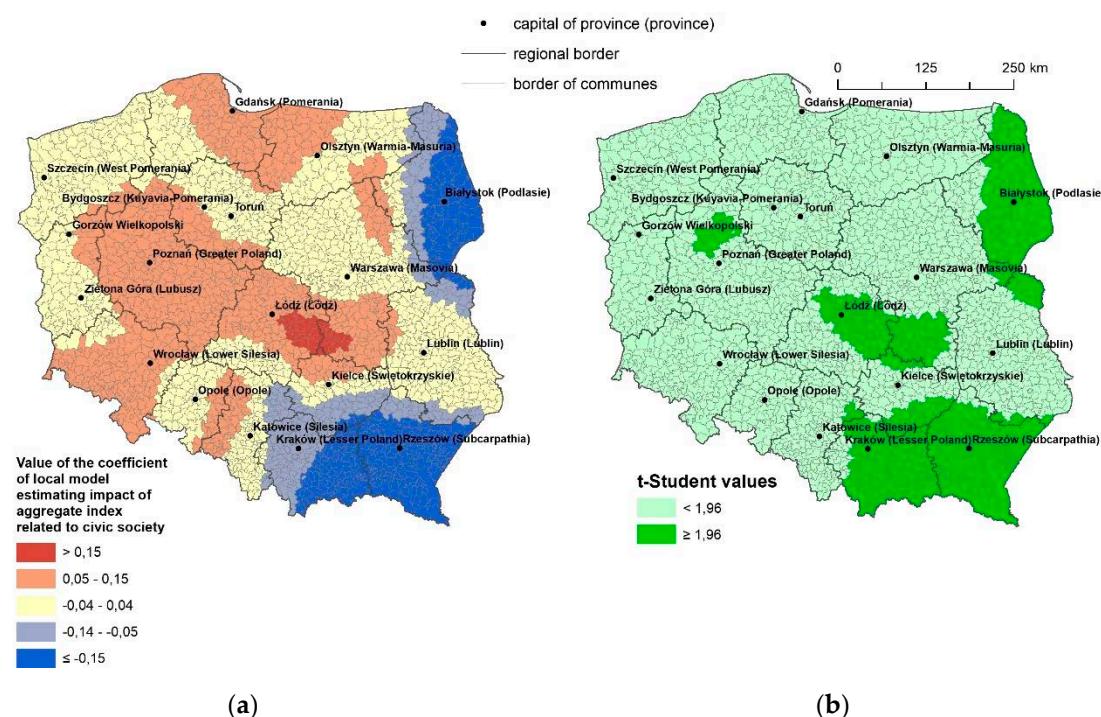


Figure 8. Value (a) and significance (b) of impact of civic society development on difference between actual and evidenced forest cover in Poland, in 2018. Source: Own elaboration.

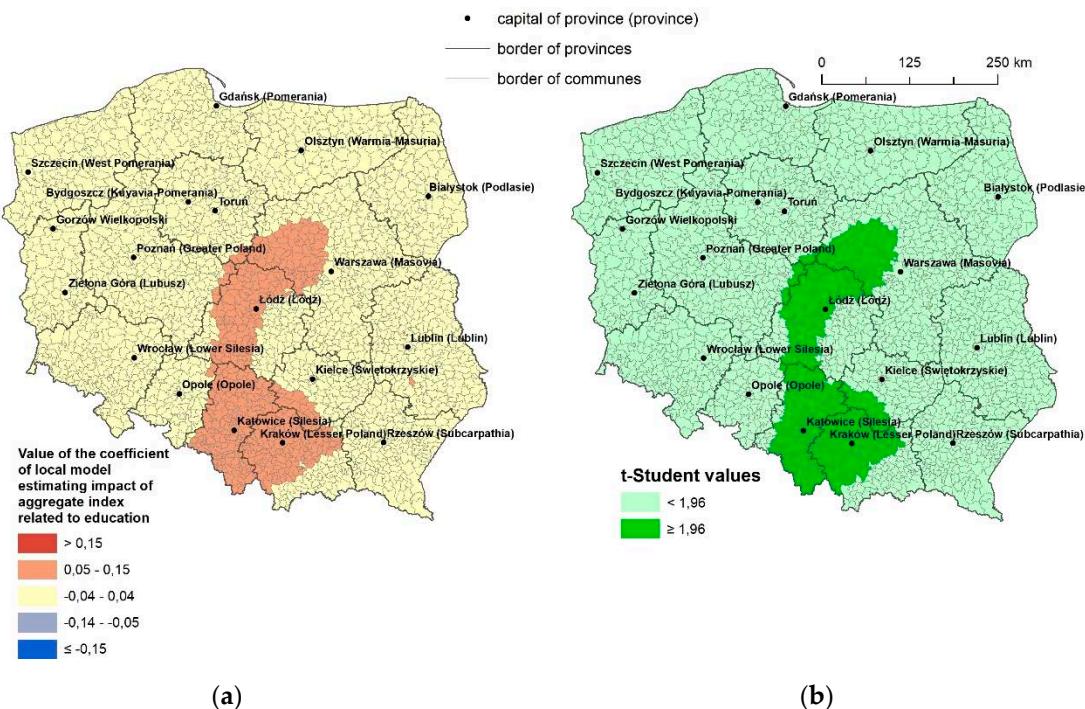


Figure 9. Value (a) and significance (b) of impact of education on difference between actual and evidenced forest cover in Poland, in 2018. Source: Own elaboration.

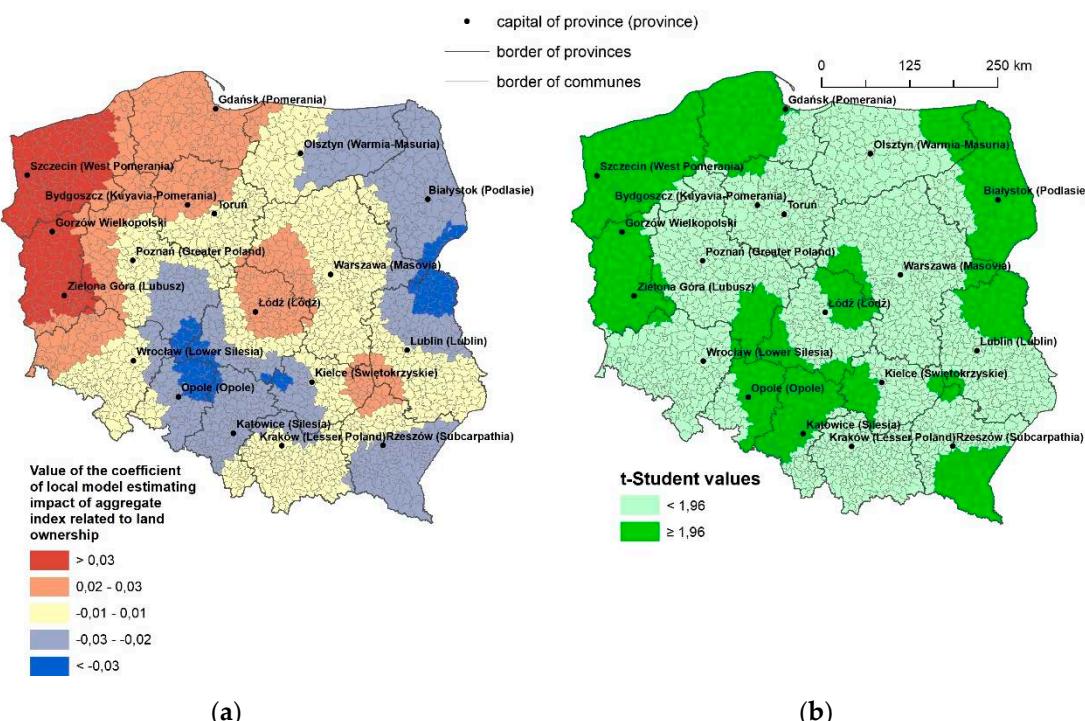


Figure 10. Value (a) and significance (b) of impact of land ownership on difference between actual and evidenced forest cover in Poland, in 2018. Source: Own elaboration.

The culture and quality of spatial planning was confirmed as the factor stimulating correction of the land registry data related to forest cover (see Figure 11). In particular, this is evidenced in both of the provinces of Kuyavia-Pomerania and Pomerania, where communes characterized by significant

overestimated forest cover in the land registry are clustered. The mentioned provinces were identified as the areas where hypothesis H5 was confirmed. On the other hand, higher coverage by valid local spatial development plans does not protect all Polish communes against forest classification errors in the land registry. The problem is evidenced both in areas characterized by significantly underestimated (the metropolitan area of Warsaw, and mountain area on the border of the Silesia and Lesser Poland provinces), as well as overestimated (communes on the Polish-Ukrainian border) forest cover in the land registry. This also means that using coverage by valid local spatial development plans as a measure of culture and quality of spatial planning has serious limitations.

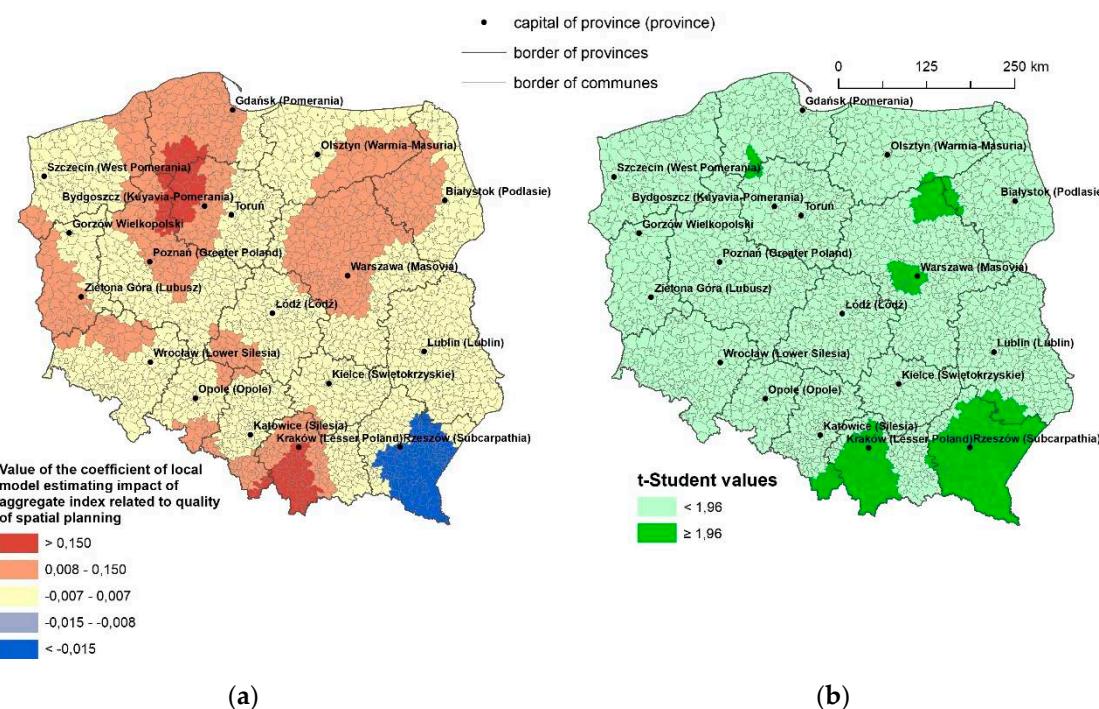


Figure 11. Value (a) and significance (b) of impact of quality and culture of spatial planning on difference between actual and evidenced forest cover in Poland, in 2018. Source: Own elaboration.

5. Conclusions

The goal of this paper relates to the social, demographic, and economic factors determining differences between forest identification based on remote sensing techniques and land registry. The combined application of the GWR method and local Moran's I statistics allowed the identification of regions where urbanization processes, civic society development, education level of the society, land ownership, and culture and quality of spatial planning affect the differences between actual forest cover and evidenced in the land registry. Spatial patterns of mentioned relations were diagnosed in areas where forest cover is over- or underestimated in the land registry.

It was confirmed that in less developed areas, local development policy stimulating urbanization processes does not respect land use planning principles, including accuracy of land registry. The problem of inconsistencies in the development of borderland communities was confirmed as local civic societies are frequently organized in opposition to state principles and institutions, including the land registry. The metropolitan area of Kraków was evidenced as the territory where the education level of the society protects from a substantial overestimation of forest cover in the land registry. Issues related to the land registry quality diagnosed in the eastern part of Poland, mainly on the western edge of the Białowieża Forest, needs to be solved mainly by the state-owned company managing forests. Finally, higher coverage by valid local spatial development plans stimulates protection against forest classification errors in the land registry for a limited number for Polish communes.

Author Contributions: Conceptualization, M.A., K.L.-N., M.N. and T.N.; methodology, M.A., K.L.-N., M.N. and T.N.; software, M.A. and M.N.; validation, K.L.-N., M.N. and T.N.; formal analysis, T.N.; investigation, K.L.-N. and M.N.; data curation, M.A., M.B. and M.N.; writing—original draft preparation, M.A., M.B., K.L.-N., M.N. and T.N.; writing—review and editing, K.L.-N. and T.N.; visualization, M.A., M.N., K.L.-N. and T.N. All authors have read and agreed to the published version of the manuscript.

Funding: This research received no external funding.

Acknowledgments: We give here our special thanks to Małgorzata Orzechowska and Maria Wąchal (SoftwareMill) for the linguistic support.

Conflicts of Interest: The authors declare no conflict of interest.

References

1. Boucher, Y.; Grondin, P.; Auger, I. Land use history (1840–2005) and physiography as determinants of southern boreal forests. *Landscape Ecol.* **2014**, *29*, 437–450. [[CrossRef](#)]
2. Pineda, J.N.B.; Bosque, S.J.; Gómez, D.M.; Franco, P.R. Exploring the driving forces behind deforestation in the state of Mexico (Mexico) using geographically weighted regression. *Appl. Geogr.* **2010**, *30*, 576–591. [[CrossRef](#)]
3. Hu, X.; Wu, Z.; Wu, C.; Ye, L.; Lan, C.; Tang, K.; Xu, L.; Qiu, R. Effects of road network on diversiform forest cover changes in the highest coverage region in China: An analysis of sampling strategies. *Sci. Total Environ.* **2016**, *565*, 28–39. [[CrossRef](#)] [[PubMed](#)]
4. Lossou, E.; Owusu-Prempeh, N.; Agyemang, G. Monitoring Land Cover changes in the tropical high forests using multi-temporal remote sensing and spatial analysis techniques. *Remote Sens. Appl. Soc. Environ.* **2019**, *16*, 100264. [[CrossRef](#)]
5. Bhugeloo, A.; Peerbhay, K.; Ramdhani, S.; Sershen. Tracking indigenous forest cover within an urban matrix through land use analysis: The case of a rapidly developing African city. *Remote Sens. Appl. Soc. Environ.* **2019**, *13*, 328–336. [[CrossRef](#)]
6. Gunggut, H.; Saufi, D.S.N.S.A.M.; Zaaba, Z.; Liu, M.S.-M. Where have All the Forests Gone? Deforestation in Land Below the Wind. *Proced. Soc. Behav. Sci.* **2014**, *153*, 363–369. [[CrossRef](#)]
7. Singh, M. Evaluating the impact of future climate and forest cover change on the ability of Southeast (SE) Asia’s protected areas to provide coverage to the habitats of threatened avian species. *Ecol. Indic.* **2020**, *114*, 106307. [[CrossRef](#)]
8. De Keersmaeker, L.; Onkelinx, T.; De Vos, B.; Rogiers, N.; Vandekerkhove, K.; Thomaes, A.; De Schrijver, A.; Hermy, M.; Verheyen, K. The analysis of spatio-temporal forest changes (1775–2000) in Flanders (northern Belgium) indicates habitat-specific levels of fragmentation and area loss. *Landscape Ecol.* **2015**, *30*, 247–259. [[CrossRef](#)]
9. Feranec, J.; Šuri, M.; Ot’ahel’, J.; Cebečauer, T.; Kolář, J.; Soukup, T.; Zdeňková, D.; Waszmuth, J.; Vâjdea, V.; Vîjdea, A.M.; et al. Inventory of major landscape changes in the Czech Republic, Hungary, Romania and Slovak Republic 1970s–1990s. *ITC J.* **2000**, *2*, 129–139. [[CrossRef](#)]
10. Skaloš, J.; Engstová, B.; Trpáková, I.; Šantrůčková, M.; Podrážský, V. Long-Term changes in forest cover 1780–2007 in central Bohemia, Czech Republic. *Eur. J. For. Res.* **2012**, *131*, 871–884. [[CrossRef](#)]
11. Wulf, M.; Sommer, M.; Schmidt, R. Forest cover changes in the Prignitz region (NE Germany) between 1790 and 1960 in relation to soils and other driving forces. *Landscape Ecol.* **2010**, *25*, 299–313. [[CrossRef](#)]
12. Jeon, S.B.; Olofsson, P.; Woodcock, C.E. Land use change in New England: A reversal of the forest transition. *J. Land Use Sci.* **2014**, *9*, 105–130. [[CrossRef](#)]
13. Di Fazio, S.; Modica, G.; Zoccali, P. *Evolution Trends of Land Use/Land Cover in a Mediterranean Forest Landscape in Italy BT—Computational Science and Its Applications—ICCSA 2011*; Murgante, B., Gervasi, O., Iglesias, A., Taniar, D., Apduhan, B.O., Eds.; Springer: Berlin/Heidelberg, Germany, 2011; pp. 284–299.
14. Puddu, G.; Falcucci, A.; Maiorano, L. Forest changes over a century in Sardinia: Implications for conservation in a Mediterranean hotspot. *Agrofor. Syst.* **2012**, *85*, 319–330. [[CrossRef](#)]
15. Borowska-Stefanśka, M.; Leśniewska-Napierała, K.; Wiśniewski, S. Land cover changes in Poland between 1990 and 2012. *Geografie* **2018**, *123*, 63–83. [[CrossRef](#)]
16. Leśniewska-Napierała, K.; Nalej, M.; Napierała, T. The Impact of EU Grants Absorption on Land Cover Changes—The Case of Poland. *Remote Sens.* **2019**, *11*, 2359. [[CrossRef](#)]

17. Kozak, J.; Estreguil, C.; Vogt, P. Forest cover and pattern changes in the Carpathians over the last decades. *Eur. J. For. Res.* **2007**, *126*, 77–90. [[CrossRef](#)]
18. Kozak, J.; Estreguil, C.; Ostapowicz, K. European forest cover mapping with high resolution satellite data: The Carpathians case study. *Int. J. Appl. Earth Obs. Geoinf.* **2008**, *10*, 44–55. [[CrossRef](#)]
19. Szymura, T.H.; Unajski, A.; Ruczakowska, A.M. Zmiany powierzchni lasów na obszarze Karkonoskiego Parku Narodowego w okresie 1747–1977 [Changes of forest cover in the Karkonosze National Park area in 1747–1977 period]. *Opera Corcon.* **2010**, *47*, 159–166.
20. Gielarek, S.; Klich, D.; Antosiewicz, M. Zmiany powierzchni leśnej w Bieszczadach Zachodnich w XIX i XX wieku [Forest cover change in Western Bieszczady Mts. in 19 th and 20 th century]. *Sylwan* **2011**, *155*, 835–842.
21. Nalej, M. Agricultural land cover changes in metropolitan areas of Poland for the period 1990–2012. *Misc. Geogr.* **2016**, *20*, 39–45. [[CrossRef](#)]
22. Fiedeń, Ł. Changes in land use in the communes crossed by the A4 motorway in Poland. *Land Use Policy* **2019**, *85*, 397–406. [[CrossRef](#)]
23. Pașca, A.; Năsui, D. The Use of CORINE Land Cover 2012 and Urban Atlas 2012 databases in agricultural spatial analysis. Case study: Cluj County, Romania. *Res. J. Agric. Sci.* **2016**, *48*, 314–322.
24. Vanonckelen, S.; Rompaey, A. Van Spatiotemporal Analysis of the Controlling Factors of Forest Cover Change in the Romanian Carpathian Mountains. *Mt. Res. Dev.* **2015**, *35*, 338–350. [[CrossRef](#)]
25. Gulinck, H.; Múgica, M.; De Lucio, J.V.; Atauri, J.A. A framework for comparative landscape analysis and evaluation based on land cover data, with an application in the Madrid region (Spain). *Landscape. Urban Plan.* **2001**, *55*, 257–270. [[CrossRef](#)]
26. Teixido, A.L.; Quintanilla, L.G.; Carreño, F.; Gutiérrez, D. Impacts of changes in land use and fragmentation patterns on Atlantic coastal forests in northern Spain. *J. Environ. Manag.* **2010**, *91*, 879–886. [[CrossRef](#)]
27. Valbuena-Carabaña, M.; de Heredia, U.L.; Fuentes-Utrilla, P.; González-Doncel, I.; Gil, L. Historical and recent changes in the Spanish forests: A socio-economic process. *Rev. Palaeobot. Palynol.* **2010**, *162*, 492–506. [[CrossRef](#)]
28. Verburg, P.H.; Neumann, K.; Nol, L. Challenges in using land use and land cover data for global change studies. *Glob. Chang. Biol.* **2011**, *17*, 974–989. [[CrossRef](#)]
29. Sylla, L.; Xiong, D.; Zhang, H.Y.; Bangoura, S.T. A GIS technology and method to assess environmental problems from land use/cover changes: Conakry, Coyah and Dubreka region case study. *Egypt. J. Remote Sens. Sp. Sci.* **2012**, *15*, 31–38. [[CrossRef](#)]
30. Ciupa, T.; Suligowski, R.; Wałek, G. Zmiany w zasięgu lasów w Górzach Świętokrzyskich w ostatnich 200 latach [Changes in forest coverage of the Holy Cross Mountains during last 200 years]. *Eduk. Biol. Sr.* **2016**, *4*, 16–23.
31. Schaefer, M.; Thinh, N.X. Evaluation of Land Cover Change and Agricultural Protection Sites: A GIS and Remote Sensing Approach for Ho Chi Minh City, Vietnam. *Heliyon* **2019**, *5*, e01773. [[CrossRef](#)]
32. Straume, K. The social construction of a land cover map and its implications for Geographical Information Systems (GIS) as a Management Tool. *Land Use Policy* **2014**, *39*, 44–53. [[CrossRef](#)]
33. Liu, Z.; Zhang, T.; Yu, J.; Zhou, L. Determinants of rural households' afforestation program participation: Evidence from China's Ningxia and Sichuan provinces. *Glob. Ecol. Conserv.* **2019**, *17*, 1–14. [[CrossRef](#)]
34. Patra, S.; Sahoo, S.; Mishra, P.; Mahapatra, S.C. Impacts of urbanization on land use /cover changes and its probable implications on local climate and groundwater level. *J. Urban Manag.* **2018**, *7*, 70–84. [[CrossRef](#)]
35. Śleszyński, P.; Gibas, P.; Sudra, P. The Problem of Mismatch between the CORINE Land Cover Data Classification and the Development of Settlement in Poland. *Remote Sens.* **2020**, *12*, 2253. [[CrossRef](#)]
36. Ünal, H.E.; Birben, Ü.; Bolat, F. Rural population mobility, deforestation, and urbanization: Case of Turkey. *Environ. Monit. Assess.* **2019**, *191*, 21. [[CrossRef](#)]
37. Alig, R. Urbanization in the US: Land use trends, impacts on forest area, projections, and policy considerations. *J. Resour. Energy Dev.* **2010**, *7*, 35–60. [[CrossRef](#)]
38. Cui, N.; Feng, C.-C.; Wang, D.; Li, J.; Guo, L. The Effects of Rapid Urbanization on Forest Landscape Connectivity in Zhuhai City, China. *Sustainability* **2018**, *10*, 3381. [[CrossRef](#)]
39. Sejati, A.W.; Buchori, I.; Rudiarto, I. The Impact of Urbanization to Forest Degradation in Metropolitan Semarang: A Preliminary Study. *IOP Conf. Ser. Earth Environ. Sci.* **2018**, *123*, 012011. [[CrossRef](#)]

40. De Clercq, E.M.; Clement, L.; De Wulf, R.R. Monte Carlo simulation of false change in the overlay of misregistered forest vector maps. *Landsc. Urban Plan.* **2009**, *91*, 36–45. [CrossRef]
41. Seebach, L.; Strobl, P.; Vogt, P.; Mehl, W.; San-Miguel-Ayanz, J. Enhancing post-classification change detection through morphological post-processing—A sensitivity analysis. *Int. J. Remote Sens.* **2013**, *34*, 7145–7162. [CrossRef]
42. Chmielewski, J. Problemy rozpraszania się zabudowy na obszarze metropolitalnym Warszawy [Problems of urban sprawl in the Warsaw metropolitan area]. *Urbanista* **2005**, *7*, 52–62.
43. Makowska-Iskierka, M. *Procesy Urbanizacyjne na Terenach Turystyczno-Wypoczynkowych Strefy Podmiejskiej Łodzi [The Urbanization Processes in the Tourist Destinations. Example of the Urban Fringe Zone of Łódź]*; Łódzkie Towarzystwo Naukowe: Łódź, Poland, 2011.
44. Janeczko, E.; Budnicka-Kosior, J.; Dąbrowski, R. The urbanisation processes and forest landscape on the example of the north part of the Mazowiecki Landscape Park (MPK). *Miškininkystė ir Kraštovarka. For. Landsc. Manag.* **2017**, *1*, 35–40.
45. Piussi, P. Expansion of European mountain forests. In *Forests in Sustainable Mountain Development: A State of Knowledge Report for 2000*; IUFRO Research Series 5; Price, M.F., Butt, N., Eds.; CABI Publishing: Wallingford, NY, USA, 2000; pp. 19–25.
46. Gray, J.; Lämmerhirt, D. Data and the city—How can public data infrastructures change lives in urban regions? *SSRN Electron. J.* **2019**. [CrossRef]
47. McDougall, K. *A Local-State Government Spatial Data Sharing Partnership Model to Facilitate Sdi Development*; University of Melbourne: Victoria, Australia, 2006.
48. Rajabifard, A.; Williamson, I.P. Spatial Data Infrastructures: Concept, SDI Hierarchy and Future Directions. In Proceedings of the Geomatics' 80 Conference, Teheran, Iran, 29 April–2 May 2001; Available online: <https://minerva-access.unimelb.edu.au/handle/11343/33897> (accessed on 18 June 2020).
49. Bernhard, M. Civil Society after the First Transition: Dilemmas of Post-communist Democratization in Poland and Beyond. *Communist Post Communist Stud.* **1996**, *29*, 309–330. [CrossRef]
50. Radzik-Maruszak, K.; Mieczkowska-Czerniak, K. From indifference to protest: Citizen activity at the local level in Poland. *Ann. UMCS Politol.* **2013**, *20*, 151–169.
51. Letki, N. Socialization for participation? Trust, membership, and democratization in east-central Europe. *Polit. Res. Q.* **2004**, *57*, 665–679. [CrossRef]
52. Kikosicka, K. Partycypacja społeczności lokalnej w planowaniu przestrzennym (przykład gminy Dąbrowice) [Local community participation in spatial planning (example municipalities Dąbrowice)]. *Acta Univ. Lodz. Folia Geogr. Socio Econ.* **2014**, *17*, 97–113.
53. Leśniewska-Napierała, K.; Napierała, T. Participatory budgeting: Creator or creation of a better place? Evidence from rural Poland. *Bull. Geogr. Socio Econ. Ser.* **2020**, *48*, 65–81. [CrossRef]
54. Rymarczyk, E.; Parzych, P.; Szabat-Precikowska, A. Problematyka funkcjonowania ewidencji gruntów i budynków z punktu widzenia organu ją prowadzącego [The issue of the functioning land and buildings registration from the conducting perspective]. *Infrastrukt. Ekol. Teren. Wiej.* **2012**, *1*, 85–96.
55. Wolny, B. Wybrane problemy aktualizacji danych ewidencji gruntów i budynków [Selected issues concerning updating of the register of lands and buildings]. *Prz. Geod.* **2005**, *77*, 14–17.
56. Noszczyk, T.; Hernik, J. Potrzeba czynnego prowadzenia ewidencji gruntów i budynków [The Necessity to Keep Land and Property Registers in an Active Manner]. *Infrastruct. Ecol. Rural. Areas* **2017**, *1*, 229–241. [CrossRef]
57. Steudler, D.; Williamson, I.P. Evaluation of national land administration system in Switzerland—Case study based on a management model. *Surv. Rev.* **2005**, *38*, 317–330. [CrossRef]
58. Walzer, M. *Toward a Global Civil Society*; Berghahn Books: Oxford, NY, USA, 1998.
59. Norris, P. *The Worldwide Digital Divide: Information Poverty, the Internet and Development*; Cambridge University Press: Cambridge, UK, 2000.
60. Jackson, G.; Perez-Diaz, V.M. *The Return of Civil Society: The Emergence of Democratic Spain*; Harvard University Press: Cambridge, MA, USA, 1993.
61. Seligman, A. *The Idea of Civil Society*; Free Press: New York, NY, USA, 1992.
62. Siemiński, W. Cele i zasady partycypacji społecznej w planowaniu przestrzennym—Przegląd literatury [Public participation in spatial planning as an element of city policy]. *Człow. Środowisko* **2007**, *40*, 77–93.

63. Kohler-Koch, B.; Quittkat, C. What is civil society and who represents civil society in the EU? Results of an online survey among civil society experts. *Policy Soc.* **2009**, *28*, 11–22. [CrossRef]
64. Banks, N.; Hulme, D. The Role of NGOs and Civil Society in Development and Poverty Reduction. *Brooks World Poverty Institute Working Paper*. 2012, p. 171. Available online: <https://ssrn.com/abstract=2072157> (accessed on 18 June 2020).
65. Healey, P. Planning through debate: The communicative turn in planning theory. *Town Plan. Rev.* **1992**, *63*, 143–162. [CrossRef]
66. Howe, J.; Langdon, C. Towards a Reflexive Planning Theory. *Plan. Theory* **2002**, *1*, 209–225. [CrossRef]
67. Strzelecki, A. The Development of Participation Budget in the Civic Society of Kujawsko-Pomorskie Voivodship. *Law Adm. Post Soviet Eur.* **2018**, *1*, 52–63. [CrossRef]
68. Leśniewska-Napierała, K. Budżet partycypacyjny jako narzędzie finansowania inwestycji w Łodzi [Participatory budget as a tool for financing investments in Łódź]. *Stud. Miej.* **2017**, *25*, 107–119. [CrossRef]
69. Pietraszko-Furmanek, I. *Partycypacja Społeczna w Środowiskach Lokalnych* [Public Participation in Local Communities]; Krakowskie Towarzystwo Edukacyjne: Krakow, Poland, 2012; ISBN 9788375712605.
70. Wendt, J.A. *Wymiar Przestrzenny Struktur i Aktywności Społeczeństwa Obywatelskiego w Polsce* [Spatial Aspect of the Structures and Activities of Civil Society in Poland]; IGiPZ PAN: Warsaw, Poland, 2007.
71. Tasaki, T.; Kameyama, Y. Sustainability Indicators: Are We Measuring What We Ought to Measure? *Glob. Environ. Res.* **2015**, *19*, 147–154.
72. Putnam, R.D. Social Capital: Measurement and Consequences. *Can. J. Policy Res.* **2001**, *2*, 41–51.
73. Balaceanu, C.; Apostol, D.; Penu, D. Sustainability and Social Justice. *Proced. Soc. Behav. Sci.* **2012**, *62*, 677–681. [CrossRef]
74. Woolcock, M.; Narayan, D. Social Capital: Implications for Development Theory, Research, and Policy. *World Bank Res. Obs.* **2000**, *15*, 225–249. [CrossRef]
75. Brodie, E.; Cowling, E.; Nissen, N.; Ellis Paine, A.; Jochum, V.; Warburton, D. *Understanding Participation: A Literature Review*; National Council for Voluntary Organisations: London, UK, 2009.
76. Grabowska, M.; Szawielski, T. *Budowanie Demokracji. Podziały Społeczne, Partie Polityczne i Społeczeństwo Obywatelskie w Postkomunistycznej Polsce* [Building Democracy. Social Divisions, Political Parties and Civil Society in Post-Communist Poland]; PWN: Warsaw, Poland, 2003.
77. Stewart, S.; Dollbaum, J.M. Civil society development in Russia and Ukraine: Diverging paths. *Communist Post Communist Stud.* **2017**, *50*, 207–220. [CrossRef]
78. Gumkowska, M.; Herbst, J.; Huszcz, J. *Społeczny Kontekst Rozwoju Ekonomii Społecznej w Polsce—Raport z Badania* [Social Context of the Development of the Social Economy in Poland—Research Report]; Fundacja Inicjatyw Społeczno-Ekonomicznych: Warsaw, Poland, 2006.
79. Czapinski, J.; Panek, T. *Social Diagnosis 2003*; Wyższa Szkoła Finansów i Zarządzania: Białystok, Poland, 2003.
80. Kalaitzidakis, P.; Mamuneas, T.P.; Savvides, A.; Stengos, T. Measures of human capital and nonlinearities in economic growth. *J. Econ. Growth* **2001**, *6*, 229–254. [CrossRef]
81. Janc, K.; Czapiewski, K. Wykształcenie czynnikiem wspierającym rozwój gospodarczy obszarów wiejskich [Education as a Factor Supporting the Economic Development of Rural Areas]. *Stud. Obsz. Wiejs.* **2005**, *8*, 69–84.
82. Brach, M.; Karaszkiewicz, W.; Olenderek, H. Nowa Koncepcja Określania Działki Ewidencyjnej dla Gruntów w Zarządzie PGL Lasy Państwowe [New Concept of Registered Parcel Determination for Areas in the Property of the State Forests National Forest Holding]. *Sylwan* **2015**, *159*, 883–892. [CrossRef]
83. Łuczyński, R. Technologiczne i prawne aspekty wznawiania oraz ustalania przebiegu granic działek ewidencyjnych [Technological and legal aspects of marking out and delimitation of borders of lands parcels]. *Acta Sci. Pol. Geod. Descr. Terr.* **2009**, *8*, 23–38.
84. Felcenloben, D. Granice działki ewidencyjnej desygnatem wiarygodności publicznej katastru nieruchomości—Propozycje zmiany obowiązującego modelu [Borders of a cadastral parcel as a qualifier of social reliability of a real estate cadastre—Proposals of modifications of]. *Prz. Geod.* **2010**, *82*, 9–13.
85. Williamson, I.P.; Enemark, S.; Wallace, J.; Rajabifard, A. *Land Administration for Sustainable Development*; Esri Press: New York, NY, USA, 2009.
86. Ghimbasan, A.C.; Vorovenciu, I. Situation of cadaster and land registry at european and national level. *Stud. Univ. Vasil. Gold. Stiint. Ing. Agro Tur.* **2017**, *12*, 27–32.

87. Busko, M.; Meusz, A. Current status of real estate cadastre in Poland with reference to historical conditions of different regions of the country. *Environ. Eng. Proc. Int. Conf. Environ. Eng. ICEE* **2014**, *9*, 1–8.
88. Bennett, R.; Rajabifard, A.; Williamson, I.; Wallace, J. On the need for national land administration infrastructures. *Land Use Policy* **2012**, *29*, 208–219. [[CrossRef](#)]
89. Felcenloben, D. Kryteria oceny jakości danych i informacji, gromadzonych i udostępnianych z katastru nieruchomości [Criteria for assessing the quality of data and information collected and shared from the real estate cadastre]. *Prz. Geod.* **2011**, *83*, 11–17.
90. Zwirowicz, K. Wybrane problemy ekonomiczno-techniczne wykorzystywania danych ewidencyjnych na potrzeby związane z użytkowaniem ziemi [Selected Economic and Technical Aspects of the Use of Cadastral Data for the Purpose of Land Use]. *Stud. Mater. Tow. Nauk. Nieruchom.* **2010**, *18*, 67–76.
91. Felcenloben, D. *Ocena Jakości Danych Ewidencyjnych Oraz Efektywności Funkcjonowania Katastru Nieruchomości* [Assessment of Registration Data Quality and the Efficiency of Functioning of the Real Estate Cadastre]; University of Environmental and Life Science: Wrocław, Poland, 2015.
92. Dz.U. 1989 nr 30 poz. 163, Ustawa z dnia 17 maja 1989 r. In *Prawo Geodezyjne i Kartograficzne* [Geodetic And Cartographic Law of 17 May 1989]; The President of the Council of Ministers: Warsaw, Poland, 1989.
93. Dz.U. 2001 nr 38 poz. In 454, *Rozporządzenie Ministra Rozwoju Regionalnego i Budownictwa z Dnia 29 Marca 2001 r. w Sprawie Ewidencji Gruntów i Budynków*; The President of the Council of Ministers: Warsaw, Poland, 2001.
94. Budkowski, S.; Litwin, U. Issue of quality and reliability of spatial records information in the context of data concerning boundary points. *Geomat. Landmanag. Landsc.* **2018**, *3*, 35–44. [[CrossRef](#)]
95. Kussul, N.; Lavreniuk, M.; Skakun, S.; Shelestov, A. Deep Learning Classification of Land Cover and Crop Types Using Remote Sensing Data. *IEEE Geosci. Remote Sens. Lett.* **2017**, *14*, 778–782. [[CrossRef](#)]
96. Kamaras, A.; Prenafeta-Boldú, F.X. A review of the use of convolutional neural networks in agriculture. *J. Agric. Sci.* **2018**, *156*, 312–322. [[CrossRef](#)]
97. Liu, C.; Zeng, D.; Wu, H.; Wang, Y.; Jia, S.; Xin, L. Urban Land Cover Classification of High-Resolution Aerial Imagery Using a Relation-Enhanced Multiscale Convolutional Network. *Remote Sens.* **2020**, *12*, 311. [[CrossRef](#)]
98. Krysiak, S.; Papińska, E.; Majchrowska, A.; Adamak, M.; Koziarkiewicz, M. Detecting Land Abandonment in Łódź Voivodeship Using Convolutional Neural Networks. *Land* **2020**, *9*, 82. [[CrossRef](#)]
99. Hu, Y.; Zhang, Q.; Zhang, Y.; Yan, H. A Deep Convolution Neural Network Method for Land Cover Mapping: A Case Study of Qinhuangdao, China. *Remote Sens.* **2018**, *10*, 2053. [[CrossRef](#)]
100. Ronneberger, O.; Fischer, P.; Brox, T. U-Net: Convolutional Networks for Biomedical Image Segmentation. *arXiv* **2015**, arXiv:1505.04597v1.
101. Lin, T.-Y.; Dollar, P.; Girshick, R.; He, K.; Hariharan, B.; Belongie, S. Feature Pyramid Networks for Object Detection. In Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, HI, USA, 21–26 July 2017; pp. 936–944.
102. Chaurasia, A.; Culurciello, E. LinkNet: Exploiting Encoder Representations for Efficient Semantic Segmentation. *IEEE VCIP* **2017**. [[CrossRef](#)]
103. Zhao, H.; Shi, J.; Qi, X.; Wang, X.; Jia, J. Pyramid Scene Parsing Network. *IEEE CVPR* **2017**. [[CrossRef](#)]
104. Mazzia, V.; Khalil, A.; Chiaberge, M. Improvement in Land Cover and Crop Classification based on Temporal Features Learning from Sentinel-2 Data Using Recurrent—Convolutional Neural Network (R-CNN). *Appl. Sci.* **2020**, *10*, 238. [[CrossRef](#)]
105. Dz.U. 1991 nr 101 poz. In 444, *Ustawa z Dnia 28 Września 1991 r. o Lasach* [Forest Act of 28 September 1991]; The President of the Council of Ministers: Warsaw, Poland, 1991.
106. *Rocznik Statystyczny Leśnictwa* [Statistical Yearbook of Forestry]; Główny Urząd Statystyczny [Statistics Poland]: Warsaw, Poland, 2018.
107. Dz.U. 2011 nr 279 poz. In 1642, *Rozporządzenie MSWiA z Dnia 17 Listopada 2011 r. w Sprawie Bazy Danych Obiektów Topograficznych Oraz Bazy Danych Obiektów Ogólnogeograficznych, a Także Standardowych Opracowań Kartograficznych*; The President of the Council of Ministers: Warsaw, Poland, 2011.
108. Majewska, J. Inter-Regional agglomeration effects in tourism in Poland. *Tour. Geogr.* **2015**, *17*, 408–436. [[CrossRef](#)]
109. Majewska, J.; Napierała, T.; Adamak, M. Wykorzystanie nowych technologii i informacji do opisu przestrzeni turystycznej [Using New Information and Communication Technologies for the Description of Tourism Space]. *Folia Tur.* **2016**, *41*, 309–339.

110. Saisana, M.; Tarantola, S. *State-Of-The-Art Report on Current Methodologies and Practices for Composite Indicator Development*; European Commission Joint Research Centre, Institute for the Protection and the Security of the Citizen Technological and Economic Risk Management Unit: Ispra, Italy, 2002.
111. Brown, S.; Versace, V.L.; Laurenson, L.; Ierodiaconou, D.; Fawcett, J.; Salzman, S. Assessment of Spatiotemporal Varying Relationships Between Rainfall, Land Cover and Surface Water Area Using Geographically Weighted Regression. *Environ. Model. Assess.* **2012**, *17*, 241–254. [[CrossRef](#)]
112. Gao, J.; Li, S. Detecting spatially non-stationary and scale-dependent relationships between urban landscape fragmentation and related factors using Geographically Weighted Regression. *Appl. Geogr.* **2011**, *31*, 292–302. [[CrossRef](#)]
113. Shariff, N.M.; Gairola, S.; Talib, A. Modelling urban land use change using geographically weighted regression and the implications for sustainable environmental planning. In Proceedings of the Modelling for Environment’s Sake: Proceedings of the 5th Biennial Conference of the International Environmental Modelling and Software Society, iEMSs 2010, Ottawa, ON, Canada, 5–8 July 2010; Available online: <https://scholarsarchive.byu.edu/cgi/viewcontent.cgi?article=2330&context=iemssconference> (accessed on 18 June 2020).
114. Taghipour Javi, S.; Malekmohammadi, B.; Mokhtari, H. Application of geographically weighted regression model to analysis of spatiotemporal varying relationships between groundwater quantity and land use changes (case study: Khanmirza Plain, Iran). *Environ. Monit. Assess.* **2014**, *186*, 3123–3138. [[CrossRef](#)]
115. Huang, J.; Huang, Y.; Pontius, R.G.; Zhang, Z. Geographically weighted regression to measure spatial variations in correlations between water pollution versus land use in a coastal watershed. *Ocean Coast. Manag.* **2015**, *103*, 14–24. [[CrossRef](#)]
116. Su, S.; Xiao, R.; Zhang, Y. Multi-Scale analysis of spatially varying relationships between agricultural landscape patterns and urbanization using geographically weighted regression. *Appl. Geogr.* **2012**, *32*, 360–375. [[CrossRef](#)]
117. Li, C.; Li, F.; Wu, Z.; Cheng, J. Exploring spatially varying and scale-dependent relationships between soil contamination and landscape patterns using geographically weighted regression. *Appl. Geogr.* **2017**, *82*, 101–114. [[CrossRef](#)]
118. Matthews, S.A.; Yang, T.C. Mapping the results of local statistics: Using geographically weighted regression. *Demogr. Res.* **2012**, *26*, 151–166. [[CrossRef](#)] [[PubMed](#)]
119. Mennis, J. Mapping the results of geographically weighted regression. *Cartogr. J.* **2006**, *43*, 171–179. [[CrossRef](#)]



© 2020 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0/>).

Publikacja nr 3:

Adamiak, M., Jaźdżewska I., Nalej M. (2021). *Analysis of Built-Up Areas of Small Polish Cities with the Use of Deep Learning and Geographically Weighted Regression*, *Geosciences*, 11(5), 223, <https://doi.org/10.3390/geosciences11050223>

MEiN: 70, CiteScore'21: 3,4.

Article

Analysis of Built-Up Areas of Small Polish Cities with the Use of Deep Learning and Geographically Weighted Regression

Maciej Adamiak ¹, Iwona Jaźdżewska ² and Marta Nalej ^{2,*}

¹ SoftwareMill, 02-791 Warsaw, Poland; maciej.adamiak@softwaremill.com

² Faculty of Geographical Sciences, University of Łódź, Kopcińskiego 31, 90-142 Łódź, Poland; iwona.jazdzewska@geo.uni.lodz.pl

* Correspondence: marta.nalej@geo.uni.lodz.pl; Tel.: +48-426-35-45-68

Abstract: Small cities are an important part of the settlement system, a link between rural areas and large cities. Although they perform important functions, research focuses on large cities and metropolises while marginalizing small cities, the study of which is of great importance to progress in social sciences, geography, and urban planning. The main goal of this paper was to verify the impact of selected socio-economic factors on the share of built-up areas in 665 small Polish cities in 2019. Data from the Database of Topographic Objects (BDOT), Sentinel-2 satellite imagery from 2015 and 2019, and Local Data Bank by Statistics Poland from 2019 were used in the research. A machine learning segmentation procedure was used to obtain the data on the occurrence of built-up areas. Hot Spot (Getis-Ord G^*) analysis and geographically weighted regression (GWR) was applied to explain spatially varying impact of factors related to population, spatial and economic development, and living standards on the share of built-up areas in the area of small cities. Significant association was found between the population density and the share of built-up areas in the area of the cities studied. The influence of the other socio-economic factors examined, related to the spatial and economic development of the cities and the quality of life of the inhabitants, showed great regional variation. The results also indicated that the share of built-up areas in the area of the cities under study is a result of the conditions under which they were established and developed throughout their existence, and not only of the socio-economic factors affecting them at present.



Citation: Adamiak, M.; Jaźdżewska, I.; Nalej, M. Analysis of Built-Up Areas of Small Polish Cities with the Use of Deep Learning and Geographically Weighted Regression. *Geosciences* **2021**, *11*, 223. <https://doi.org/10.3390/geosciences11050223>

Academic Editors: Elzbieta Bielecka, Małgorzata Luc and Jesus Martinez-Frias

Received: 29 March 2021

Accepted: 17 May 2021

Published: 20 May 2021

Publisher's Note: MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



Copyright: © 2021 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

Small cities are an important part of settlement systems. They are the glue that binds the network of villages, medium-sized cities, and large cities together. Small cities influence the level of local and regional development. They perform some of the functions necessary for rural areas (administrative, educational, commercial, service, cultural, etc.) and also provide facilities for large cities [1–4]. The term “small” in relation to a settlement unit recognized as a city varies from region to region or country to country. In China, this term is used for cities under 500,000 [5] or 100,000 inhabitants [6], in the United States, it is under 50,000 [7], while in developing countries it is between 5,000 and 20,000 [8], with local definitions also varying [9]. In Poland, cities with fewer than 20,000 inhabitants are considered small. The smallest Polish city (Wyśmierzyce) had 894 inhabitants in 2019 [10].

Some shortcomings with regard to small city studies were pointed out by Bell and Jayne [8] and Demazière et al. [11]. They noted the focus of researchers on big cities and metropolises while marginalizing small cities, the study of which is of great importance to progress in social sciences, geography, and urban planning. These authors also set out the direction that should be taken in small city research. In the transnational context, these included the ways in which small cities were linked in the international division of labor, the globalization of finance, and investment. On the other hand, in a local context, studies of small cities should address population, social dynamics, governance structure,

as well as their economic position and links with larger national centers. It is also important to understand the history, heritage, cultural life, values, and goals of small cities. The study of the physical structure of the landscapes and the spatial organization of small cities was mentioned as other much needed research directions.

Nowadays, sustainable development of small cities [12,13], smart cities [14], quality of life of inhabitants [15–17], demographic problems [18] are also discussed. Various indicators have been proposed to assess their sustainability: economic, social and environmental [19], historical [20,21], as well as aiming to implement the idea of smart sustainable cities. Studies of small cities are most often carried out on a regional or local scale, but there are also studies with a broader spatial scope, addressing the topic of small cities even on a continental basis [22–24].

There is also an increasing use of remote sensing data in urban research. They are most often the basis for obtaining land use/land cover (LULC) data using various classification methods. Satellite imagery from Landsat [25–33] is often used, as well as Sentinel [34–36] and others, such as Ziyuan 3-01 [37], IRS-1D [32], SPOT XS [38]. Other remote sensing data such as LIDAR (Light Detecting and Ranging) are also used [39]. Geographic Information System (GIS) [6,28,29,40–45] are equally frequently used. They are no longer just a tool to facilitate data management and mapping. Extensive GIS tools allow for efficient spatial analyses, including analysis of spatial patterns or modelling spatial relations using, for example, Hot Spot analysis (Getis-Ord G_i^*), or ordinary least squares (OLS) regression or Geographically Weighted Regression (GWR) [46–50].

Geographically Weighted Regression (GWR) was used to explain the influence of demographic, social, and economic conditions on the spatial variation of the share of built-up areas in the area of small cities in Poland. This method allows the estimation of local spatial patterns of the influence of different variables on the phenomenon under study and has been successfully applied in various urban studies [51]. Li et al. [46] used GWR to investigate the spatial heterogeneity of determinants of spatial structure fragmentation in 289 cities in China. A study of the spatial variability of the influence of different anthropogenic determinants of landscape fragmentation using GWR was conducted for Shenzhen City, Guangdong Province, China [52]. Ivajnščič et al. [50] used GWR for urban heat island (UHI) studies, to model the relationship between mean air temperature and influencing factors on the example of the small city of Ljutomer in Slovenia. Using GWR, Zhao et al. [49] examined the effects of five variables describing socio-demographic, economic, and spatial situations on the compactness of built-up areas in 160 Chinese cities. Royuela et al. [53] examined the impact of quality of life on urban sprawl. Using the example of Barcelona, Spain, they used GWR to assess how variables describing quality of life influence household location decisions. Bagan and Yamagata [54] analyzed the spatial-temporal expansion of urbanized areas in Japan between 1990 and 2006. They used GWR to model population density using the example of the city of Sapporo, Hokkaido, Japan. Noresah and Ruslan [55] used GWR to estimate the strength of the relationship between urban built-up areas and the factors, described by 20 variables, affecting their changes, for Sungai Petani city in Malaysia. This method was also used by Shariff et al. [56], to investigate the effects of variables describing environmental, physical, and socio-economic factors on urban land use change in Penang Island, Malaysia.

The history of Poland's small cities is varied and mostly dates back to the distant past. Some of the cities had important administrative functions in the past, which they lost over time to other more rapidly developing centers. This was particularly evident during the period of industrialization and the development of the transport network. Some of them are currently experiencing economic development and population growth, and many are now looking for new development factors [57–60]. For a large group of cities, stagnation or regression processes in the social, economic and spatial spheres are more characteristic [9,11,17,57,61]. The diversity and role of small cities in the settlement system make them a very interesting subject of research.

The main objective of the study was to undertake research on the impact of selected socio-economic factors on the share of built-up areas in small Polish cities and their spatial differentiation across the country. Based on literature review, various variables describing the determinants of the share of built-up land in the urban area were identified and used in the study of Polish small cities (Table 1).

Table 1. Description of determinants of built-up areas share in the area of small Polish cities in 2019.

Variable	Abbreviation	Measure [Unit]	Research Where the Variable Was Considered before
Population density	Pop_Density	persons/km ²	[7,19,62,63]
Newly built residential buildings	Buildings	number of buildings	[49,64,65]
Share of registered unemployed in the population of working age	Unemployment	% of unemployed	[19,57]
Share of working age population in % of total population	Work_Pop	% of population	[7,57,62]
Domestic economic entities newly registered in the REGON register	Enterprises	number of entities	[19,62,64]
Dwellings equipped with facilities (bathroom)—as % of total dwellings	Living_Standard	% of total number of dwellings	[16,66]

2. Materials and Methods

2.1. Study Area

The study area included small Polish cities. The area of Poland is 322,000 km². The capital and largest city is Warsaw. The population of Poland in 2019 was 38,253,955 [10], of which 60% lived in cities, and the number of administrative units defined as cities was 940. As many as 75% of these were small cities, i.e., those with fewer than 20,000 inhabitants. In the first two decades of the 21st century, the population of small cities in Poland fluctuated insignificantly, slightly exceeding 5 million people, which means that about 13% of Poles lived in small cities. Small cities can be found all over Poland and are quite evenly distributed, but there are areas where there are more of them, namely the central and southern parts of the country. In the study, small cities were defined as those units with a population of less than 20,000 inhabitants in 1999; a total of 665 cities were selected (Figure 1).

2.2. Data Sources

The study used data from three sources. Data from the Local Data Bank of Statistics Poland, the Central Office of Geodesy and Cartography, and The European Space Agency (ESA) were used. Sentinel-2 images were downloaded from the Copernicus Open Access Hub provided by ESA (<https://scihub.copernicus.eu> (accessed on 13 May 2021)). The images used were from 2015 and 2019, acquired between 1 April and 30 September each year. A wide timespan was used in order to acquire cloudless images, although images with 1–3% cloud cover were also accepted. Four Sentinel-2 channels: 4 (red), 3 (green), 2 (blue), and 8 (near infrared), with a resolution (ground sample distance, GDS) of 10 m were combined into four-channel rasters. The main source of data on built-up areas up to date for 2015 was the Database of Topographic Objects from the resources of the Central Office of Geodesy and Cartography. The thematic scope of the Database of Topographic Objects includes three levels of accuracy. The database contains nine object classes divided into 57 categories containing 244 types of topographic objects. Five object types were used in the study, representing different types of building objects, belonging to the category of built-up areas included in the Land Cover object class. The data of built-up areas were obtained with an accuracy corresponding to a map at a scale of 1:10,000 with a minimum patch area of 0.1 ha.

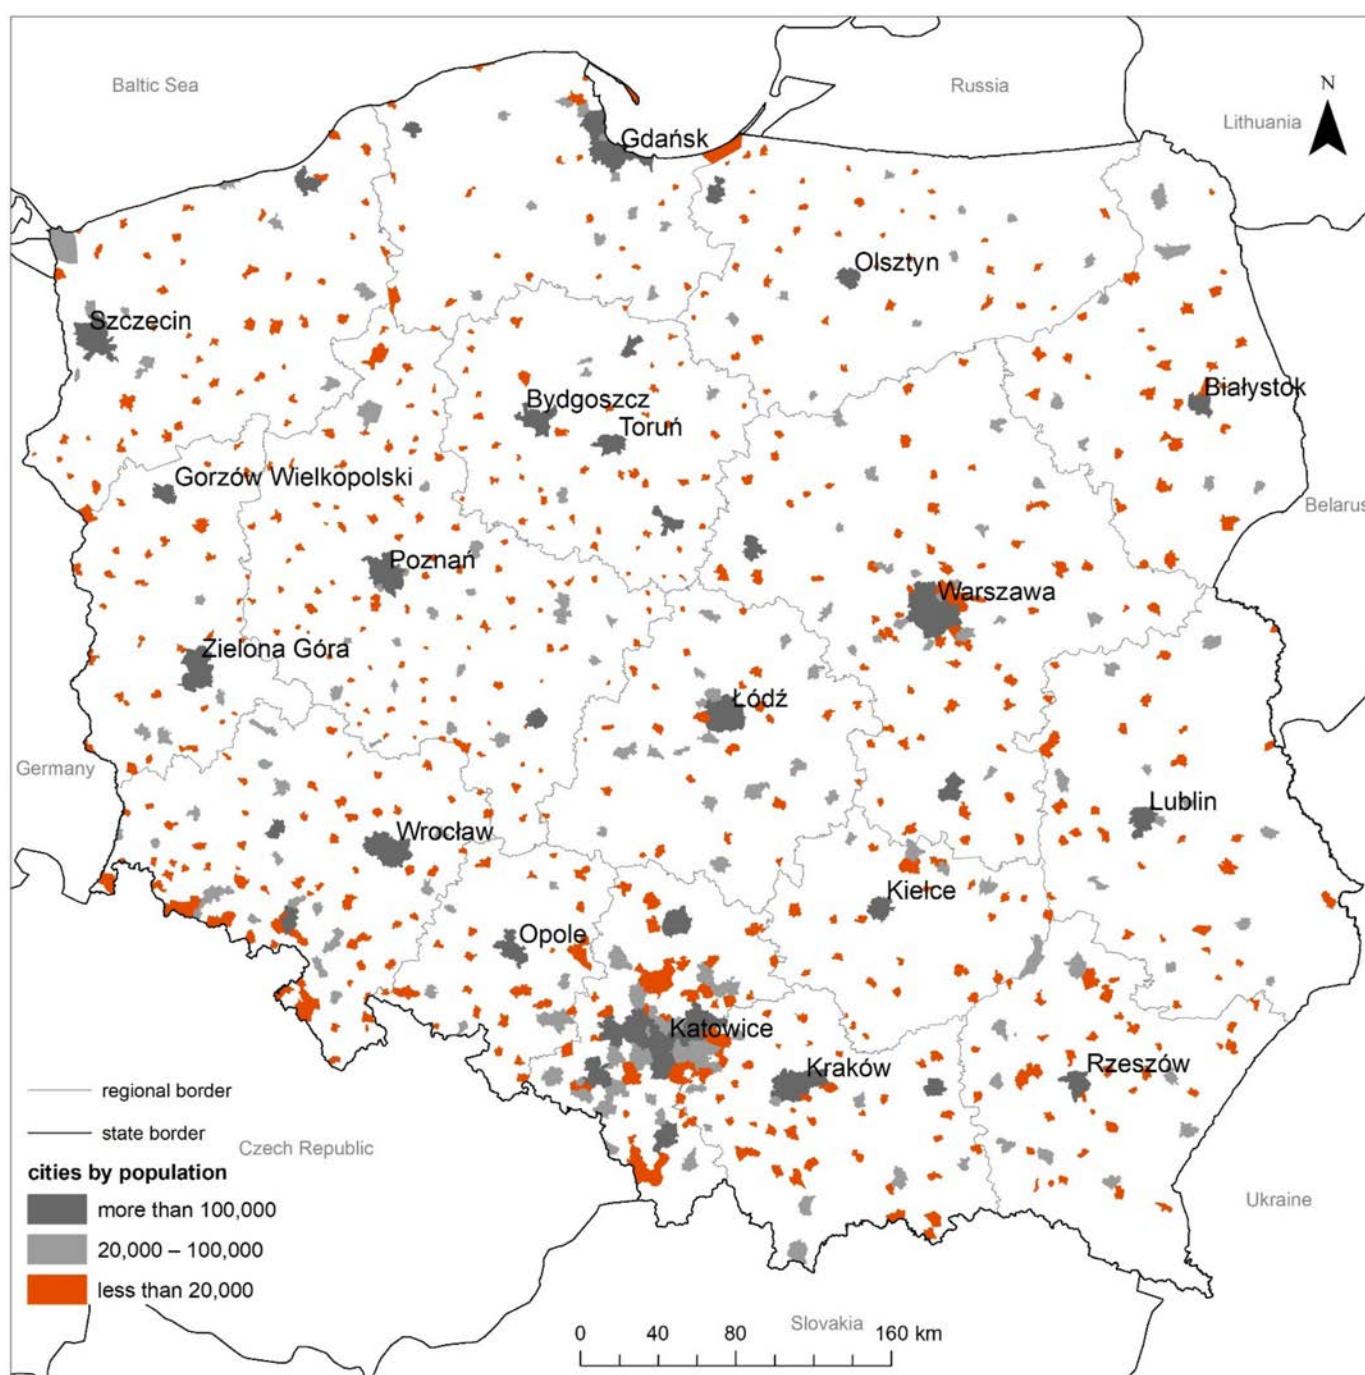


Figure 1. Cities in Poland by population in 1999 based on Head Office of Geodesy and Cartography (GUGiK) borders register and Statistics Poland data.

Socio-economic data were obtained from the Statistics Poland in MS Excel spreadsheet format. In Polish statistics, data for cities are collected and disseminated in the administrative division of Poland into municipalities. Some of the cities are separate municipalities, but a large group of them are parts of the so-called urban-rural municipalities. In such cases, much of the information is aggregated for the entire municipality, i.e., its rural and urban parts. For this reason, a limited amount of data exclusively applicable to small cities could be obtained for the study. Six variables were used, for which descriptive statistics were calculated (Table 2).

Table 2. Descriptive statistics for socio-economic data.

Socio-Economic Factors	Statistics			
	Minimum	Median	Average	Maximum
Pop_Density	11	607	721.4	3444
Buildings	0	8	13.7	364
Unemployment	0.3	4.3	4.6	12.0
Work_Pop	53.5	60.3	60.4	66.7
Enterprises	4	45	64.3	604
Living_Standard	69.1	93.8	92.4	99.7

2.3. Methods of Analysis

The share of built-up areas cover within a given spatial unit area was calculated with the use of Sentinel-2 satellite images. In the first stage, a machine learning model was used to perform semantic segmentation and delineate built-up land cover. Then the obtained results were aggregated to the borders of the cities.

Semantic segmentation is a machine learning task of detecting a specific region of an image and assigning it a label to make this region distinguishable from different discovered regions and thus facilitating the process of image content interpretation [67]. Segmentation, in terms of the presented research, is a process of classifying pixels, originating from Sentinel-2 satellite images, into two categories representing built-up areas and other land cover types (Figure 2). The mask in supervised machine learning classification was representing built-up areas created by residential and industrial buildings, warehouse, agricultural production buildings, etc., together with small areas and devices, functionally related to buildings—such as yards, squares, court-yards, passages, crossings, home playgrounds, etc. [68].

The machine learning pipeline was prepared to support DeepLabV3+ [69] model using the Xception [70] backbone. The model has been implemented in Python 3.7 using Tensorflow 2.2.0 [71] and Keras 2.3.1 [72] frameworks. DeepLabV3+ is a deep convolutional neural network architecture characterized by its outstanding capabilities to handle the problem of segmenting objects at multiple scales by designing its main modules to capture multi-scale context. The use of other machine learning model architectures was also considered. During preliminary studies, such solutions as U-Net [73], FPN [74], and PSPNet [75] were tested but they showed less effectiveness than DeepLabV3+.

The model was trained using a loss function being a sum of binary focal loss [74] and Jaccard index loss [76]. During the process of model training, only the 2015 dataset was utilized. The 2015 dataset was the only one containing the area of the whole country and success in its correct segmentation was necessary to achieve satisfactory results in the 2019 dataset. The 2015 dataset was split into three subsets. The first subset intended for training accounted for 90% of the dataset. Validation subset was formed using 5% of the dataset. The main purpose of the validation subset was measuring the performance during intermediate training steps and for early stopping. Test data used during final model evaluation accounted for 5% of each set for 2015 and 2019. The accuracy of the model was monitored using the intersection over union (IoU), f1-score, pixel-wise binary accuracy, precision, and recall metrics. Foreground to background threshold was set to 0.5, meaning probability map values above 0.5 will be treated as built-up areas. Summary of evaluation on all datasets is presented in Table 3. Score values were calculated in relation to the ground truth segmentation mask, which had some flaws the model had to deal with. Although, the dataset used to produce segmentation maps is the largest and most precise source of information on built-up areas available in Poland, it is not free from defects. During careful analysis, one can discover that in multiple areas the delineated regions are visibly under or oversegmented. These issues were mitigated by crafting a model that is able to generalize well-enough to make the segmentation smoother. Overall, the model achieved satisfactory results, which was also indicated by the results of the perceptual evaluation.



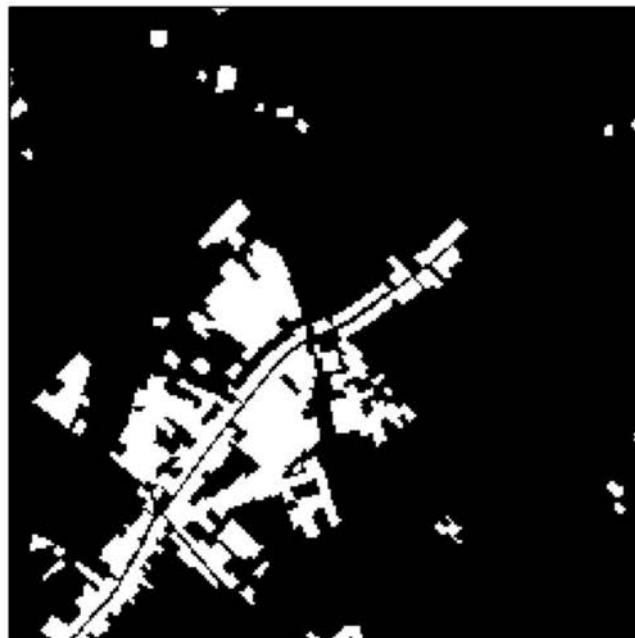
(a)



(b)



(c)

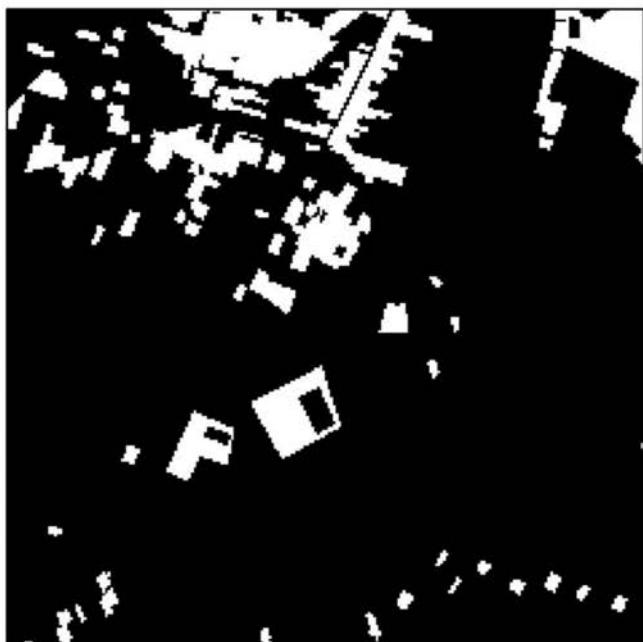


(d)

Figure 2. Cont.



(e)



(f)



(g)



(h)

Figure 2. *Cont.*

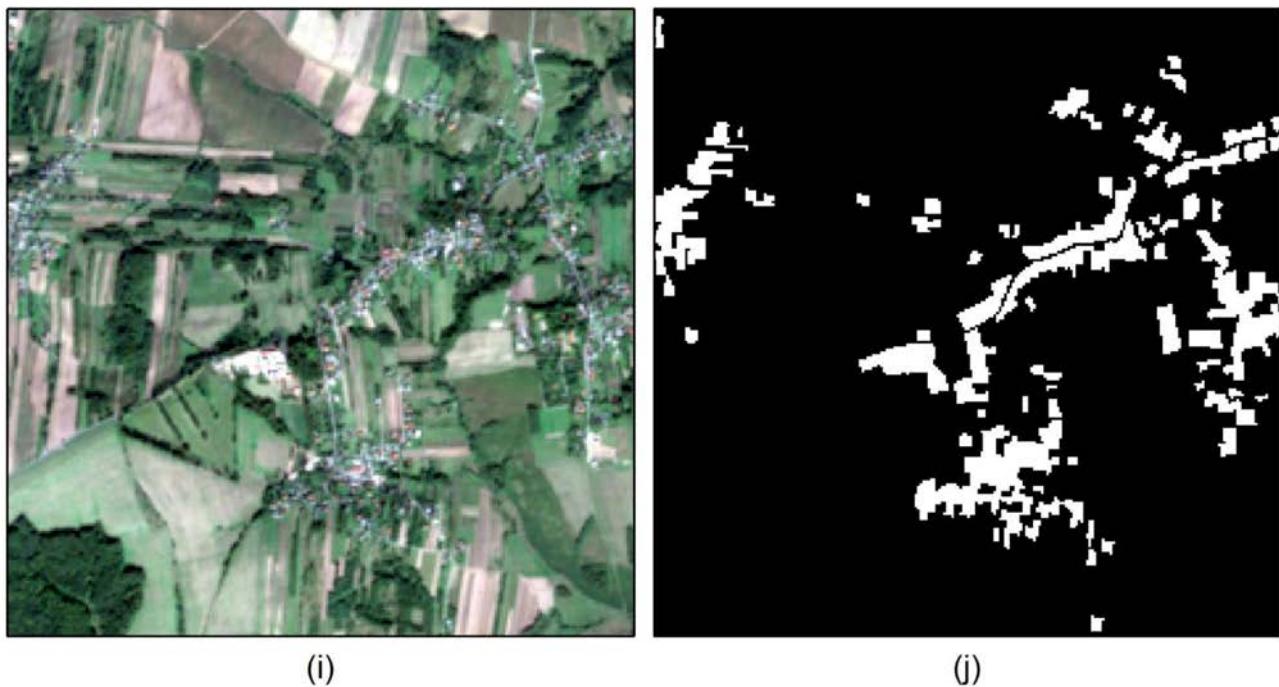


Figure 2. Examples of images (**a,c,e,g,i**) and segmentation maps (**b,d,f,h,j**).

Table 3. Summary of urban land cover semantic segmentation model evaluation on 2015 and 2019 datasets.

Dataset	IoU	F1-Score	Binary Accuracy	Precision	Recall
2015	0.548	0.708	0.979	0.693	0.726
2019	0.588	0.741	0.963	0.679	0.814

It should be noted that the limitation of using the machine learning method to obtain data on built-up areas is the occurrence of cloud cover in satellite images used as source materials. The presence of cloud cover may limit or prevent the recognition of objects. However, the selection of cloudless satellite images or the use of cloud removal techniques makes this limitation quite easy to overcome [77–79].

The spatial diversity of cities in terms of the share of built-up areas in their area was analyzed using Geographic Information Systems (GIS) tools available in ArcGIS 10.7 software. Hot spot analysis using the Getis-Ord G_i^* statistic was applied first [80–82]. It allows for finding statistically significant clusters of high (hot spots) and low values (cold spots) and is expressed by the formula:

$$G_i^* = \frac{\sum_{j=1}^n w_{i,j} x_j - \bar{X} \sum_{j=1}^n w_{i,j}}{S \sqrt{\frac{[n \sum_{j=1}^n w_{i,j}^2 - (\sum_{j=1}^n w_{i,j})^2]}{n-1}}} \quad (1)$$

where x_j is the attribute value for feature j , $w_{i,j}$ is the spatial weight between feature i and j , n is equal to the total number of feature and:

$$\bar{X} = \frac{\sum_{j=1}^n x_j}{n}, \quad (2)$$

$$S = \sqrt{\frac{\sum_{j=1}^n x_j^2}{n} - (\bar{X})^2} \quad (3)$$

The Getis-Ord G_i^* local statistic score for each trait in the data set is the z-score. The occurrence of statistically significant positive z-scores indicates a hot spot. The larger

the z-score, the more intense the clustering of high values. For statistically significant negative z-scores, there is a cold spot, the lower the score, the more intense the clustering of low values.

The use of GWR in the study was preceded by Ordinary Least Square (OLS), which aimed to identify the global spatially continuous influence of demographic, social, and economic factors on the share of built-up areas in the surface of small cities in Poland [49,83]. The OLS model is expressed as follows:

$$y_i = \beta_0 + \sum_{j=1}^n \beta_j x_{ij} + \varepsilon_i, \quad (4)$$

where y_i is the observation of the dependent variable at location i , β_0 is a constant term, and β_j measures the relationship between independent variable x_{ij} and y for the set of i locations. ε_i is the error associated with location i .

GWR is an extension of global regression models and allows the estimation of local influences of demographic, social, and economic factors on the share of built-up area in small cities in Poland, the examination of spatial relationships between variables in the model and the identification of patterns [84–86]. The GWR model is expressed as follows:

$$y_i = \beta_0(u_i, v_i) + \sum_{j=1}^n \beta_j(u_i, v_i)x_{ij} + \varepsilon_i \quad (5)$$

where y_i is the dependent variable, i represents regions of the study area, (u_i, v_i) denotes the location of i observed region, $\beta_j(u_i, v_i)$ indicates the j regression parameter at the location of observation i , which is a function of the geographical position, x_{ij} is the independent variable, and ε_i is the random error of i region.

The results of GWR application were presented on a map showing the coefficient of determination describing the compatibility of local models with empirical observations and on maps estimating the values of the influence of local parameters of independent variables on the share of built-up area in the area of small cities in Poland and the significance of the identified impacts [87,88].

The procedure of data preparation and the processing steps were summarized in a schematic workflow given in Figure 3.

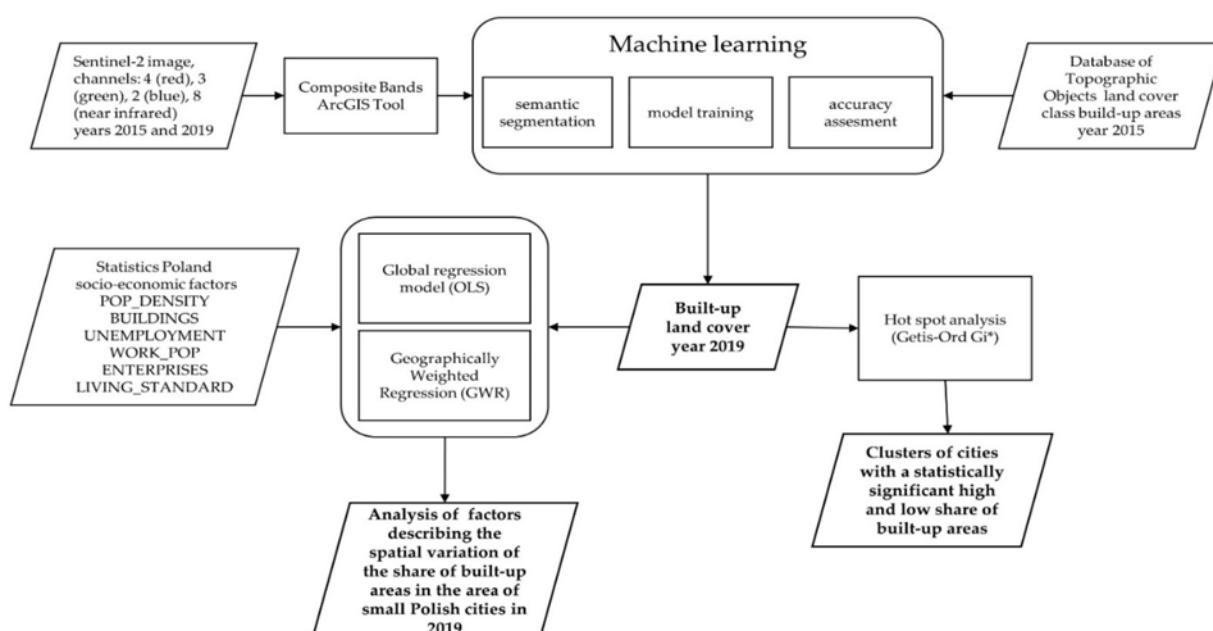


Figure 3. Methodology flowchart for analysis of built-up areas of small Polish cities in 2019 with the use of deep learning and geographically weighted regression.

3. Results

3.1. Share of Built-Up Areas in the Area of Small Cities in Poland in 2019

Based on the data obtained as a result of machine learning segmentation of Sentinel-2 satellite images, the acreage of build-up areas was calculated for each city (Figure 4). Built-up areas were related to the area of each city within the administrative borders and the share of built-up areas in the urban area was determined.

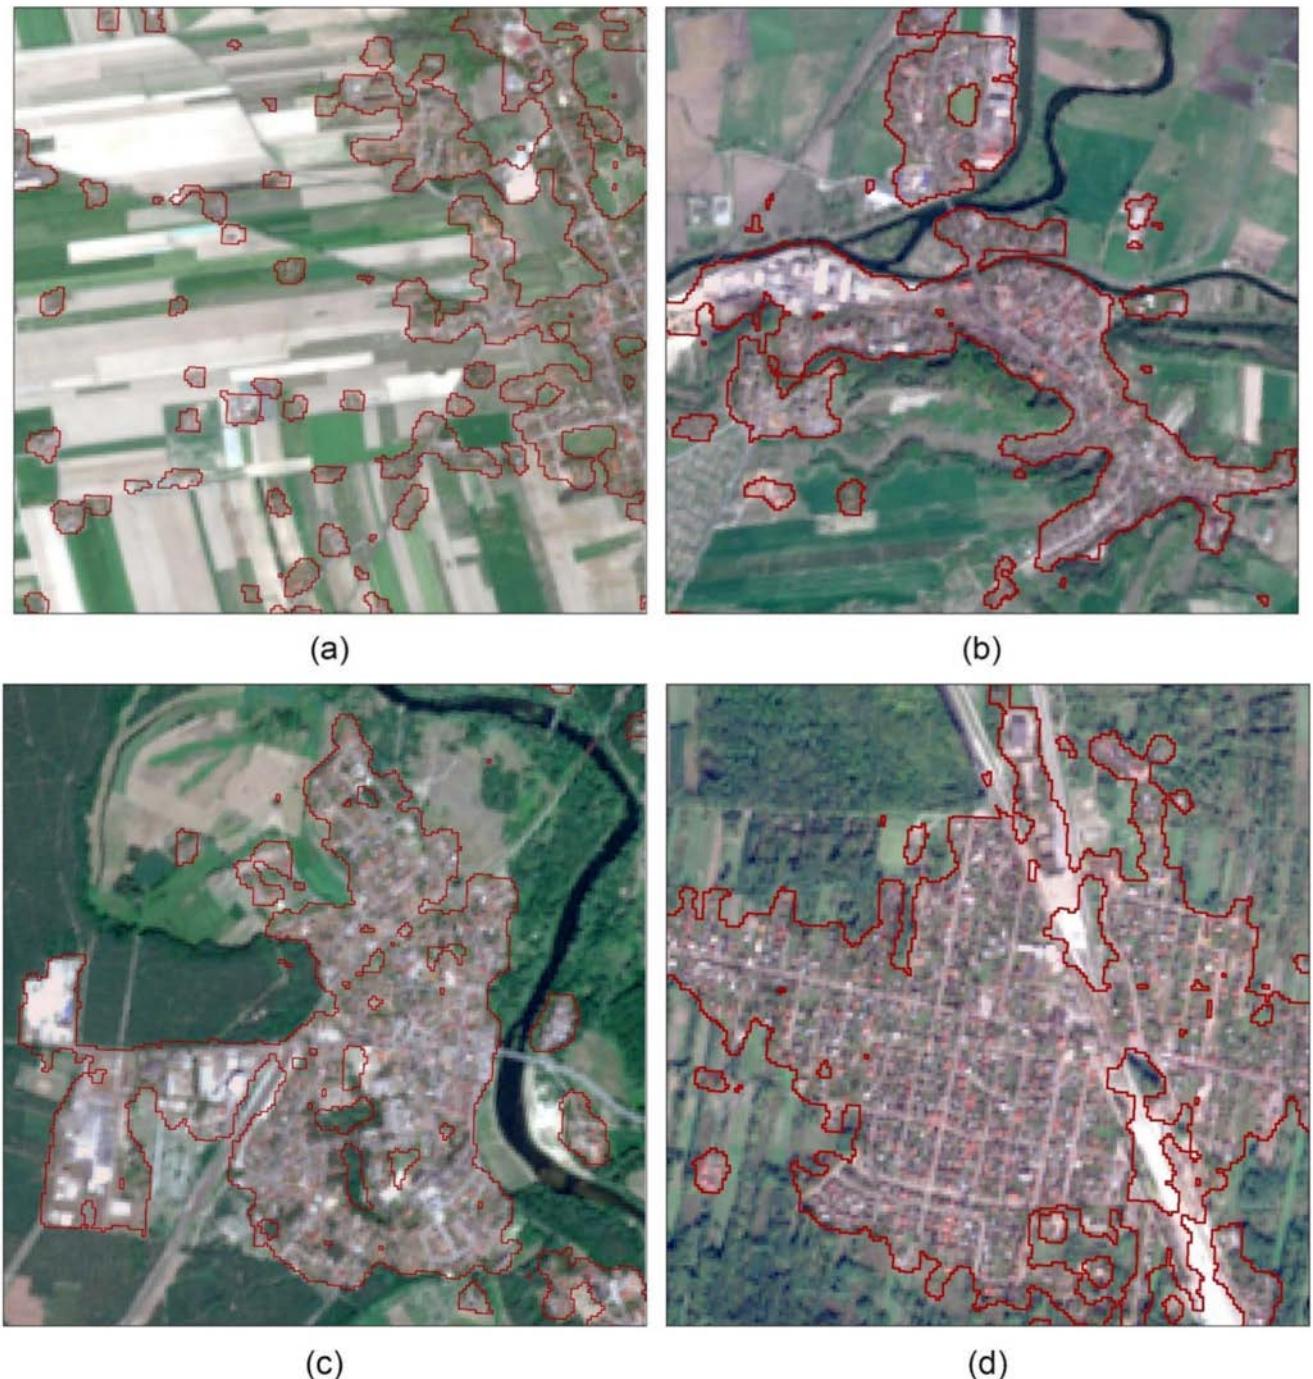


Figure 4. Cont.

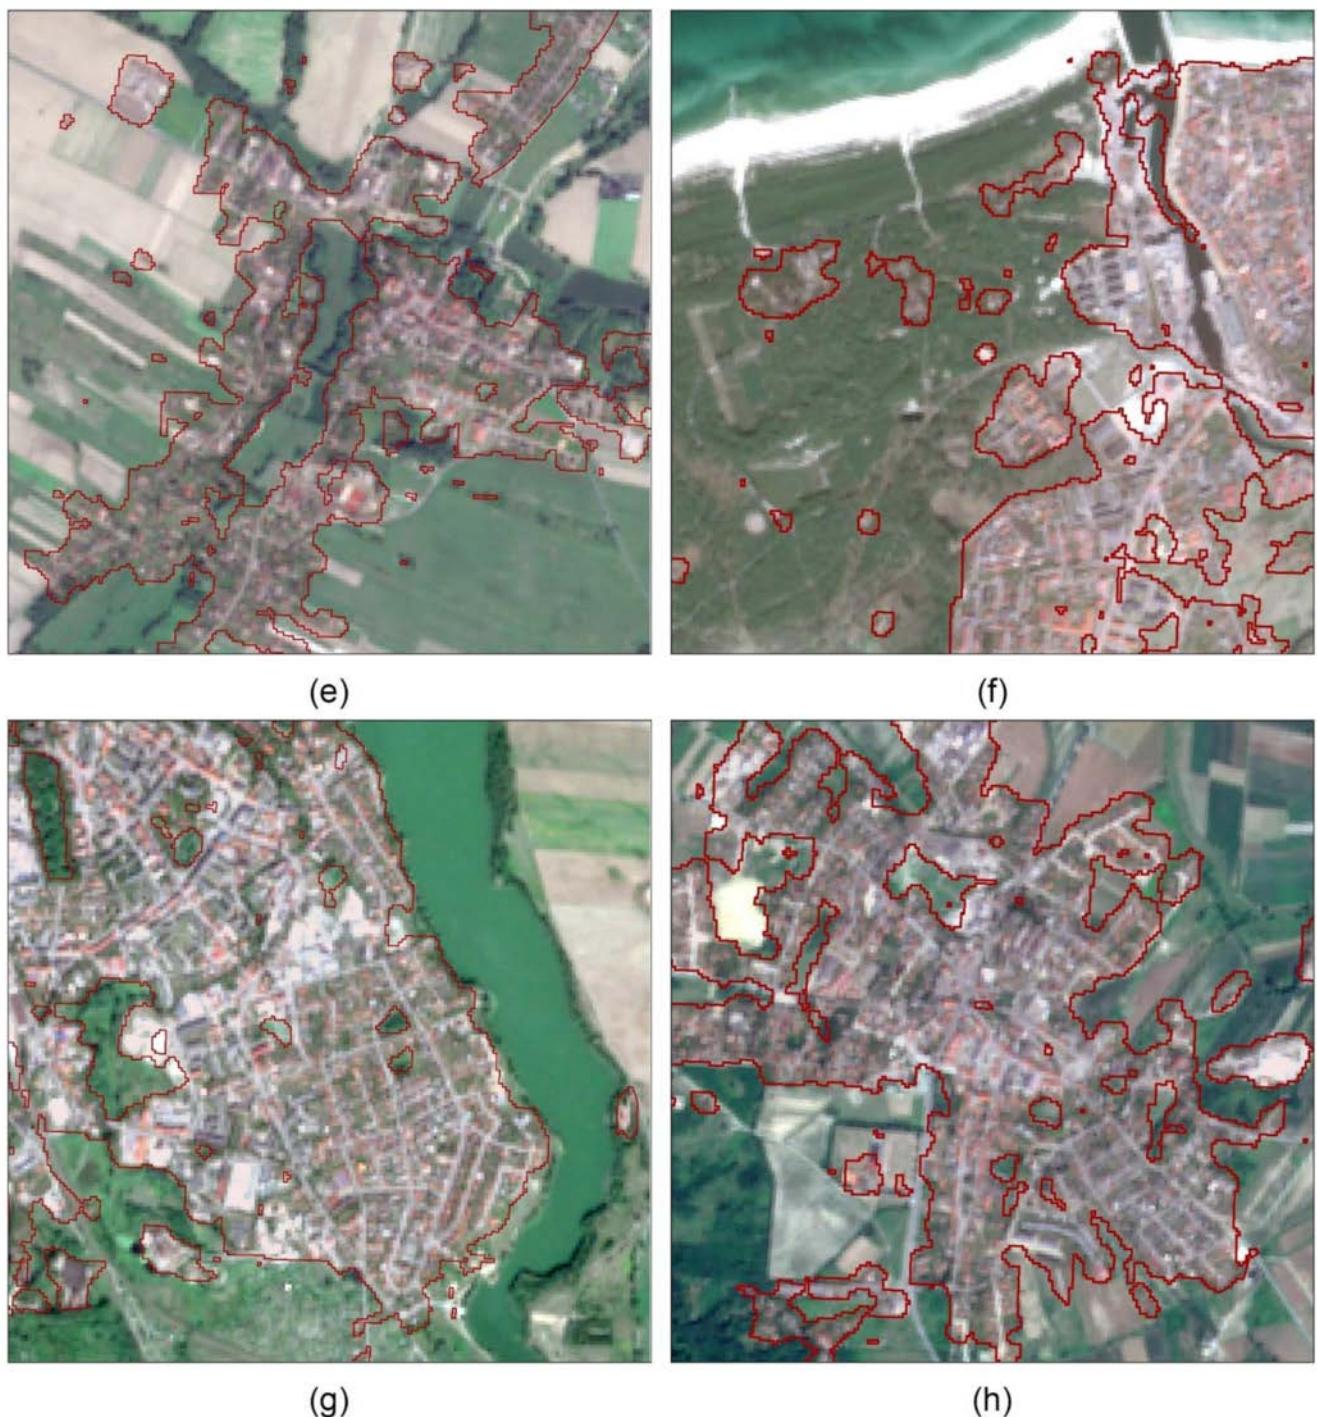


Figure 4. Cont.

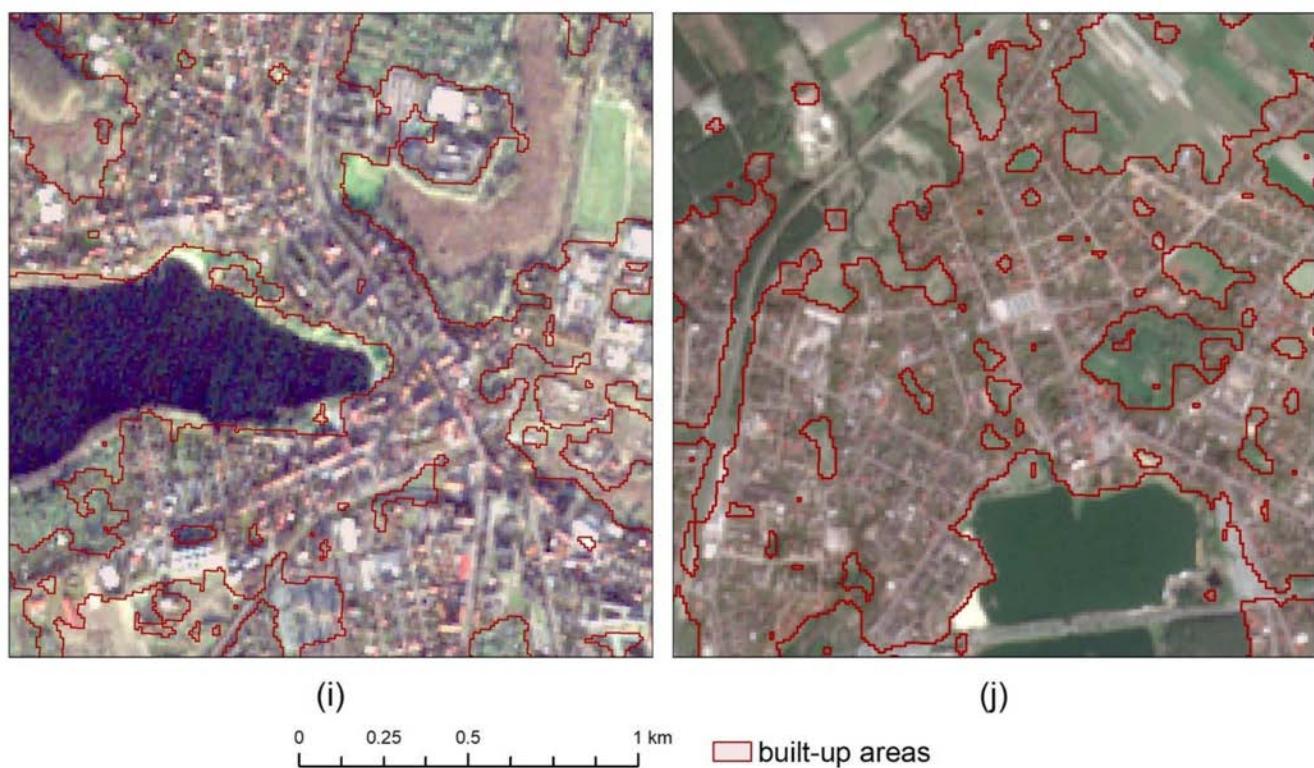


Figure 4. Build-up areas obtained as a result of machine learning segmentation, examples of: (a) Nieszawa (b) Ujście, (c) Nowogród Bobrzański, (d) Pilawa, (e) Sośniewice, (f) Ustka, (g) Olecko, (h) Sobótka, (i) Nowogard, (j) Główno.

The share of built-up areas in the urban area varies spatially. It can be indicated that cities with a low share of built-up areas are located mainly in southern Poland in the following regions: Śląski, Opolski, in the southern part of the Dolnośląski, and in the eastern part of the country in the Podlaski and on the border of the Świętokrzyski, Lubelski, and Podkarpacki (Figure 5). Cities with a high share of built-up areas were mainly located in Mazowiecki and Wielkopolski regions.

The analysis of the share of built-up areas in the area of small cities in Poland in 2019 also showed that the average share of built-up areas was 28.5% with a standard deviation of 0.99%. The lowest value of 1.7% was recorded for Krynica Morska, a city located in the north of Poland, in Pomorski region, on the Vistula Spit. The highest value, 83.6%, was recorded for the city of Łomianki, located in the Mazowiecki region and bordering Warsaw to the south. Cities with the lowest proportions of built-up areas, up to 15%, accounted for 20.6% of all cities surveyed. They were mainly located in the south and east of Poland. For 70.1% of the cities, the share of built-up areas ranged from 15 to 50%, while the highest shares of built-up areas in their area, above 50%, were found in 9.3% of the surveyed cities. They were mainly located in the central part of the Mazowiecki region, around the capital city of Warsaw, and in the western and southern parts of the Wielkopolski region (Figure 3).

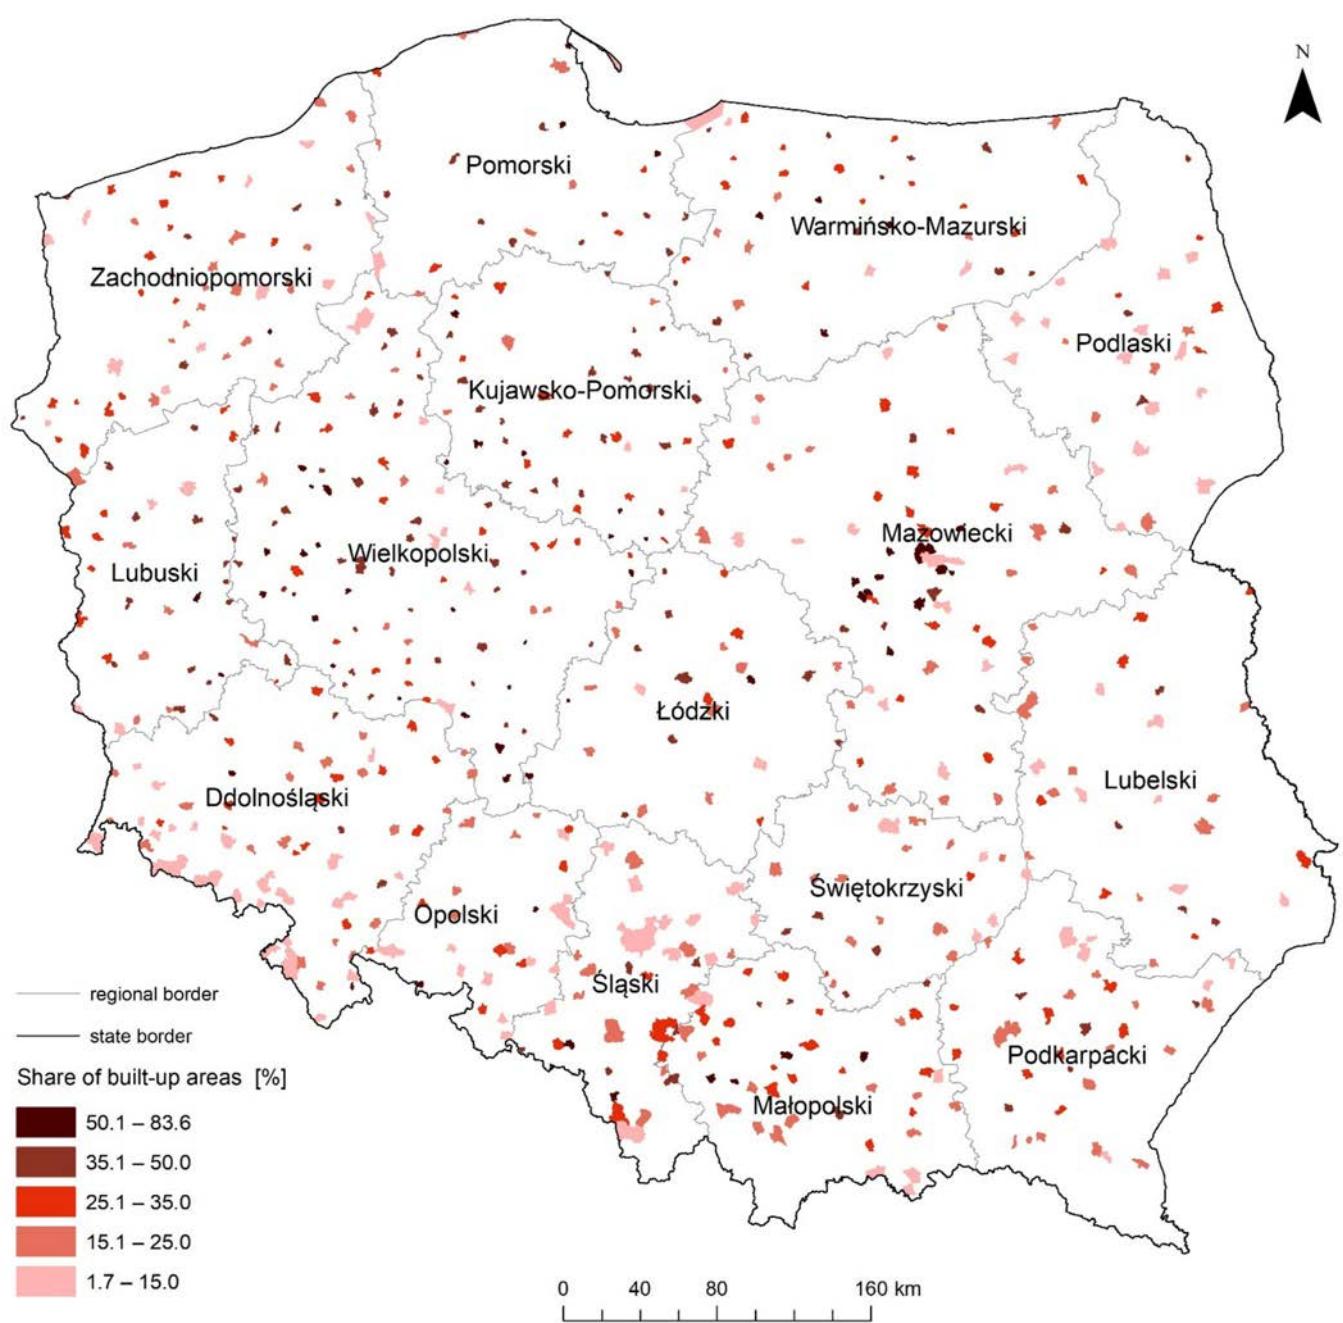


Figure 5. Share of built-up areas in the administrative area of small cities in Poland in 2019.

3.2. Hot Spots and Cold Spots of the Share of Built-Up Areas in the Area of Small Cities in Poland in 2019

The applied Hot Spot analysis (Getis-Ord G_i^*) allowed the identification of clusters of cities with a statistically significant high and low share of built-up areas in their area (Figure 6). There are two hot spots in the studied area, the first one in the central part of Mazowiecki region, in the area of Warsaw, the second, more extensive, covering Wielkopolski and Kujawsko-Pomorski regions. Cold spots occurred in three locations. The most extensive covered the southern part of Dolnośląski region, as well as Opolski and Śląski regions. The second was located on the border of three regions: Świętokrzyski, Mazowiecki, and Lubelski. The last cold spot was located in Podlaski region.

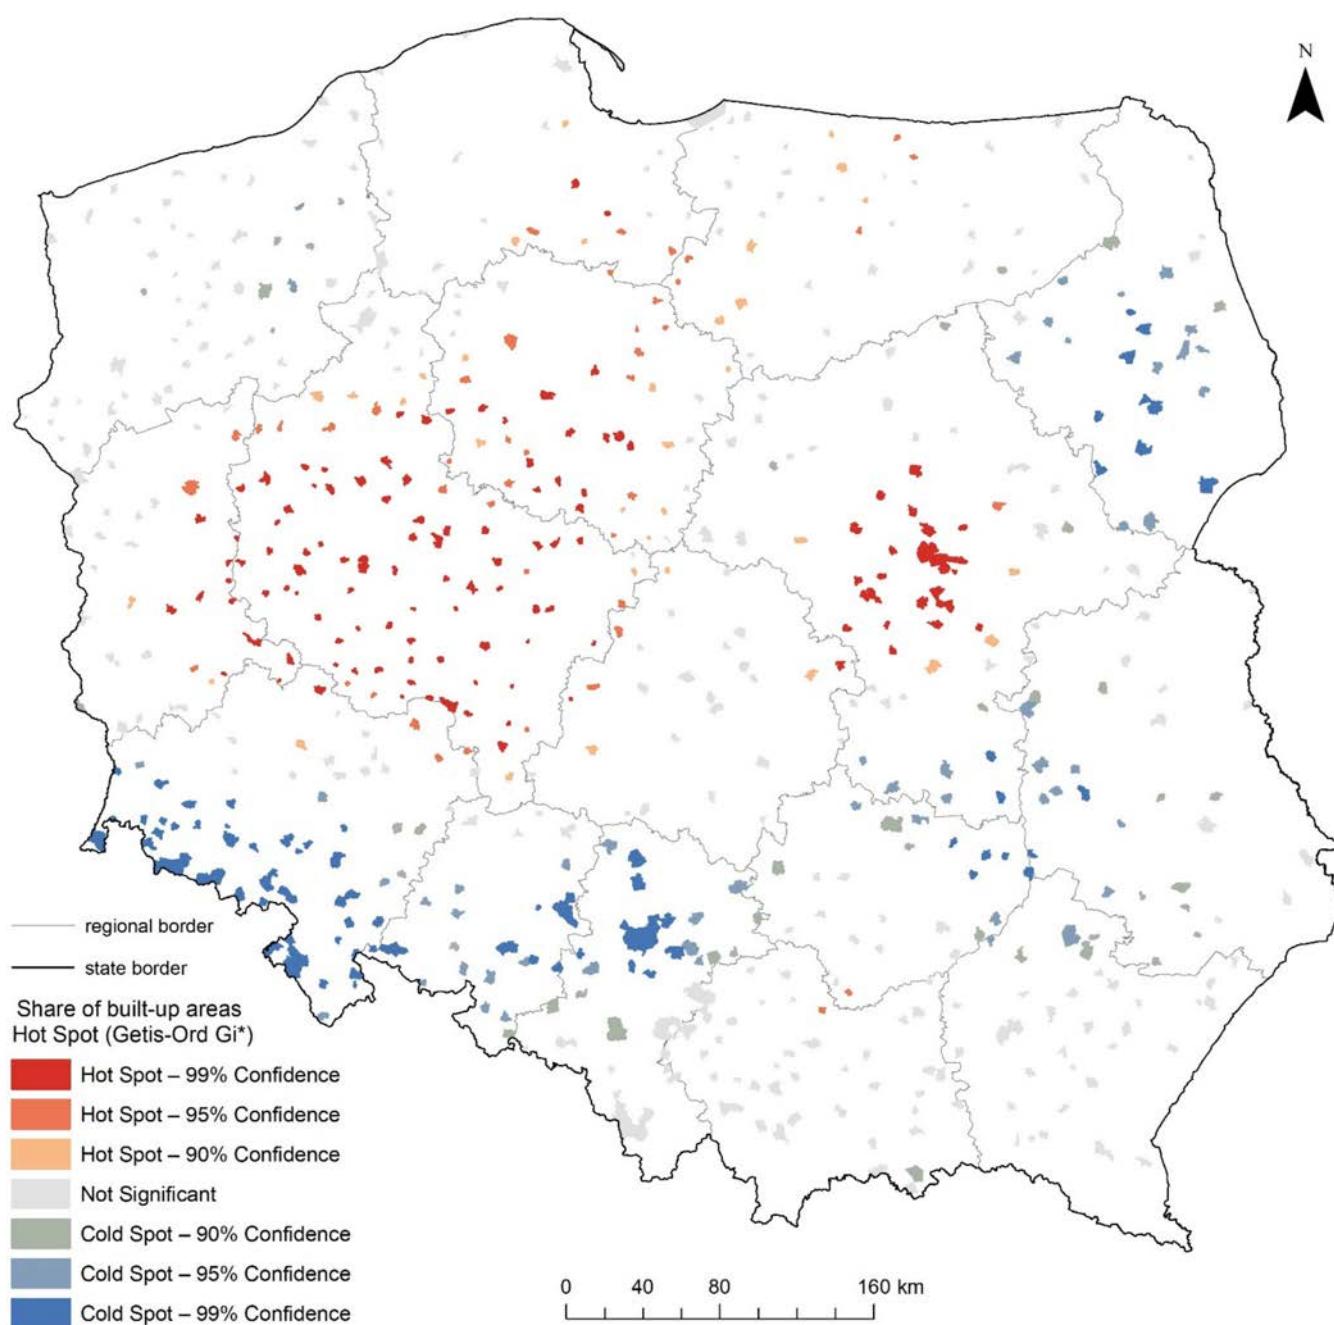


Figure 6. Hot spots of share of built-up areas in the administrative area of cities in 2019.

3.3. Global and Local Model of the Share of Built-Up Land in the Area of Small Cities in Poland

The global regression model (OLS) explaining the effect of selected variables on the share of built-up area in small cities in Poland in 2019 was evaluated (Table 4). The coefficient of determination for the global model (R^2) reached 0.790, adjusted R^2 0.788 and AICc (Akaike's Information Criterion) equal to 863.971. This result can be regarded as satisfactory and pointing to significant associations between socio-economic variables and the share of built-up areas. All the more so, as four out of six variables were identified as statistically significant (p -value < 0.01). Positive associations were noted for population density (Pop_Density) and the emergence of new residential buildings (Buildings). This may be caused by the increase in the wealth of the inhabitants and the need to improve housing conditions or the local development policy favoring the creation of new built-up areas. On the other hand, in cities with a higher unemployment (Unemployment) rate, the share of built-up areas in the area of the surveyed units is smaller. Interestingly, a negative association between the share of built-up areas in the surface area of small cities was shown for domestic economic entities (Enterprises).

Table 4. Global model estimating.

Variable	Coefficient	Standard Error	t-Value	p-Value
Pop_Density	0.9206	0.0207	44.4981	p -value < 0.01
Buildings	0.2014	0.0263	7.6640	p -value < 0.01
Unemployment	-0.0695	0.0185	-3.7638	p -value < 0.01
Work_Pop	-0.0311	0.0192	-1.6219	0.1565
Enterprises	-0.2115	0.0298	-7.1048	p -value < 0.01
Living_Standard	-0.0163	0.0204	-0.8027	0.4477

For GWR, R^2 reached 0.868, adjusted R^2 0.843 and AICc 713.881. Which indicates that the estimation of local models based on this method more effectively describes the phenomenon under study. Higher R^2 values indicate a stronger explanatory power of the regression model, and a model with a lower AICc value indicates a better fit to the observed data. GWR with Fixed Kernel type was used in the study because it achieved a smaller AICc compared to Adaptive Kernel type with an AICc of 717.095. The accuracy of GWR-based estimates of the local influence of various demographic social and economic factors on the share of built-up area in small cities in Poland varies spatially (Figure 7). The best estimates of the share of built-up areas according to the components under study were obtained for cities located in the Zachodniopomorski, Lubuski, and Dolnośląski regions occupying the western part of the country, and for cities from the Opolski and Śląski regions located in the south of Poland. This also applied to cities located in the north-east of Poland in the Podlaski and partly in the Warmińsko-Mazurski regions.

GWR coefficients for socio-economic factors describing the spatial variation of the share of built-up areas in the area of small cities (Table 5) indicate positive associations between population density or the number of buildings in small cities and the share of built-up areas in the area of cities. The next two, the percentage of unemployed and the share of the population of working age, have a mostly negative associations with the examined characteristic. The most varied is the variable defining the quality of life of residents (defined by the share of bathrooms [%] in residential buildings), which takes both negative and positive values.

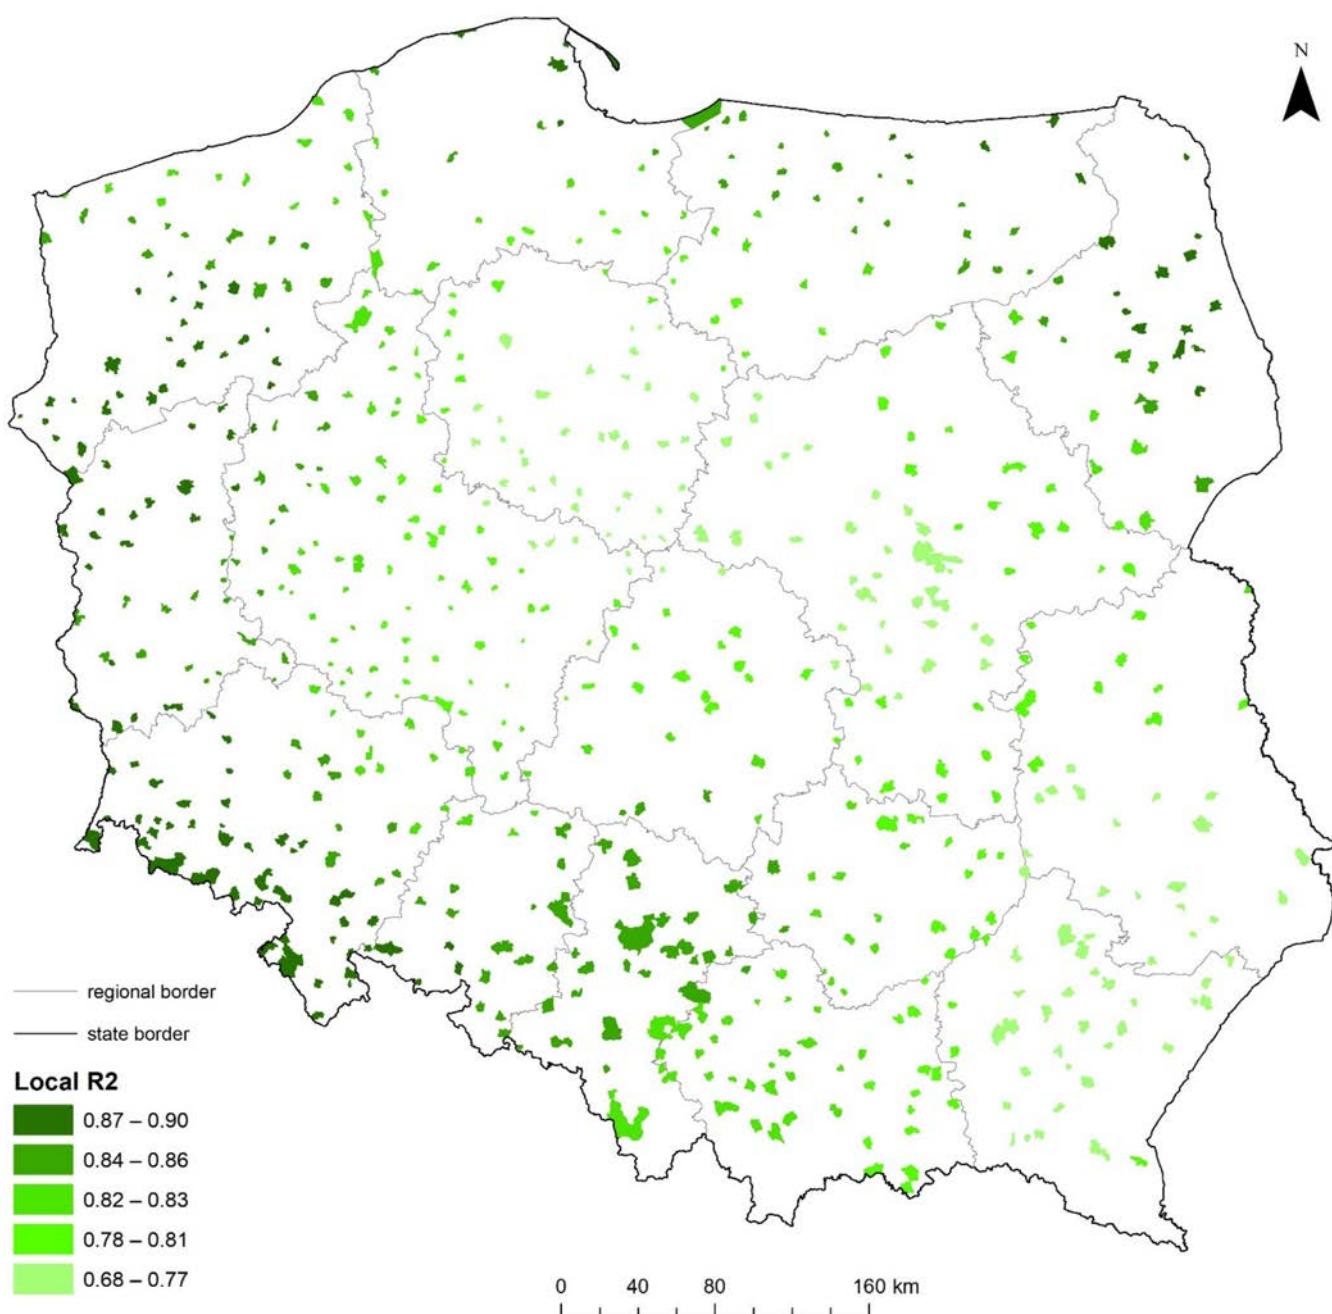


Figure 7. Coefficients of determination of local models estimating share of built-up areas in the area of small Polish cities in 2019.

Table 5. Summary of GWR coefficients depicting the spatially varying relationships between share of built-up areas in small cities [%] and socio-economic factors.

Socio-Economic Factors	Minimum	Median	Average	Maximum
Pop_Density	0.75	0.96	0.98	1.66
Buildings	0.03	0.18	0.21	1.02
Unemployment	-0.31	-0.09	-0.10	0.10
Work_Pop	-0.20	-0.02	-0.03	0.70
Enterprises	-0.65	-0.23	-0.24	0.01
Living_Standard	-0.20	-0.03	-0.03	0.11

Population density (Pop_Density) was the most important spatial stimulant of the share of built-up areas in the area of the cities studied (Figure 8). The higher the population density, the greater the proportion of built-up areas. A significant relationship between population density and the share of built-up areas has been found for the whole of Poland. The strongest association with this variable was observed in the south of Poland in the following regions: Małopolski, Podkarpacki, and Świętokrzyski, and in the east of the country, in Lubelski and Podlaski. The weakest impact of this variable is seen in northern Poland in Pomorski, Kujawsko-Pomorski, and Warmińsko-Mazurski regions. As well as in the southern part of Dolnośląski and Opolski regions. These regions formed part of the cold spot of the share of built-up areas in the area of small cities (Figure 6) and are regions with an unfavorable economic structure, threatened by depopulation, which consequently also adversely affects the share of built-up areas in the area of small towns located within their borders.

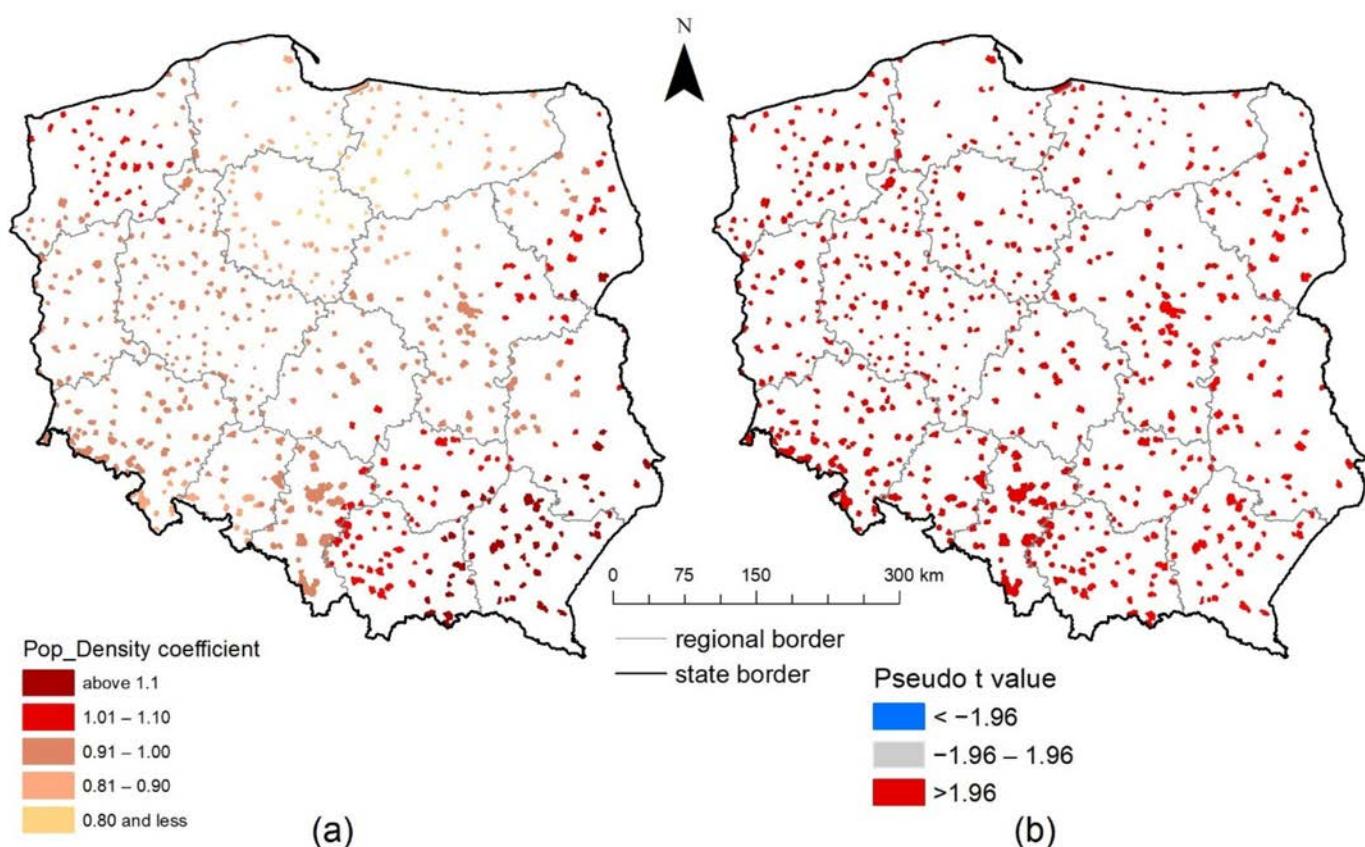


Figure 8. Value (a) and significance (b) of the coefficient of the effect of population density (Pop_Density) on the share of built-up land in the area of Polish small cities in 2019.

A significant positive association was also found between the share of built-up areas in the area of small cities was also found in the number of new residential buildings put into use (Buildings) for a prevailing part of Poland, with the exception of Śląski, Małopolski, part of Lubelski, and Wielkopolski and Lubuski regions. This association was strongest in the northern part of Poland, in Pomorski and Zachodniopomorski regions, and partially in Warmińsko-Mazurski and Podlaski (Figure 9). This is an expected relationship, the construction of new buildings is an obvious cause of increasing the share of built-up areas in the area of the surveyed units. However, the lack of significance of this factor for the regions indicated above may mean that the buildings in the cities located there are relatively old and their large share in the area of the cities under study has been shaped by historical processes. This is particularly evident in the case of Wielkopolski region, where a hot spot of the share of built-up areas in the area of small cities is located (Figure 6).

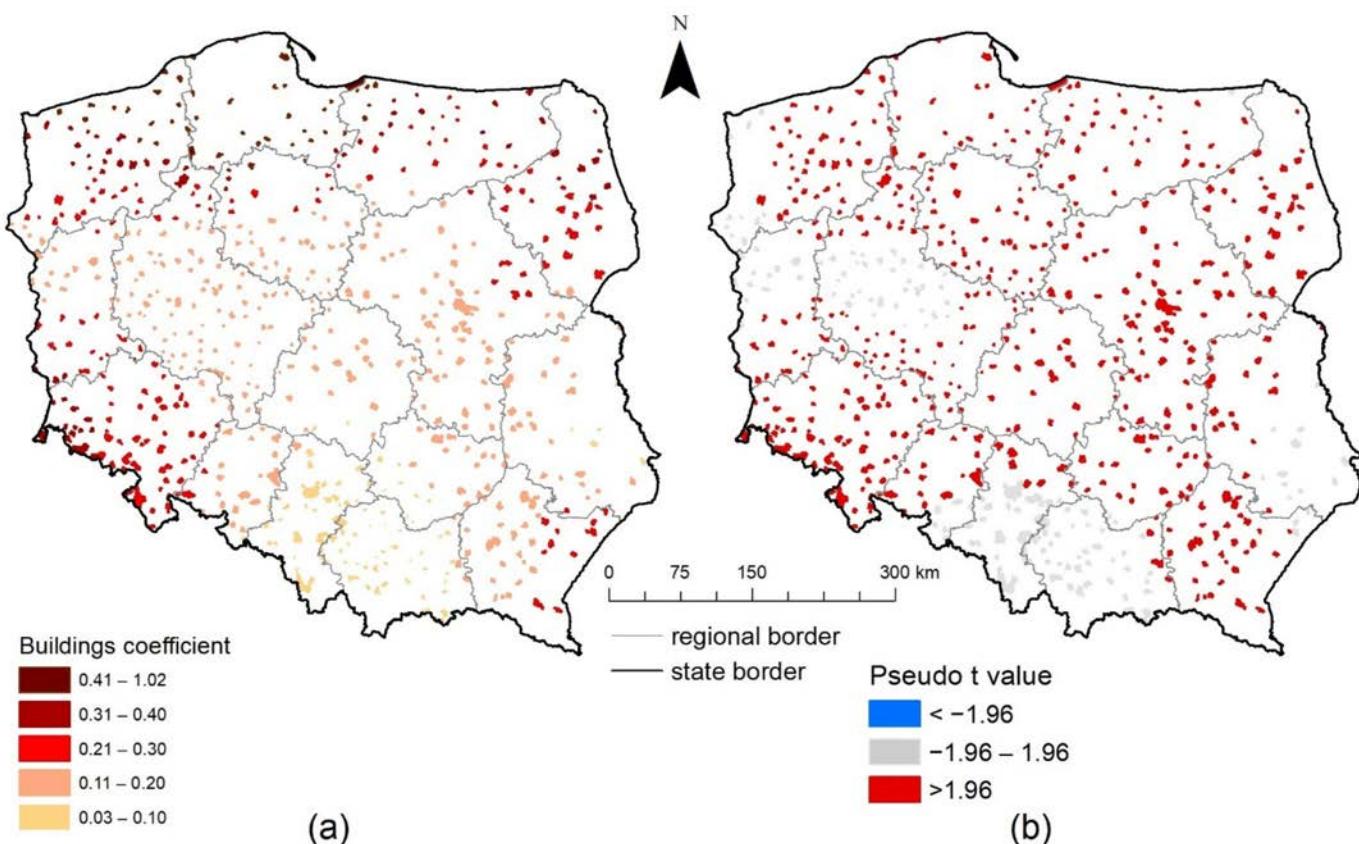


Figure 9. Value (a) and significance (b) of the coefficient of the effect of the number of new residential buildings put into use (Buildings) on the share of built-up area in the area of small Polish cities in 2019.

A significant association was detected between the share of built-up areas in the area of small cities in Poland in 2019 and the share of registered unemployed in the number of people of working age (Unemployment), mainly in the western and southern part of Poland, in Lubuski Wielkopolski, Dolnośląski Opolski and Śląski regions, as well as in the band stretching from the central part of Mazowiecki southwards through the western part of Lubelski to the northern part of Podkarpacki region (Figure 10). This association was mostly negative, meaning that the lower the unemployment rate, the higher the share of built-up areas in the area of the surveyed cities. The influence of this factor was strongest in southern Poland, in a belt running from the southern part of Lubuski, Dolnośląski, Opolski regions to the southern part of Śląski. The association with this variable can be seen in the occurrence of hot spots of the share of built-up areas in Wielkopolski and Mazowiecki regions (Figure 6), which were the areas with the lowest unemployment rate in Poland in 2019. It can as well be inferred that it has a partial influence on the occurrence of cold spots of the share of built-up areas in the area of small cities visible in the south of Poland, especially in Opolski and partly in Dolnośląski, which are regions at risk of depopulation and less development with higher unemployment.

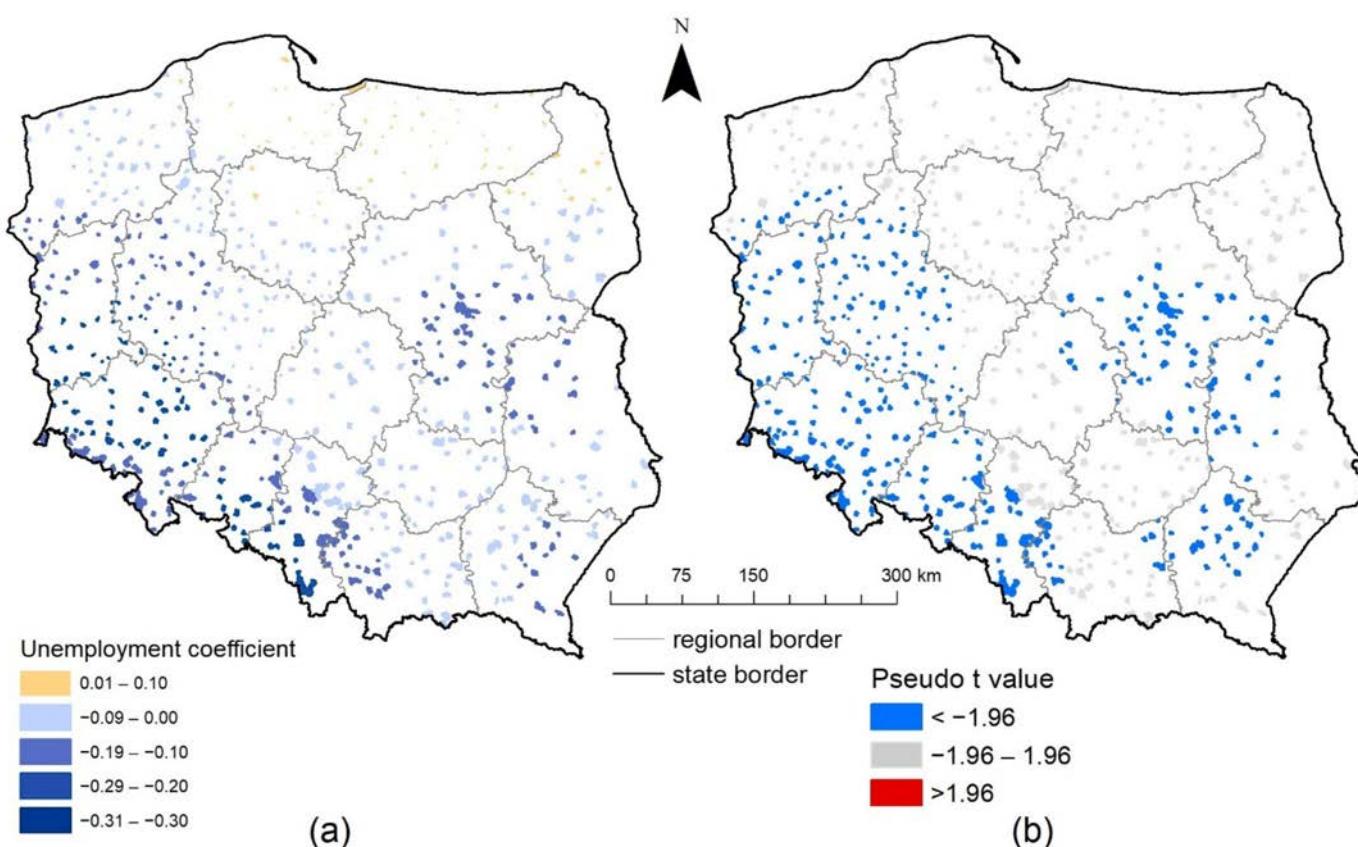


Figure 10. Value (a) and significance (b) of the coefficient of the impact of the share of registered unemployed in the number of people of working age (Unemployment) on the share of built-up areas in the area of Polish cities in 2019.

Issues related to the share of working-age population in the total population (Work_Pop) are a predominantly negative factor associated with the share of built-up areas in the area of the surveyed cities. The smaller the share of the population of working age, the larger the share of built-up areas in the area of small cities. However, the impact of this variable is significant only for the central and northern part of Mazowiecki and the western part of Podlaski region (Figure 11). Although the impact of this variable is very limited, it can be concluded that it is related to the influence of the capital city of Warsaw, whose developed labor market attracts people of working age, especially from small cities located in its immediate and near vicinity.

Another variable—the number of newly registered domestic economic entities in the REGON register (Enterprises) had a significant association with the share of built-up areas in the area of small cities in the majority of the country, except for the regions located in the south of Poland: Opolski, Śląski, Małopolski, Podkarpacki, and partly Łódzki, Świętokrzyski, and Lubelski (Figure 12). The impact of this factor is overwhelmingly negative. The smaller the number of enterprises, the greater was the share of built-up areas in the area of the surveyed cities. This influence was strongest in the regions of western and northern Poland. From Dolnośląski region to the north through Zachodniopomorski to Podlaski region to the east. It can be assumed that buildings in these cities were mainly residential and newly registered domestic economic entities, e.g., services, were located in owners' place of residence.

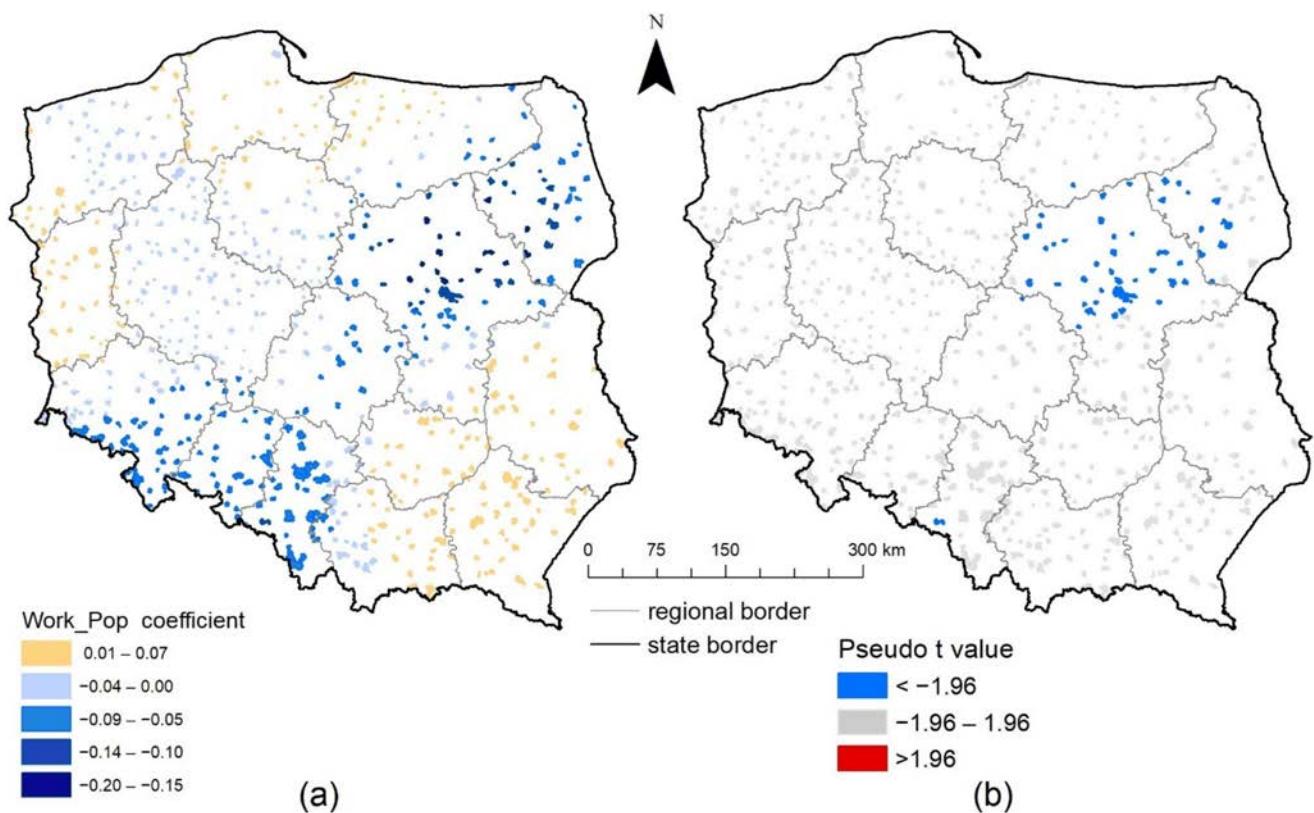


Figure 11. Value (a) and significance (b) of the coefficient of the impact of the share of working-age population in the total population (Work_Pop) on the share of built-up land in the area of small Polish cities in 2019.

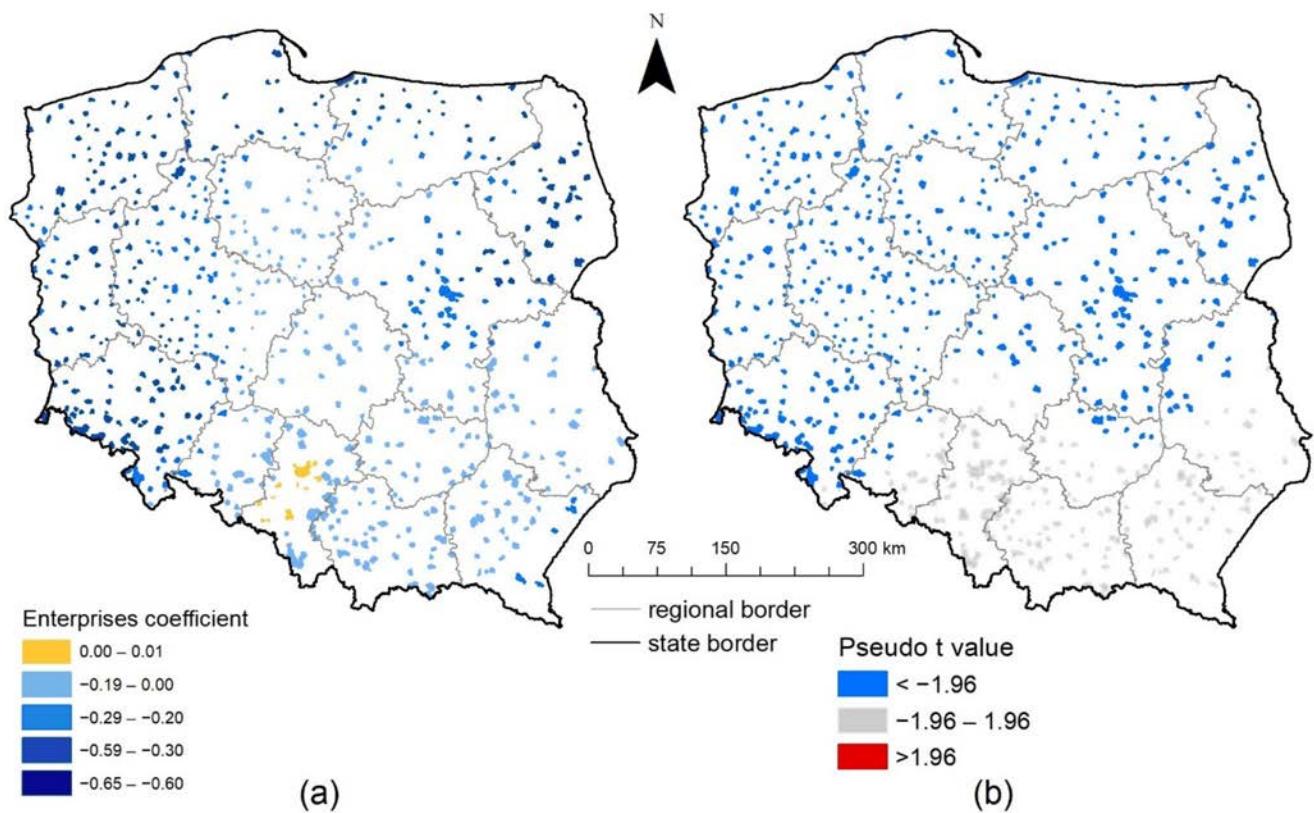


Figure 12. Value (a) and significance (b) of the coefficient of the impact of newly registered domestic economic entities in the REGON register (Enterprises) on the share of built-up areas in the area of small cities in Poland in 2019.

For the last examined variable, the quality of life expressed as the share of dwellings equipped with facilities (bathrooms) in the total number of dwellings (Living_Standard), two opposite statistically significant tendencies of association with the share of built-up area in small cities in Poland were observed (Figure 13). Negative relationship was observed in the belt running from Zachodniopomorski region, through Wielkopolski to the northern edges of Opolski and Śląski regions. In this area, the lower the quality of life, the higher the share of built-up area in the surveyed cities. An inverse relationship was found for the central part of Mazowiecki region, where a higher quality of life translates into a higher share of built-up areas in the area of small cities. Both areas coincide with the designated hot spots of the share of built-up areas in the area of the surveyed cities (Figure 6). These seemingly contradictory trends can be traced back to the different age of urban development in the two regions. While the buildings in cities centered around Warsaw, in the central part of the Mazowiecki region, have developed intensively over the last 25 years, the built-up areas in cities in Wielkopolski are relatively older and have been shaped by other historical factors, the conditions in which settlement units were established and developed throughout their existence.

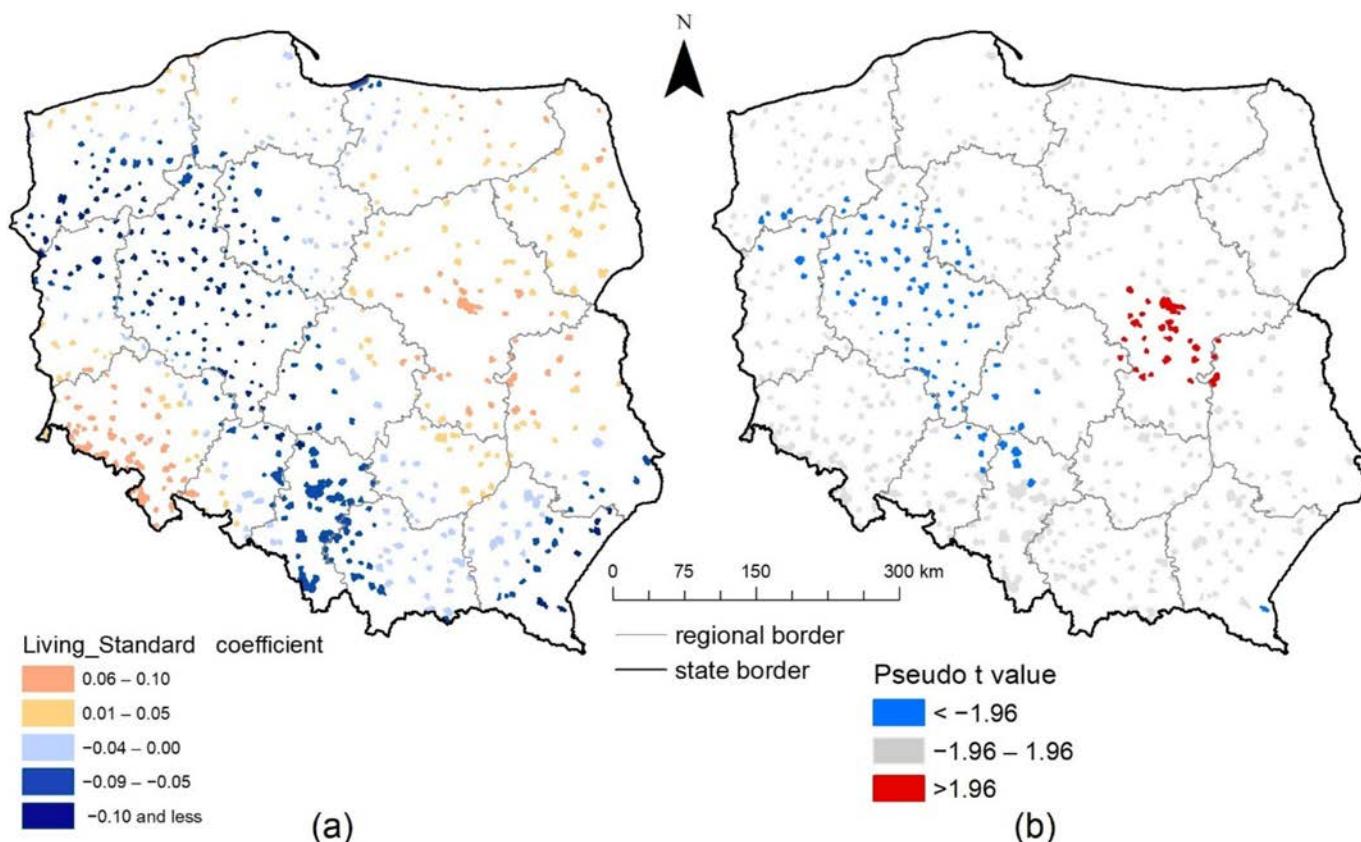


Figure 13. Value (a) and significance (b) of the coefficient of the impact of the share of dwellings equipped with facilities (bathrooms) in the total number of dwellings (Living_Standard) on the share of built-up areas in the area of small cities in Poland in 2019.

The use of combined deep learning, Hot Spot analysis (Getis-Ord G_i^*), and GWR methods allowed to identify the significance and impact of individual determinants. It was found that population density and the construction of new residential buildings had the greatest influence on the share of built-up areas in the area of the surveyed cities. The results also indicated that the share of built-up areas in the area of the cities under study is a result of the conditions under which they were established and developed, and not only of the socio-economic factors affecting them at present.

4. Discussion and Future Directions

The fact that cities are built up is not debatable, but the regional variation of the built-up areas suggests a need to examine the reasons and factors influencing this fact. The variables associated with the share of built-up areas in small cities in a national perspective have not yet been considered by researchers. A certain problem in determining the built-up areas in all cities in a given year is the lack of available up-to-date geodetic data sources. This is made possible by information extracted from satellite images [35,89–91]. The aim of this study was to investigate the spatial differentiation of the share of built-up areas in the area of small cities in Poland, as well as to search for factors influencing this differentiation. Sentinel-2 satellite images and data from the Statistics Poland were used for this purpose.

The paper is not able to make any causal claims, but the obtained results allowed for the identification of some statistically significant relationships between the studied variables. The scheme of the adopted research procedure has already been successfully applied in urban studies [49,50,63]. The method of Hot Spot Analysis (Getis-Ord G^*) was used to determine regional variations in the share of hot-spots and cold-spots in built-up areas (Figure 4). The GWR method was applied and it was found that the variables explaining the spatial variation in the share of built-up areas are regionally differentiated and have positive, negative, or mixed associations with the variable under study.

The variables used in the research were also applied in the other studies of small towns in Poland. The population related variable used most frequently was the number of inhabitants, population density, but also population dynamics and migrations. These variables often were the base for the selection of cities taken into account in the research, they were used to study the development of small towns and create a typology of settlement units [18,57,62,64]. Variables allowing to describe the economic activity of inhabitants of small cities in Poland were also often used. Data on professional activity, unemployment level, working age population, number of enterprises, or employment in a specific sector of the economy, e.g., in services, were used to study the development of small cities and the role they play in the country's settlement system [1,57,64,92]. Variables related to the spatial development of small cities, such as changes in the administrative area of cities, share of urbanized area of the town, changes in the number of flats and houses, and infrastructure are used less frequently and mainly in the field of small town development [57,62]. The greatest differentiation occurs among the variables describing the living standards of small city residents. This issue can be described in various ways, often also through the subjective opinions of the inhabitants; however, the most frequently used in research are: the level of infrastructure development and access to services related to education, health, trade, and culture [1,16,92]. Positive associations with the share of built-up areas in small Polish cities have been detected for population density (Figure 8) and the number of new residential buildings (Figure 9). Negative relationships have been found for three socio-economic variables: the share of the registered unemployed in the working-age population (Figure 10), the share of working-age population in the total population (Figure 11), and—which was quite surprising—the number of newly registered domestic economic entities (Figure 12). The quality of life of inhabitants of small towns were determined with the use of the variable showing the share of dwellings equipped with facilities (bathrooms) in the total number of dwellings. This variable showed notable spatial differentiation and various associations (Figure 13). In the Mazowiecki region around Warsaw, it had a positive association with the share of built-up areas, but in Wielkopolski region the relationship was opposite. This indicates differences in the equipment of buildings forming built-up areas in the cities of these regions.

The inclusion of a temporal variable can not only improve inference but also reveal new relationships. In future research, the research area can be narrowed down to a single city or a group of cities, but it can also be extended to include a network of cities in Poland's neighboring countries. Sentinel-2 satellite images offer this possibility. The issue to be resolved will be the selection of variables available for all the countries studied.

Unfortunately, a major barrier is the lack of availability of statistical data. In the databases of Statistics Poland as well as Eurostat—European Statistics, most data are aggregated to the level of municipalities, which affects limited possibilities of statistical data analysis for small cities.

The presented research scheme may be an inspiration to undertake similar research. Capturing the relationship between the share of built-up areas and socio-economic factors requires further research. The proportion of built-up areas in cities is the result of long-standing processes and urban morphology. Most of the cities studied have medieval origins, but there are also those established during the industrialization of Poland, as well as tourist and spa towns, and others [93]. They play different roles in the Polish settlement system [1,92,94–96]. More and more towns in the suburban areas of large cities are growing rapidly in terms of population and built-up areas. As a consequence of this development, they will obtain city rights and change the urban settlement network of Poland. Others are going through economic stagnation or regression, with population declining and built-up areas remaining unchanged. It is worth continuing research with new variables and also their dynamics [97]. New variables can also be of a qualitative nature related to: the origins of cities, geographical location (lowlands, highlands, mountains), proximity to roads, transport hubs, ports, and large cities.

Author Contributions: Conceptualization, M.A., I.J. and M.N.; methodology, M.A., I.J. and M.N.; software, M.A.; validation, I.J. and M.N.; formal analysis, M.A., I.J. and M.N.; investigation, M.A., I.J. and M.N.; resources, I.J. and M.N.; data curation, M.N.; writing—original draft preparation, M.A., I.J. and M.N.; writing—review and editing, M.A., I.J. and M.N.; visualization, M.N.; supervision, I.J. and M.N.; project administration, M.N.; funding acquisition, M.A., I.J. and M.N. All authors have read and agreed to the published version of the manuscript.

Funding: This research received no external funding.

Institutional Review Board Statement: Not applicable.

Informed Consent Statement: Not applicable.

Data Availability Statement: Publicly available datasets were analyzed in this study. This data can be found here: <https://bdl.stat.gov.pl/BDL>, <http://www.gugik.gov.pl/pzgik>, <https://scihub.copernicus.eu> (accessed on 13 May 2021).

Acknowledgments: This work has been supported by Faculty of Geographical Sciences at University of Lodz.

Conflicts of Interest: The authors declare no conflict of interest.

References

1. Czapiewski, K.; Bański, J.; Górczyńska, M. The Impact of Location on the Role of Small Towns in Regional Development: Mazovia, Poland. *Eur. Countrys.* **2016**, *8*, 413–426. [[CrossRef](#)]
2. Vaishar, A.; Št'astná, M.; Stonáská, K. Small Towns—Engines of Rural Development in the South-Moravian Region (Czechia): An Analysis of the Demographic Development. *Acta Univ. Agric. Silvic. Mendel. Brun.* **2015**, *63*, 1395–1405. [[CrossRef](#)]
3. Agergaard, J.; Kirkegaard, S.; Birch-Thomsen, T. Between Village and Town: Small-Town Urbanism in Sub-Saharan Africa. *Sustainability* **2021**, *13*, 1417. [[CrossRef](#)]
4. Tan, K.C. Small Towns in Chinese Urbanization. *Geogr. Rev.* **1986**, *76*, 265–275. [[CrossRef](#)]
5. Gu, C.; Li, Y.; Han, S.S. Development and Transition of Small Towns in Rural China. *Habitat Int.* **2015**, *50*, 110–119. [[CrossRef](#)]
6. Tan, M.; Li, X.; Xie, H.; Lu, C. Urban Land Expansion and Arable Land Loss in China—A Case Study of Beijing–Tianjin–Hebei Region. *Land Use Policy* **2005**, *22*, 187–196. [[CrossRef](#)]
7. Brennan, C.; Hackler, D.; Hoene, C. Demographic Change in Small Cities, 1990 to 2000. *Urban Aff. Rev.* **2005**, *40*, 342–361. [[CrossRef](#)]
8. Bell, D.; Jayne, M. Small Cities? Towards a Research Agenda. *Int. J. Urban. Reg. Res.* **2009**, *33*, 683–699. [[CrossRef](#)]
9. Demazière, C. Dealing with Small and Medium-Sized Towns (SMSTs) in Urban Studies. *Espaces Sociétés* **2017**, *168–169*, 17–32. [[CrossRef](#)]
10. Statistics Poland Local Data Bank. Available online: <https://bdl.stat.gov.pl/BDL> (accessed on 23 February 2021).
11. Demazière, C.; Serrano, J.; Vye, D. (Eds.) Introduction. *Les villes petites et moyennes et leurs acteurs: Regards de chercheurs*. In *Villes Petites Et Moyennes (Norois)*; Presses Universitaires de Rennes: Rennes, France, 2012; pp. 7–10.

12. Knox, P.; Mayer, H. *Small Town Sustainability: Economic, Social, and Environmental Innovation*; Walter de Gruyter: Basel, Switzerland, 2013.
13. Mayer, H.; Knox, P. Small-Town Sustainability: Prospects in the Second Modernity. *Eur. Plan Stud.* **2010**, *18*, 1545–1565. [CrossRef]
14. Ahvenniemi, H.; Huovila, A.; Pinto-Seppä, I.; Airaksinen, M. What Are the Differences between Sustainable and Smart Cities? *Cities* **2017**, *60*, 234–245. [CrossRef]
15. Jaźdżewska, I.; Frykowski, M. Rozwój gospodarczy gmin a aktywność obywatelska mieszkańców wsi i małych miast województwa łódzkiego. In *Oblicza Kapitału Społecznego. Studium Teoretyczne i Empiryczne*; Byłok, F., Kwiatek, A., Eds.; Politechnika Częstochowska Wydział Zarządzania: Częstochowa, Poland, 2009; pp. 71–84.
16. Kwiatek-Sołtys, A.; Mainet, H. Quality of Life and Attractiveness of Small Towns: A Comparison of France and Poland. *Quaest. Geogr.* **2014**, *33*, 103–113. [CrossRef]
17. Bell, D.; Jayne, M. *Small Cities: Urban Experience beyond the Metropolis*; Routledge: London, UK, 2006.
18. Kamińska, W.; Mularczyk, M. Demographic Types of Small Cities in Poland. *Misc. Geogr.* **2014**, *18*, 24–33. [CrossRef]
19. Valtenbergs, V.; Ainhoa, G.; Ralfs, P. Selecting Indicators for Sustainable Development of Small Towns: The Case of Valmiera Municipality. *Procedia Comput. Sci.* **2013**, *26*, 21–32. [CrossRef]
20. Huovila, A.; Bosch, P.; Airaksinen, M. Comparative Analysis of Standardized Indicators for Smart Sustainable Cities: What Indicators and Standards to Use and When? *Cities* **2019**, *89*, 141–153. [CrossRef]
21. Nesticò, A.; Maselli, G. Sustainability Indicators for the Economic Evaluation of Tourism Investments on Islands. *J. Clean. Prod.* **2020**, *248*, 119217. [CrossRef]
22. Klusáková, L.; Ozouf-Marignier, M. Small Towns as European Cultural Heritage. Introduction. In *Small Towns in Europe in the 20th and 21st Centuries*; Klusáková, L., Ed.; Charles University in Prague, Karolinum Press: Prague, Czech Republic, 2017.
23. Van Lindert, P.; Verkoren, O. *Small Towns and beyond: Rural Transformation and Small Urban Centres in Latin America*; Thela Publishers: Amsterdam, The Netherlands, 1997.
24. Wisner, B.; Pelling, M.; Mascarenhas, A.; Holloway, A.; Ndong, B.; Faye, P.; Ribot, J.; Simon, D. Small cities and towns in Africa: Insights into adaptation challenges and potentials. In *Urban Vulnerability and Climate Change in Africa*; Springer: Berlin/Heidelberg, Germany, 2015; pp. 153–196.
25. Naikoo, M.W.; Rihan, M.; Ishtiaque, M.; Shahfahad. Analyses of Land Use Land Cover (LULC) Change and Built-up Expansion in the Suburb of a Metropolitan City: Spatio-Temporal Analysis of Delhi NCR Using Landsat Datasets. *J. Urban Manag.* **2020**, *9*, 347–359. [CrossRef]
26. Zhao, J.; Guo, W.; Huang, W.; Huang, L.; Zhang, D.; Yang, H.; Yuan, L. Characterizing Spatiotemporal Dynamics of Land Cover with Multi-Temporal Remotely Sensed Imagery in Beijing during 1978–2010. *Arab. J. Geosci.* **2013**, *7*, 3945–3959. [CrossRef]
27. Yin, J.; Yin, Z.; Zhong, H.; Xu, S.; Hu, X.; Wang, J.; Wu, J. Monitoring Urban Expansion and Land Use/Land Cover Changes of Shanghai Metropolitan Area during the Transitional Economy (1979–2009) in China. *Environ. Monit. Assess.* **2010**, *177*, 609–621. [CrossRef]
28. Yang, X.; Lo, C.P. Modelling Urban Growth and Landscape Changes in the Atlanta Metropolitan Area. *Int. J. Geogr. Inf. Sci.* **2003**, *17*, 463–488. [CrossRef]
29. Yang, X.; Lo, C.P. Using a Time Series of Satellite Imagery to Detect Land Use and Land Cover Changes in the Atlanta, Georgia Metropolitan Area. *Int. J. Remote Sens.* **2010**, *23*, 1775–1798. [CrossRef]
30. Yang, X.; Lo, C.P. Drivers of Land-Use/Land-Cover Changes and Dynamic Modeling for the Atlanta, Georgia Metropolitan Area. *Photogramm. Eng. Remote Sens.* **2002**, *68*, 1073–1082.
31. Yuan, F.; Sawaya, K.E.; Loeffelholz, B.C.; Bauer, M.E. Land Cover Classification and Change Analysis of the Twin Cities (Minnesota) Metropolitan Area by Multitemporal Landsat Remote Sensing. *Remote Sens. Environ.* **2005**, *98*, 317–328. [CrossRef]
32. Dewan, A.M.; Yamaguchi, Y. Using Remote Sensing and GIS to Detect and Monitor Land Use and Land Cover Change in Dhaka Metropolitan of Bangladesh during 1960–2005. *Environ. Monit. Assess.* **2008**, *150*, 237–249. [CrossRef] [PubMed]
33. Bagan, H.; Yamagata, Y. Land-Cover Change Analysis in 50 Global Cities by Using a Combination of Landsat Data and Analysis of Grid Cells. *Environ. Res. Lett.* **2014**, *9*, 1–13. [CrossRef]
34. Corbane, C.; Sabo, F.; Syrris, V.; Kemper, T.; Politis, P.; Pesaresi, M.; Soille, P.; Osé, K. Application of the Symbolic Machine Learning to Copernicus VHR Imagery: The European Settlement Map. *IEEE Geosci. Remote Sens. Lett.* **2020**, *17*, 1153–1157. [CrossRef]
35. Pesaresi, M.; Corbane, C.; Julea, A.; Florczyk, A.J.; Syrris, V.; Soille, P. Assessment of the Added-Value of Sentinel-2 for Detecting Built-Up Areas. *Remote Sens.* **2016**, *8*, 299. [CrossRef]
36. Haas, J.; Ban, Y. Sentinel-1A SAR and Sentinel-2A MSI Data Fusion for Urban Ecosystem Service Mapping. *Remote Sens. Appl. Soc. Environ.* **2017**, *8*, 41–53. [CrossRef]
37. Liu, C.; Huang, X.; Zhu, Z.; Chen, H.; Tang, X.; Gong, J. Automatic Extraction of Built-Up Area from ZY3 Multi-View Satellite Imagery: Analysis of 45 Global Cities. *Remote Sens. Environ.* **2019**, *226*, 51–73. [CrossRef]
38. Weber, C.; Puissant, A. Urbanization Pressure and Modeling of Urban Growth: Example of the Tunis Metropolitan Area. *Remote Sens. Environ.* **2002**, *86*, 341–352. [CrossRef]
39. Zhou, W.; Troy, A.; Grove, M. Object-Based Land Cover Classification and Change Analysis in the Baltimore Metropolitan Area Using Multitemporal High Resolution Remote Sensing Data. *Sensors* **2008**, *8*, 1613–1636. [CrossRef]

40. McConnachie, M.M.; Shackleton, C.M. Public Green Space Inequality in Small Towns in South Africa. *Habitat Int.* **2010**, *34*, 244–248. [[CrossRef](#)]
41. Gismalla, Y.A.; Bruen, M. Use of a GIS in Reconnaissance Studies for Small-Scale Hydropower Development in a Developing Country: A Case Study from Tanzania. *IAHS Publ. Ser. Proc. Rep. Intern Assoc. Hydrol. Sci.* **1996**, *235*, 307–312.
42. Weng, Q. Modeling Urban Growth Effects on Surface Runoff with the Integration of Remote Sensing and GIS. *Environ. Manag.* **2001**, *28*, 737–748. [[CrossRef](#)]
43. Wright, J.; Liu, J.; Bain, R.; Perez, A.; Crocker, J.; Bartram, J.; Gundry, S. Water Quality Laboratories in Colombia: A GIS-Based Study of Urban and Rural Accessibility. *Sci. Total. Environ.* **2014**, *485–486*, 643–652. [[CrossRef](#)]
44. Stoica, I.-V.; Tulla, A.F.; Zamfir, D.; Petrișor, A.-I. Exploring the Urban Strength of Small Towns in Romania. *Soc. Indic. Res.* **2020**, *152*, 843–875. [[CrossRef](#)]
45. Cieślak, I.; Biłozor, A.; Szuniewicz, K. The Use of the CORINE Land Cover (CLC) Database for Analyzing Urban Sprawl. *Remote Sens.* **2020**, *12*, 282. [[CrossRef](#)]
46. Li, S.; Zhou, C.; Wang, S.; Gao, S.; Liu, Z. Spatial Heterogeneity in the Determinants of Urban Form: An Analysis of Chinese Cities with a GWR Approach. *Sustainability* **2019**, *11*, 479. [[CrossRef](#)]
47. Bitter, C.; Mulligan, G.F.; Dall'erba, S. Incorporating Spatial Variation in Housing Attribute Prices: A Comparison of Geographically Weighted Regression and the Spatial Expansion Method. *J. Geogr. Syst.* **2007**, *9*, 7–27. [[CrossRef](#)]
48. Ganguly, K.; Kumar, R.; Reddy, K.M.; Rao, P.J.; Saxena, M.R.; Shankar, G.R. Optimization of Spatial Statistical Approaches to Identify Land Use/Land Cover Change Hot Spots of Pune Region of Maharashtra Using Remote Sensing and GIS Techniques. *Geocarto Int.* **2017**, *32*, 777–796. [[CrossRef](#)]
49. Zhao, F.; Tang, L.; Qiu, Q.; Wu, G. The Compactness of Spatial Structure in Chinese Cities: Measurement, Clustering Patterns and Influencing Factors. *Ecosyst. Health Sustain.* **2020**, *6*, 1743763. [[CrossRef](#)]
50. Ivajnšič, D.; Kaligarič, M.; Žiberna, I. Geographically Weighted Regression of the Urban Heat Island of a Small City. *Appl. Geogr.* **2014**, *53*, 341–353. [[CrossRef](#)]
51. Brunsdon, C.; Fotheringham, A.S.; Charlton, M.E. Geographically Weighted Regression: A Method for Exploring Spatial Nonstationarity. *Geogr. Anal.* **1996**, *28*, 281–298. [[CrossRef](#)]
52. Gao, J.; Li, S. Detecting Spatially Non-Stationary and Scale-Dependent Relationships between Urban Landscape Fragmentation and Related Factors Using Geographically Weighted Regression. *Appl. Geogr.* **2011**, *31*, 292–302. [[CrossRef](#)]
53. Royuela, V.; Moreno, R.; Vayá, E. Influence of Quality of Life on Urban Growth: A Case Study of Barcelona, Spain. *Reg. Stud.* **2010**, *44*, 551–567. [[CrossRef](#)]
54. Bagan, H.; Yamagata, Y. Analysis of Urban Growth and Estimating Population Density Using Satellite Images of Nighttime Lights and Land-Use and Population Data. *GISci. Remote Sens.* **2015**, *52*, 765–780. [[CrossRef](#)]
55. Noresah, M.S.; Ruslan, R. Modelling Urban Spatial Structure Using Geographically Weighted Regression. In Proceedings of the 18th World IMACS Congress and MODSIM09 International Congress on Modelling and Simulation, The Australian National University Canberra, Cairns, QLD, Australia, 13–17 July 2009.
56. Shariff, N.M.; Gairola, S.; Talib, A. Modelling Urban Land Use Change Using Geographically Weighted Regression and the Implications for Sustainable Environmental Planning. In Proceedings of the 5th Biennial Conference of the International Environmental Modelling and Software Society, iEMSs 2010, Ottawa, ON, Canada, 5–8 July 2010.
57. Kwiatek-Sołtys, A. Small Towns in Poland—Barriers and Factors of Growth. *Procedia Soc. Behav. Sci.* **2011**, *19*, 363–370. [[CrossRef](#)]
58. Jażewicz, I. Rola Małych Miast w Przestrzeni Rolniczej Pomorza Środkowego. *Studia Obsz. Wiej.* **2006**, *11*, 159–172.
59. Jażewicz, I. Przemiany Społeczno-Demograficzne i Gospodarcze w Małych Miastach Pomorza Środkowego w Okresie Transformacji Gospodarczej. *Studiopolskie Pr. Geogr.* **2005**, *2*, 71–79.
60. Han, S.S. Urban Expansion in Contemporary China: What Can We Learn from a Small Town? *Land Use Policy* **2010**, *27*, 780–787. [[CrossRef](#)]
61. White, A. Informal Practices, Unemployment, and Migration in Small-Town Poland. *East. Eur. Politics Soc.* **2015**, *30*, 404–422. [[CrossRef](#)]
62. Parysek, J.J. Development of Polish Towns and Cities and Factors Affecting this Process at the Turn of the Century. *Geogr. Pol.* **2005**, *78*, 99–115.
63. Nilsson, P. Natural Amenities in Urban Space—A Geographically Weighted Regression Approach. *Landsc. Urban Plan.* **2014**, *121*, 45–54. [[CrossRef](#)]
64. Zuzańska-Żyśko, E. Economic Transformation of Small Silesian Towns in the Years 1990–1999. *Geogr. Pol.* **2005**, *78*, 136–149.
65. Wear, D.N.; Bolstad, P. Land-Use Changes in Southern Appalachian Landscapes: Spatial Analysis and Forecast Evaluation. *Ecosystems* **1998**, *1*, 575–594. [[CrossRef](#)]
66. Handavu, F.; Chirwa, P.W.C.; Syampungani, S. Socio-Economic Factors Influencing Land-Use and Land-Cover Changes in the Miombo Woodlands of the Copperbelt Province in Zambia. *For. Policy Econ.* **2019**, *100*, 75–94. [[CrossRef](#)]
67. Adamiak, M.; Biczkowski, M.; Leśniewska-Napierala, K.; Nalej, M.; Napierala, T. Impairing Land Registry: Social, Demographic, and Economic Determinants of Forest Classification Errors. *Remote Sens.* **2020**, *12*, 2628. [[CrossRef](#)]

68. In 1642 Rozporządzenie Ministra Spraw Wewnętrznych i Administracji z Dnia 17 Listopada 2011r. w Sprawie Bazy Danych Obiektów Topograficznych Oraz Bazy Danych Obiektów Ogólnogeograficznych, a También Standardowych Opracowań Kartograficznych. In *Dz.U.* 2011 nr 279 poz.; The President of the Council of Ministers: Warsaw, Poland, 2011; Volume 279, pp. 16096–16099.
69. Chen, L.-C.; Papandreou, G.; Schroff, F.; Adam, H. Rethinking Atrous Convolution for Semantic Image Segmentation. *arXiv* **2017**, arXiv:1706.05587.
70. Chollet, F. Xception: Deep Learning with Depthwise Separable Convolutions. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, HI, USA, 21 July 2017; pp. 1251–1258.
71. TensorFlow. Available online: <https://www.tensorflow.org/> (accessed on 30 January 2021).
72. Lin, T.-Y.; Dollár, P.; Girshick, R.; He, K.; Hariharan, B.; Belongie, S. Feature Pyramid Networks for Object Detection. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, HI, USA, 21–26 July 2017; pp. 2117–2125.
73. Ronneberger, O.; Fischer, P.; Brox, T. U-Net: Convolutional Networks for Biomedical Image Segmentation. In Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention, Munich, Germany, 5–9 October 2015; pp. 234–241.
74. Lin, T.-Y.; Goyal, P.; Girshick, R.; He, K.; Dollár, P. Focal Loss for Dense Object Detection. In Proceedings of the IEEE International Conference on Computer Vision, Venice, Italy, 22–29 October 2017; pp. 2980–2988.
75. Zhao, H.; Shi, J.; Qi, X.; Wang, X.; Jia, J. Pyramid Scene Parsing Network. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, HI, USA, 26 July 2017; pp. 2881–2890.
76. Bertels, J.; Eelbode, T.; Berman, M.; Vandermeulen, D.; Maes, F.; Bisschops, R.; Blaschko, M.B. Optimizing the Dice Score and Jaccard Index for Medical Image Segmentation: Theory and Practice. In Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention, Shenzhen, China, 13–17 October 2019; pp. 92–100.
77. Shen, H.; Li, H.; Qian, Y.; Zhang, L.; Yuan, Q. An Effective Thin Cloud Removal Procedure for Visible Remote Sensing Images. *ISPRS J. Photogramm. Remote Sens.* **2014**, *96*, 224–235. [CrossRef]
78. Gao, J.; Yuan, Q.; Li, J.; Zhang, H.; Su, X. Cloud Removal with Fusion of High Resolution Optical and SAR Images Using Generative Adversarial Networks. *Remote Sens.* **2020**, *12*, 191. [CrossRef]
79. Meraner, A.; Ebel, P.; Zhu, X.X.; Schmitt, M. Cloud Removal in Sentinel-2 Imagery Using a Deep Residual Neural Network and SAR-Optical Data Fusion. *ISPRS J. Photogramm. Remote Sens.* **2020**, *166*, 333–346. [CrossRef] [PubMed]
80. Getis, A. Spatial Autocorrelation. In *Handbook of Applied Spatial Analysis*; Fischer, M.M., Getis, A., Eds.; Springer: Berlin, German, 2010; pp. 255–278.
81. Anselin, L.; Getis, A. Spatial Statistical Analysis and Geographic Information Systems. *Ann. Reg. Sci.* **1992**, *26*, 19–33. [CrossRef]
82. Ord, J.K.; Getis, A. Local Spatial Autocorrelation Statistics: Distributional Issues and an Application. *Geogr. Anal.* **1995**, *27*, 286–306. [CrossRef]
83. Brown, D.G.; Duh, J.-D. Spatial Simulation for Translating from Land Use to Land Cover. *Int. J. Geogr. Inf. Sci.* **2004**, *18*, 35–60. [CrossRef]
84. Fotheringham, A.S.; Brunsdon, C.; Charlton, M. *Geographically Weighted Regression: The Analysis of Spatially Varying Relationships*; John Wiley & Sons: Chichester, UK, 2002.
85. Brunsdon, C.; Fotheringham, A.S.; Charlton, M. Some Notes on Parametric Significance Tests for Geographically Weighted Regression. *J. Reg. Sci.* **1999**, *39*, 497–524. [CrossRef]
86. Brunsdon, C.; Fotheringham, S.; Charlton, M. *Geographically Weighted Regression as a Statistical Model*; University of Newcastle-upon-Tyne: Newcastle, UK, 2000.
87. Matthews, S.A.; Yang, T.C. Mapping the Results of Local Statistics: Using Geographically Weighted Regression. *Demogr. Res.* **2012**, *26*, 151–166. [CrossRef]
88. Mennis, J. Mapping the Results of Geographically Weighted Regression. *Cartogr. J.* **2006**, *43*, 171–179. [CrossRef]
89. Corbane, C.; Syrris, V.; Sabo, F.; Politis, P.; Melchiorri, M.; Pesaresi, M.; Soille, P.; Kemper, T. Convolutional Neural Networks for Global Human Settlements Mapping from Sentinel-2 Satellite Imagery. *Neural Comput. Appl.* **2020**, *1*–24. [CrossRef]
90. Ettehadi Osgouei, P.; Kaya, S.; Sertel, E.; Algancı, U. Separating Built-Up Areas from Bare Land in Mediterranean Cities Using Sentinel-2A Imagery. *Remote Sens.* **2019**, *11*, 345. [CrossRef]
91. Sinha, P.; Verma, N.K.; Ayele, E. Urban Built-up Area Extraction and Change Detection of Adama Municipal Area Using Time-Series Landsat Images. *Int. J. Adv. Remote Sens. GIS* **2016**, *5*, 1886–1895. [CrossRef]
92. Konecka-Szydłowska, B.; Zuzańska-Żyśko, E.; Szmytkie, R. Role of Services in the Economies of Small Towns of Silesia Region and Wielkopolskie Voivodeship. *Bull. Geogr. Socio Econ. Ser.* **2010**, *14*, 51–62. [CrossRef]
93. Jaźdżewska, I. Urban Network in Poland during Last Millennium. *Konwersatorium Wiedzy Mieście* **2020**, *5*, 7–20. [CrossRef]
94. Kobojek, E.; Marszał, T. Local development and the role of small towns in space organisation in contemporary Poland. In *Spatial Development of Contemporary Poland in Łódź University Geographical Research*; Marszał, T., Ed.; Łódź University Press: Łódź, Poland, 2014; pp. 37–60.
95. Lamprecht, M. Small Towns and Development of Rural Areas: The Case of the Voivodship of Łódź. *Eur. Spat. Res. Policy* **2004**, *11*, 41–56.

96. Jaźdżewska, I. Rola małych miast w miejskiej sieci osadniczej Polski. In *Podstawy i Perspektywy Rozwoju Małych Miast*; Rydz, E., Ed.; Akademia Pomorska w Słupsku: Słupsk, Poland, 2007; pp. 31–46.
97. Shubho, M.T.H.; Islam, I. An Integrated Approach to Modeling Urban Growth Using Modified Built-Up Area Extraction Technique. *Int. J. Environ. Sci. Technol.* **2020**, *17*, 1–18. [[CrossRef](#)]

Publikacja nr 4:

Adamiak, M., Będkowski, K., Majchrowska, A. (2021). *Aerial Imagery Feature Engineering Using Bidirectional Generative Adversarial Networks: A Case Study of the Pilica River Region*, Poland. *Remote Sensing*, 13(2), 306, <https://doi.org/10.3390/rs13020306>

MEiN: 100, IF'20: 4.848, CiteScore'21: 6,9.

Article

Aerial Imagery Feature Engineering Using Bidirectional Generative Adversarial Networks: A Case Study of the Pilica River Region, Poland

Maciej Adamiak ^{1,*}, Krzysztof Będkowski ² and Anna Majchrowska ³

¹ SoftwareMill, 02-791 Warsaw, Poland

² Faculty of Geographical Sciences, Institute of Urban Geography, Tourism and Geoinformation, University of Łódź, 90-139 Łódź, Poland; krzysztof.bedkowski@geo.uni.lodz.pl

³ Department of Physical Geography, Faculty of Geographical Sciences, University of Łódź, 90-139 Łódź, Poland; anna.majchrowska@geo.uni.lodz.pl

* Correspondence: maciej.adamiak@softwaremill.com

Abstract: Generative adversarial networks (GANs) are a type of neural network that are characterized by their unique construction and training process. Utilizing the concept of the latent space and exploiting the results of a duel between different GAN components opens up interesting opportunities for computer vision (CV) activities, such as image inpainting, style transfer, or even generative art. GANs have great potential to support aerial and satellite image interpretation activities. Carefully crafting a GAN and applying it to a high-quality dataset can result in nontrivial feature enrichment. In this study, we have designed and tested an unsupervised procedure capable of engineering new features by shifting real orthophotos into the GAN's underlying latent space. Latent vectors are a low-dimensional representation of the orthophoto patches that hold information about the strength, occurrence, and interaction between spatial features discovered during the network training. Latent vectors were combined with geographical coordinates to bind them to their original location in the orthophoto. In consequence, it was possible to describe the whole research area as a set of latent vectors and perform further spatial analysis not on RGB images but on their lower-dimensional representation. To accomplish this goal, a modified version of the big bidirectional generative adversarial network (BigBiGAN) has been trained on a fine-tailored orthophoto imagery dataset covering the area of the Pilica River region in Poland. Trained models, precisely the generator and encoder, have been utilized during the processes of model quality assurance and feature engineering, respectively. Quality assurance was performed by measuring model reconstruction capabilities and by manually verifying artificial images produced by the generator. The feature engineering use case, on the other hand, has been presented in a real research scenario that involved splitting the orthophoto into a set of patches, encoding the patch set into the GAN latent space, grouping similar patches latent codes by utilizing hierarchical clustering, and producing a segmentation map of the orthophoto.



Citation: Adamiak, M.; Będkowski, K.; Majchrowska, A. Aerial Imagery Feature Engineering Using Bidirectional Generative Adversarial Networks: A Case Study of the Pilica River Region, Poland. *Remote Sens.* **2021**, *13*, 306. <https://doi.org/10.3390/rs13020306>

Received: 20 December 2020

Accepted: 14 January 2021

Published: 17 January 2021

Publisher's Note: MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



Copyright: © 2021 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

There is no doubt that aerial imagery is a source of valuable information about geographical space. The rapid development of remote sensing technology supported by a significant improvement in access to remote sensing imagery [1] led to an increased interest in the potential use of the collected material among academia, government, and private sector representatives in areas such as urban planning, agriculture, transport, etc. Substantial quantities of image data have become available in recent years thanks to opening public access to images acquired by satellites such as Landsat 8 [2], Sentinel-2

A/B [3], and Pléiades [4]. Furthermore, due to the epidemiological situation in Poland, the government decided to open access to national orthophoto resources [5]. Access to high-quality and properly curated image repositories undoubtedly promotes the development of new ideas and contributes to the emergence of various methods and techniques for analyzing collected data.

The use of aerial and satellite images in the basic task of remote sensing that deals with land cover and land use classification is indisputable. At an early stage of remote sensing development, the possibility of distinguishing certain spatial units by interpreting the spectral, textural, and structural features of the image was indicated. Olędzki postulated extracting homogenous fragments of satellite images called photomorphic units. These units were similar in terms of structure and texture and originated from natural processes and man-made transformations of the environment [6,7]. Descriptive definitions of image features were soon replaced by mathematical formulas [8]. Further development has led to the introduction of object classification procedures, in which, in addition to the brightness parameters of the image pixels, their neighborhood and the shape and size of the distinguished objects were taken into account [9]. Object-oriented analysis is based on databases and fuzzy logic. Probably the most popular implementation of this paradigm in remote sensing applications is in the one originally developed in eCognition [10]. These techniques have been successfully applied to research on landscape structure and forestry [11]. Referring to division units used in physico-geographic regionalization [12,13], Corine Land Cover [14,15], or for the purposes of ecological research [16,17], an additional meaning and hierarchical structure [18,19] can be also given to units distinguished from the landscape. At the same time, it is important to properly take care of the appropriate adjustments of the scale of the study and data relevant for the analyzed problem, so as not to overlook important features of the area that may affect the reliability of the analysis, i.e., to mitigate the issues connected with spatial object scaling and the scale problem [20]. What is important is that the separation of landscape units cannot be based only on image data [21]. It is also necessary to take into account data on lithology, morphogenesis, terrain, geodiversity [22], water, and vegetation. The latter is interesting due to the fact that vegetation is represented in remote sensing imagery to the greatest extent both in terms of properties and structure. Therefore, it has great potential for being utilized in landscape quantification [23]. It should be mentioned that the process of identifying landscape units is also affected by human activity and created by the cultural landscape. Another major achievement in remote sensing image classification is the introduction of algorithms based on neural networks [24].

The influence of machine learning and deep learning on contemporary remote sensing techniques and their support in geographical space analysis is undeniable [25]. There are multiple fascinating applications of machine learning (ML) and deep learning (DL) in the remote sensing domain like land use classification [26], forest area semantic segmentation [27], species detection [28], recognition of patches of alpine vegetation [29,30], classification of urban areas [31], roads detection [32], etc.

What a significant part of these studies have in common is the focus on utilizing convolutional neural network (CNN) architectures capable of solving problems that can be brought down to traditional computer vision (CV) tasks like semantic segmentation, instance segmentation, or classification. This is directly associated with the underlying mechanism that enables the network to encode complex image features. CNN's convolutional filters are gradually trained to gain the ability to detect the presence of specific patterns. Frequently, the training routine is performed in a supervised manner. The model is presented with target data and uses it to learn the solution. Supervised learning is capable of achieving extraordinary results but at the same time relies on access to manually labeled data. Another incredibly interesting approach is to train the neural network without any pre-existing labels to let it discover the patterns on its own. Although unsupervised learning algorithms like clustering are well-known among remote sensing researchers, utilizing convolutional neural networks is still to gain trust. The way of training a neural network can be even more intriguing when you exchange human supervision with machine

supervision, and let multiple neural networks control their learning progress and work like adversaries.

Generative adversarial networks (GANs) are constructed from at least one discriminator and one generator network. The main goal of these two networks is to compete with each other in the form of a two-player minimax game [33]. The generator tries to deceive the discriminator by producing artificial samples, and the discriminator assesses whether it is dealing with real or generator-originating samples. The generator network is producing samples from a specified data distribution by transforming vectors of noise [34]. This technique was successfully applied in multiple remote sensing activities from upsampling satellite imagery [35], deblurring [36] to artificial sample generation [37]. GANs' artificial data creation capabilities are not the only aspect that makes them interesting for remote sensing. When exploring the theory behind GANs, one should observe that, to perform its work, the generator retains all the information needed to produce a complex sample using only a much simpler representation called the latent code [33]. In terms of spatial analysis, this means that the network is able to produce a realistic image of an area using only a handful of configuration parameters as input. In the classic approach to GANs, this image recipe is reserved only for artificially generated samples. It was the introduction of bidirectional GANs and adversarial feature learning [38] that allowed to extract the latent code from ground truth (real) samples. The novelty of this approach when applied to aerial imagery is that it allows performing advanced spatial analysis using lower-dimensional representations of the orthophoto computed by a state-of-the-art neural network rather than utilizing raw image data. This method resembles algorithms like principal component analysis (PCA) but, instead of treating the image on the pixel level, it operates on the spatial features level and, therefore, offers a richer analysis context. The projection, a latent vector, serves as a lightweight representation of the image and holds information about the strength, occurrence, and interaction between spatial features discovered during the network training. This interesting capability opens up new possibilities for geographical space interpretation such as

- extracting features to fit in a variety of machine learning and spatial analysis algorithms like geographically weighted regression, support vector machines, etc.;
- minimizing resource consumption when processing large areas;
- discovering new features of analyzed areas by carefully exploring the network latent space.

The principal goal of our study is to evaluate the potential of bidirectional generative adversarial networks in remote sensing feature engineering activities and unsupervised segmentation. Therefore, the following hypotheses have been defined:

1. The image reconstruction process is strong enough to produce artificial images that closely resemble the original;
2. Similar orthophoto patches can produce latent space codes that are close to each other in the network latent space, therefore, preserving the similarity after encoding;
3. Latent codes enhanced by geographical coordinates can serve as artificial features used during geographical space interpretation by classical algorithms such as agglomerative clustering.

2. Materials and Methods

Figure 1 presents an overview of the proposed procedure composed of the following steps: preparing an orthophoto patches dataset, training the big bidirectional generative adversarial network (BigBiGAN), utilizing the network encoding module to convert orthophoto patches to their latent codes, enriching the data with geographical coordinates, and performing geospatial clustering on enriched latent codes.

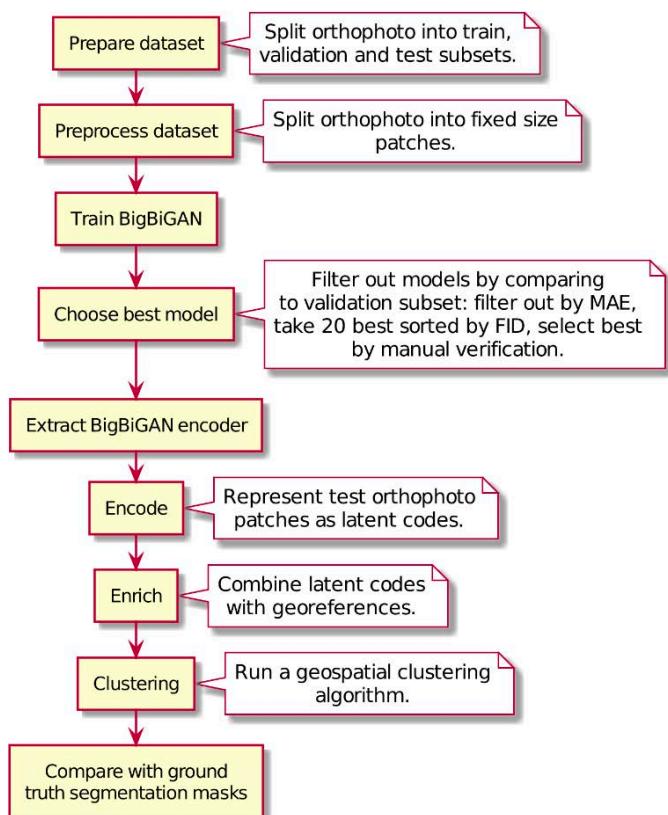


Figure 1. Investigation overview.

2.1. Research Area

To be able to produce precise results, generative models need to be trained on high-quality datasets. The dataset needs to be large enough to cover the variety of spatial features that the encoder will be able to utilize when interpreting the input image. The authors decided to utilize RGB orthophotos of the Pilica River and Sulejowski Reservoir regions in Poland. The area from which the samples have been obtained includes the Pilica River valley between Maluszyn and Tomaszów Mazowiecki together with adjacent areas (see Figure 2).

According to the physico-geographical regionalization of Poland [13], the southern and eastern parts of the area are located in the province of Polish Uplands, the macroregion of the Przedbórz Upland, the mesoregions of Włoszczowa Basin, Radomsko Hills, Przedbórz-Małogoszcz Range, and Opoczno Hills. The northwestern part is located in the mesoregions of the Piotrków Plain and the Białobrzegi Valley, which are part of the South Mazovian Hills macroregion in the Central European Lowland Province. The consequence of the location in the border zone of the Polish Uplands and the Central European Lowland is the interpenetration of features characteristic of both provinces and the relative diversification of the natural environment of the area.

According to the tectonic regionalization [39], a fragment of the area located south of Przedbórz includes the Szczecin–Miechów Synclinorium, constructed mainly from Cretaceous rock formations. The rest of the area belongs to the Mid-Polish Anticlinorium, dominated by Jurassic carbonate rocks.

The axis of the selected area is the Pilica River valley. The chosen section of the valley is in a natural condition. The Pilica River flows in an unregulated, sinuous to a meandering channel that is not embanked along its entire length from Maluszyn to the vicinity of Sulejów. There, it reaches the Smardzewice dam waters of the Sulejowski Reservoir. The valley floor descends from 211 m above sea level in the south to 154 m above sea level in the north, and the stream gradient equals 0.51%. The width of the valley varies from about 300 m in the vicinity of Sulejów and Przedbórz to over 3 km near Łęg Ręczyński. It reaches

its greatest width in places of well-formed levels of over-flood terraces occurring on both sides of the floodplain.

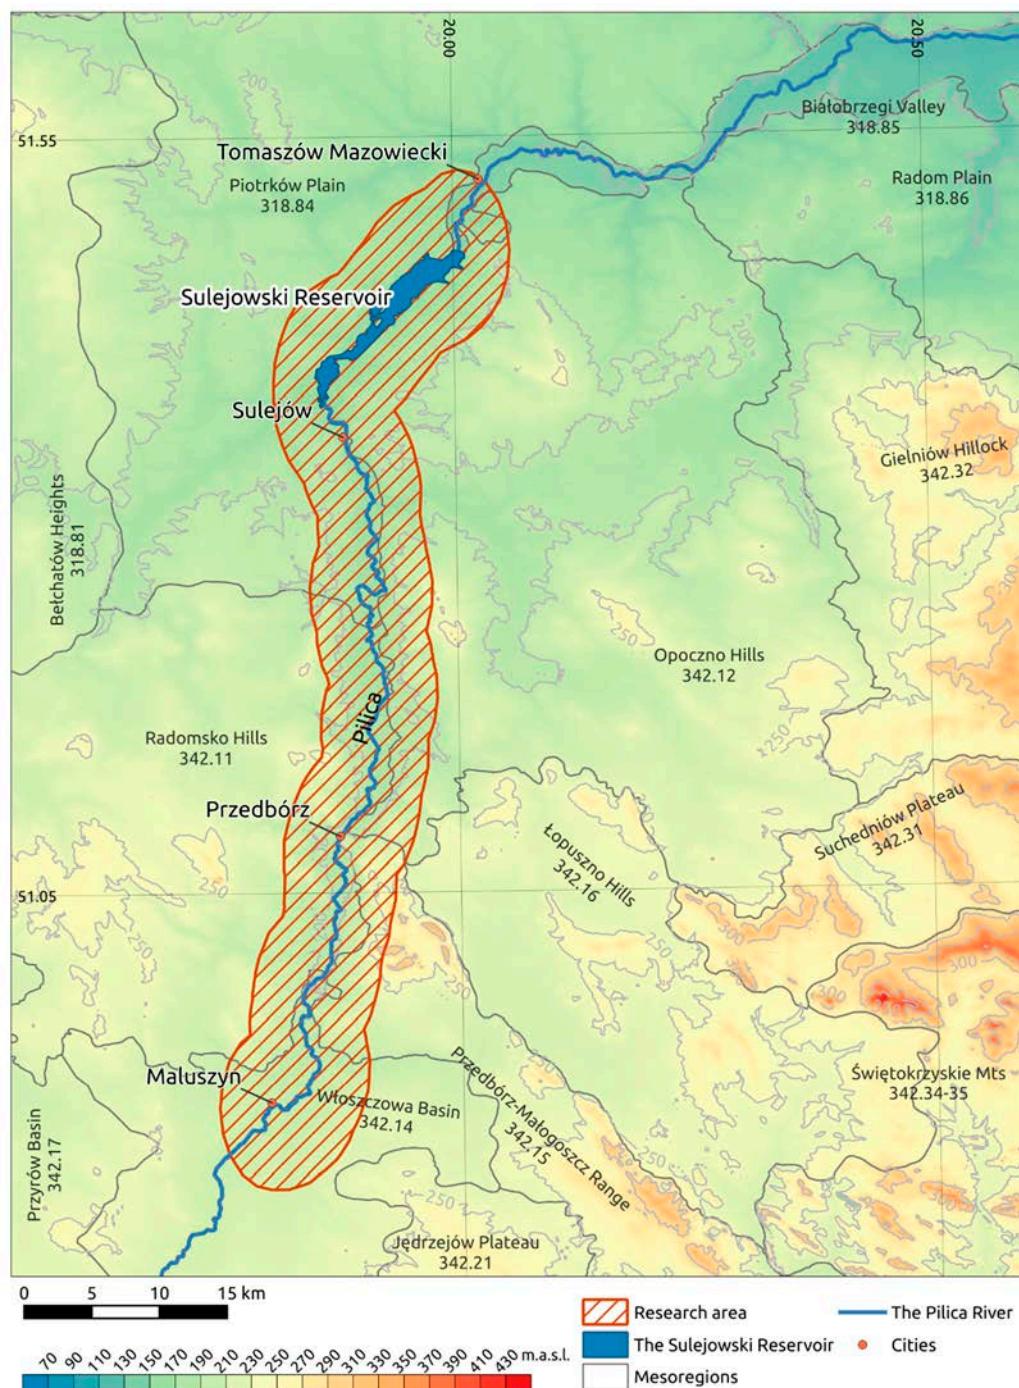


Figure 2. Research area, source: own elaboration based on physico-geographical regionalization of Poland [13] and Head Office of Geodesy and Cartography data [40]. Mesoregions codes are consistent with those introduced in the referenced paper and therefore enable precise localization of the research area within Polish mesoregions.

The valley cuts down the adjacent plain and undulating moraine uplands to about 20–25 m. These landforms were formed in the Quaternary, mainly during the Pleistocene glaciations of the Middle Polish Complex. Within the uplands on both sides of the Pilica River, the thickness of Quaternary sediments decreases from the north to the south. The surface area of Mesozoic outcrops increases, which is a result of the weakening of the

landforming capacity of the ice sheets as they entered the uplands. Absolute heights of culminations, in the form of isolated hills built of Mesozoic Jurassic and Cretaceous rocks within the Radomsko and Opoczno Hills, are also increasing, e.g., Diabla Góra 272 m, Czartoria Range 267 m, Bąkowa Góra 282 m, the form of ridges in the Przedbór-Małogoszcz Range exceeding 300 m above sea level, or Bukowa Góra 336 m.

The varied topography and the near-surface geological structures, in addition to the humidity conditions, shape the mosaic of land cover types. The area is poorly urbanized. The ground moraine plateaus are dominated by arable land, fluvioglacial plains, and other sandy areas largely occupied by forests and abandoned arable lands. In the valley, the over-flood terraces are characterized by complex systems of arable land, fallow land, forests, and meadows. The floodplain is dominated by meadows and pastures, in many places overgrown with shrubs and trees after their agricultural use ceased [41].

2.2. Dataset

The Pilica River region dataset covers the area of 691.86 km² and was generated using 138 orthophoto sheets that intersect with a 4 km buffer around the Pilica River from Sulejów to Maluszyn and Sulejowski Reservoir in Łódź Voivodeship in Poland. All orthophotos were acquired using GEOPORTAL2 [42] and possess three channels—R-red, G-green, and B-blue with 25 cm pixel ground sample distance (see Figure 3).

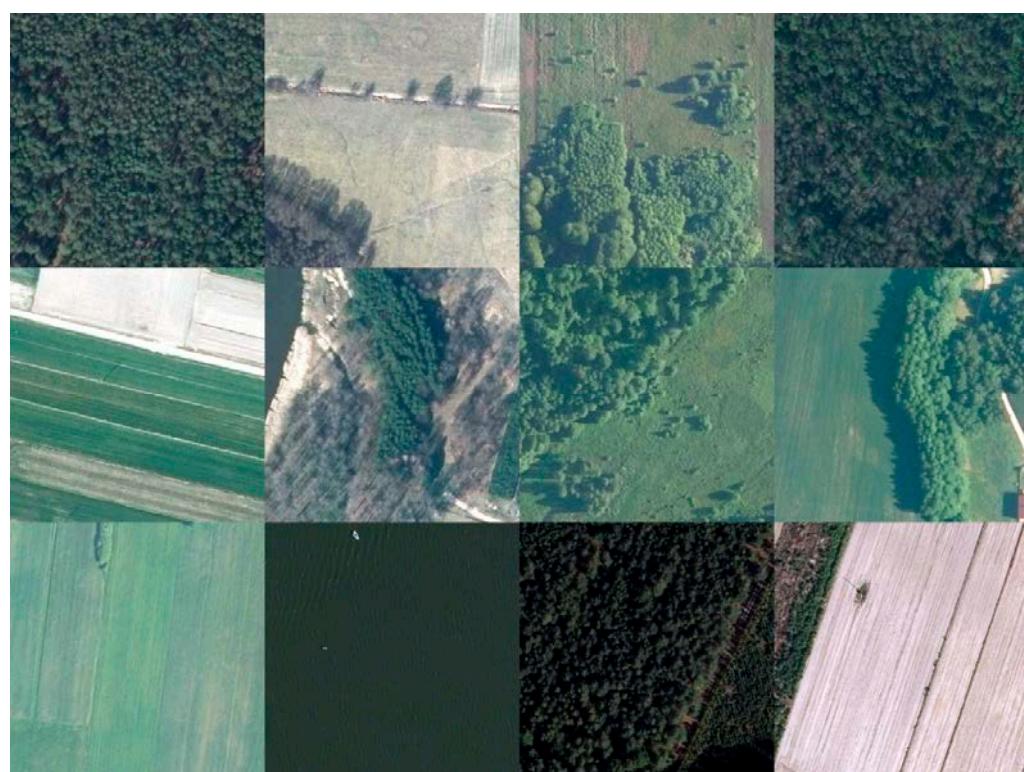


Figure 3. Examples of the Pilica River region dataset samples (512 px × 512 px patches). From the upper left corner: forest and a barely visible forest path outline, farmlands cut by a sandy road planted with trees, forest with an adjacent land abandonment, forest, farmlands, river valley, forest and an overgrown meadow, forest with clearly outlined shadow and a dirt road, farmlands, water reservoir, forest cut by a road, recently plowed farmland with balks, and a young forest.

During the preprocessing phase each image was split into 128 px × 128 px, 256 px × 256 px, 512 px × 512 px, and 1024 px × 1024 px patches. This step was crucial for electing the optimal image size and resizing approach to satisfy the requirements of the chosen neural network architecture and its internal complexity. The choice of image size directly influences hardware requirements, the ability of the neural network to learn image

features needed during the assessment of the reconstruction process, and, important from a GAN perspective, overall dataset size. It was highly important to utilize the patches large enough to be described by complete and interpretable spatial features. Image size also affects the size of the input and output tensors and the handful of technical parameters that a processing unit can handle. The authors decided that, during the research, a single GPU (Nvidia Titan RTX in US) and CPU (AMD Threadripper 1950 in US) will be used, and all computations have to fit their representative capacity. This is due to ensuring that the results can be reproduced without using a multi-GPU cluster. In consequence, the authors decided to utilize:

- A series of 256 px × 256 px patches for encoder input, which were resized from 512 px × 512 px patches using bilinear interpolation. Although 256 px × 256 px is either the network nor hardware limit, it gives the opportunity to choose a larger batch, which significantly affects BigBiGAN performance. Furthermore, 512 px × 512 px (128 m × 128 m) patch is richer in spatial information;
- A series of 128 px × 128 px patches for image discriminator input, explicitly defined by BigBiGAN architecture for 256 px × 256 px encoder input;
- A series of 128 px × 128 px patches for generator output, which were the minimal interpretable patch size.

Geographical references of each patch and source image metadata have been preserved to enable reprojecting the results back to their original location. Patches acquired from 137 images were divided, in accordance with the established practice of machine learning, into two subsets of 512 px × 512 px images in the following proportions 0.95 and 0.05, forming a training set (39826 patches) and validation set (2096 patches). Remaining images were also processed and formed two test sets—one containing 1224 (256 px × 256 px) patches and another containing 306 (512 px × 512 px) patches. The authors introduced an additional test set of 256 px × 256 px patches that were smaller than the defined training size to verify whether the solution is capable of handling input material potentially containing less spatial information than it was trained on.

Afterward, a data augmentation procedure was defined to increase the diversity of managed datasets by applying specified image transformations in a random manner. Augmentation of the dataset is important from the point of view of GAN because the network has a higher chance to adapt to different conditions such as lighting or spatial feature shape changes, and at the same time, less data is needed for the network to converge. The authors decided to utilize basic post-processing computer vision techniques, such as adding or subtracting a random value to all pixels in an image, blurring the image using gaussian kernels, applying random four-point perspective transformations, rotating with clipping, or flipping the image. What is important, each transformation was applied only during the training phase and the decision of whether to apply it was random. Finally, a TensorFlow data processing pipeline (US; Mountain View; California) was implemented to ensure that reading and augmenting the data would efficiently utilize all computational resources. The main goal was to support the GPU with constant data flow orchestrated by the CPU and enable shuffling across batches, which turned out to be crucial when working with complex network architectures and utilizing a relatively small batch size, i.e., below 128 samples.

2.3. Generative Adversarial Network

The authors decided to use the bidirectional generative neural network (BiGAN) [38] architecture as a starting point and gradually updated its elements to end up with the final solution closely resembling BigBiGAN. An interesting, proven property of these architectures is the ability to perform the inverse mapping from input data to the latent representation. This makes BiGAN and BigBiGAN great candidates to address the research problem, i.e., finding a transformation capable of mapping a multichannel image to a fixed size vector representation. BigBiGAN can be used to shift a real image to the latent space using the encoder network.

The resulting latent space code can be then utilized as generator input to reconstruct an image similar to the original encoder input. Achieving the same input and output is hard or even impossible due to the fact that the pixel-wise reconstruction quality is not even a task for bidirectional GANs, and therefore, there is no loss function assigned to assess it. One can think of reconstruction as a process of enabling a mechanism of lossy image compression and decompression that operates—not on pixel level—but feature level. The similarity measure can be chosen arbitrarily but has to have sufficient power to reliably score the resemblance of the input and output images passed through the encoder and generator. A high-quality encoder is powerful enough to store information regarding crucial spatial features of the input image, thus making it a great candidate for the main module in an automatic feature engineering mechanism to automatically generate large numbers of candidate properties and selecting the best by their information gain [43].

To avoid recreating an existing solution, the authors decided to focus on reusing the BigBiGAN design and adjusting it to processing orthophoto images (see Figure 4). BigBiGAN consists of five neural networks—a generator and an encoder, which are accompanied by discriminators that assess their performance in producing respectively artificial images and latent codes. Results from both intermediate discriminators are then combined by the main discriminator. In the research, a modification of BigBiGAN was utilized to tackle the problem of encoding orthophoto patches to the network underlying latent space. Although the generator and main discriminator architectures have been preserved, the encoder and intermediate discriminators went through a minor modification. As suggested in a study on the BigBiGAN [44], the RevNet model was simplified to reduce the number of parameters needed to train the encoder. Intermediate discriminators contained fewer multilayer perceptron modules (MLP), which were composed of smaller numbers of neurons. In consequence, this enabled the use of slightly bigger batches and, therefore, yielded better results at the cost of a training time increase. The final architecture was implemented in TensorFlow 2 and Keras. Figure 4 presents the final model training sequence blueprint.

2.4. Hierarchical Clustering

Latent space code is a 120-dimensional vector of real numbers produced by applying a GAN encoder on an orthophoto patch. Such code contains information regarding spatial features present in the scope of the encoded patch. Each part of the code controls the strength and occurrence of one or more spatial features discovered during the neural network training. One of the important features of the latent space is that codes that are closer to each other in terms of the Euclidean distance (L2 norm) are more similar in terms of the represented features, i.e., two forest area patches will be closer in the latent space than a forest area and farmland patches [45].

Furthermore, each patch holds information regarding its georeferences. To simplify further analyses, georeferences were expressed as the location of the patch center. Patch center geographical coordinates were preserved during the computation and combined with corresponding latent codes. This opened the possibility to describe a larger area, composed of multiple patches, in the form of a 120-dimensional point cloud where each point holds the information regarding its original location. The combination of georeferences and latent space code is called a georeferenced latent space for the purpose of this research (see Figure 5).

The similarity between patches, precisely between their encodings, and information regarding geographical location can serve as input for methods and techniques of geospatial clustering. During their research, the authors focused on utilizing hierarchical clustering to discover a predefined number of clusters in a patch dataset describing a single test orthophoto. Hierarchical clustering is a general family of clustering algorithms that build nested clusters by successively merging or splitting them [46]. The metric used for the merge strategy is determined by the linkage strategy. For the purpose of clustering the georeferenced latent space, Ward's linkage method [47] was used. Ward's method minimizes the sum of squared differences within all clusters. It is a variance-minimizing

approach and, in this sense, is similar to the k-means objective function but tackled with an agglomerative hierarchical approach. The connectivity matrix has been calculated using the k-nearest neighbors algorithm (*k*-NN).

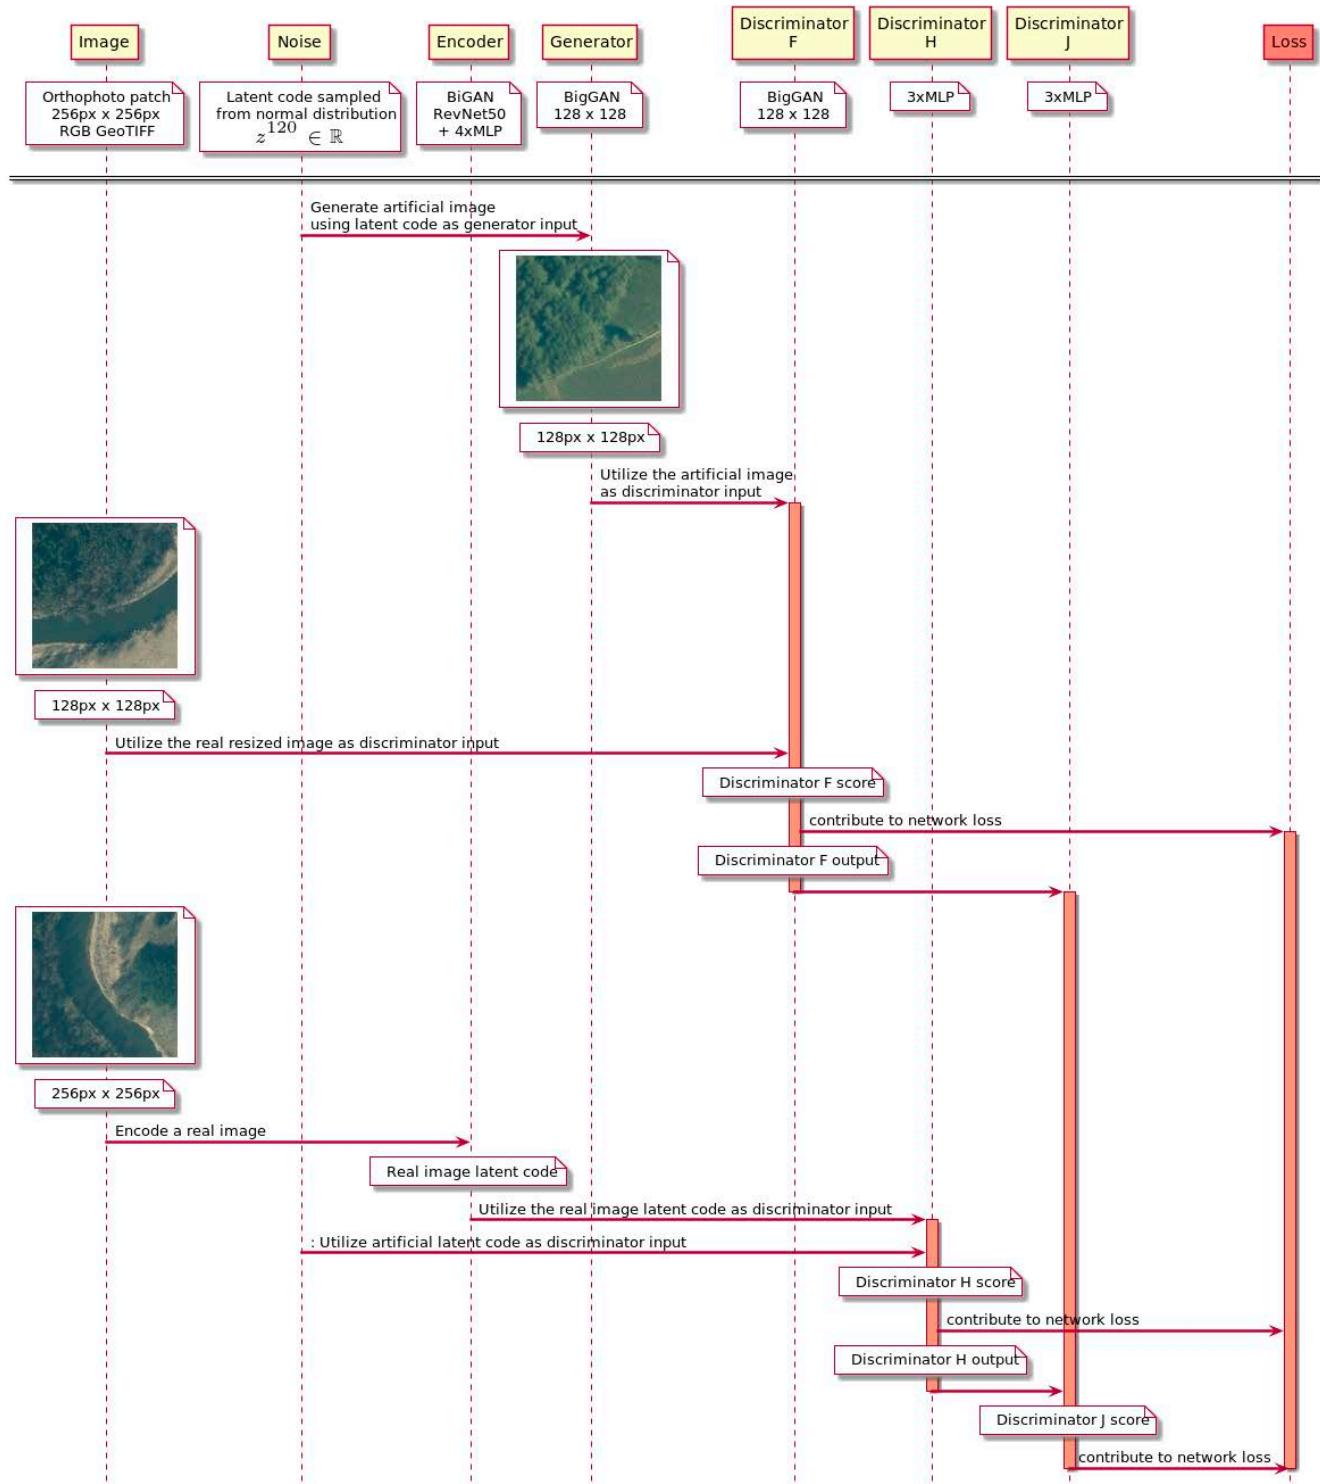


Figure 4. Big bidirectional generative adversarial network (BigBiGAN) training process.

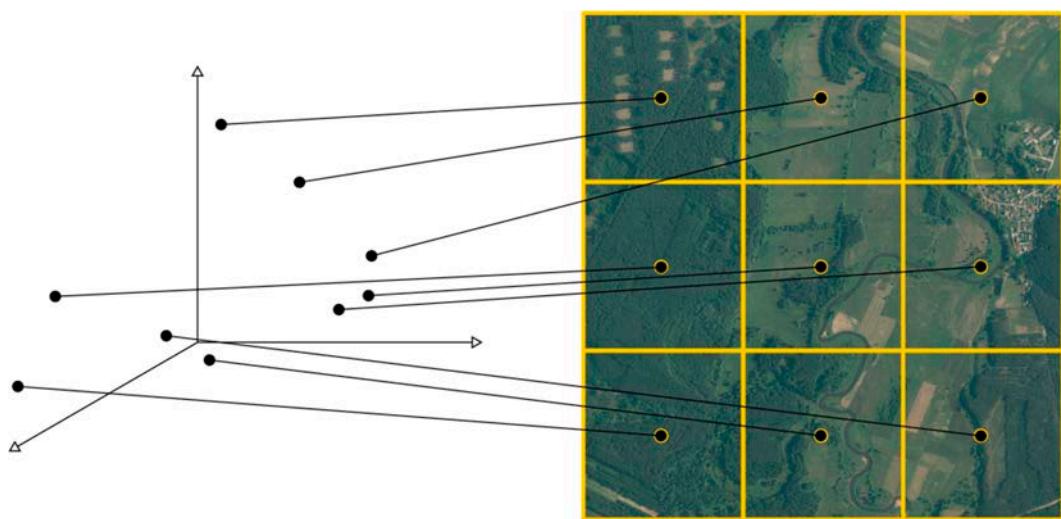


Figure 5. Latent space enhanced with geographical coordinates. The simplified image presents an example of encoding of the nine orthophoto patches (right) to a three-dimensional latent space (left) illustrated as a three-dimensional Cartesian coordinate system. Each latent code (a point in the latent space) carries additional information regarding georeferences that enables tracking its origin. Points that are closer in the three-dimensional latent space refer to patches that are visually similar. In the research, a 120-dimension latent space was trained.

3. Results

3.1. Model Training

Multiple model training session revealed that tackling the objective of training an orthophoto patch encoder is inseparably related to preparing generator and discriminator neural networks that are complex enough to learn all the features present in the input orthophoto. The networks have to be able to produce high-quality artificial images and determine whether the image is artificially generated or not, respectively. This directly influences the following:

- The overall size of the neural network, which is crucial due to GPU memory limitations and affects training duration;
- Maximum patch size that can be used as input during training and inference phases and is related to the level of detail offered in the processed dataset;
- Batch size, which has a significant influence on the stability and quality of generative adversarial models [44].

Initially chosen BiGAN architecture utilizes many concepts from previously designed networks such as deep convolutional GAN (DCGAN) [48] that, due to their simplicity, are not suitable for processing complex or large images. Therefore, their usefulness in the analysis of aerial imagery is limited. Although BiGAN offered all of the required earlier features, it was not capable of processing an orthophoto patch of size exceeding 32 pixels in both dimensions. This was a huge limitation due to the fact that, with a given 25 cm pixel ground sample distance, this method covered roughly the area of 64 m^2 . In consequence, the processed patch did not carry enough details to allow a reliable assessment of the similarity between real and artificial images. Attempts to increase the maximum processed input size led to swapping default BiGAN generator and discriminator models with other network types based on deep residual blocks [49] and inception modules [50]. The overall architecture of the generator and discriminator pair resembled BigGAN [51].

After multiple experiments, the authors confirmed that, despite the ability to generate images up to $512 \text{ px} \times 512 \text{ px}$, the network was not capable of learning a reliable bidirectional mapping between the image and the latent space. This was due to the fact that the encoder architecture was lacking in comparison with its powerful counterparts. This problem has been addressed and mitigated in the paper describing large adversarial features learning and the big bidirectional generative adversarial network (BigBiGAN) [44] by introducing intermediate discriminators and proposing a stronger encoder model (Supplementary Materials).

3.2. Reconstruction

BigBiGAN neural network was trained for 200,000 steps with a batch containing 32 randomly picked patches from the training set. The trained model was saved during each reconstruction period that occurred every 1000 steps. During this period, patches from the validation set were fed, in inference time, to the encoder and generator to measure their power in creating artificial samples and close to the irreversible encoding in terms of spatial features. Three types of metrics were calculated for each saved model to evaluate the reconstruction quality—pixel-wise mean absolute error (MAE) of image values normalized between -1 and 1 , Fréchet inception distance (FID) [52] on a pre-trained InceptionV3 model, and by performing perceptual evaluation similar to that presented in the Human Eye Perceptual Evaluation (HYPE) paper [53]. MAE above 0.5 was used to discard low-quality models that were not able to effectively reconstruct input images in the early stages of the training. Then, FID values of all preserved models were compared and 20 with the highest score were selected. The average FID score was equal to 86.36 ± 7.28 in contrast to the state-of-the-art BigBiGAN baseline FID, which was equal to 31.19 ± 0.37 .

The final model was selected by comparing the results of human evaluation of 21 arbitrarily chosen samples from the validation dataset with their reconstructed counterparts created by the network for each model. The human reader had an objective to assess whether each of the 42 images is real or artificial. The last verification phase resulted in selecting the model from the 170th reconstruction period, which yielded the least accuracy during human perceptual evaluation (accuracy: 59.5%, f-score: 0.6663). Samples and their reconstruction results are presented in Figure 6.

The overall quality of the reconstruction was assessed as sufficient during both quantitative and qualitative verification. For the selected model evaluated on non-scaled images (pixel values between 0 and 255), MAE was 27.213, structural similarity index (SSIM) [54] was 0.942, and peak signal-to-noise ratio (PSNR) [55] was equal to 42.731. From the analysis of human reader' misclassifications, it was clear that the chosen model is exceptionally good in reproducing areas like forests, land abandonment, and farmlands. The characteristic spatial features are preserved after encoding. Shadows cast by trees are consistent and natural. In the majority of cases, artificial and real images are indistinguishable. Mediocre results were achieved for urbanized areas. Reconstructed roads keep their linear character and surface type information. Although the model is capable of generating buildings, due to the high variety of housing types present in the research area and possible undersampling, the results are far from realistic. It is interesting that the link between residential areas and roads was maintained in multiple samples. Unfortunately, the generator is not capable of serving samples that contain water areas such as rivers or lakes. From all analyzed images from the training and validation set only a few presented water, which indicates weak encoding capabilities. Furthermore, all were significantly disrupted. The authors confirmed that this is related to undersampling and the insufficient information present in the RGB orthophoto. To tackle this issue, access to rich, multispectral imagery or digital terrain model (DTM) is required, or the model itself needs to be enriched to utilize additional class embeddings that could be derived from existing thematic maps or projects like Geoportal TBD [56].

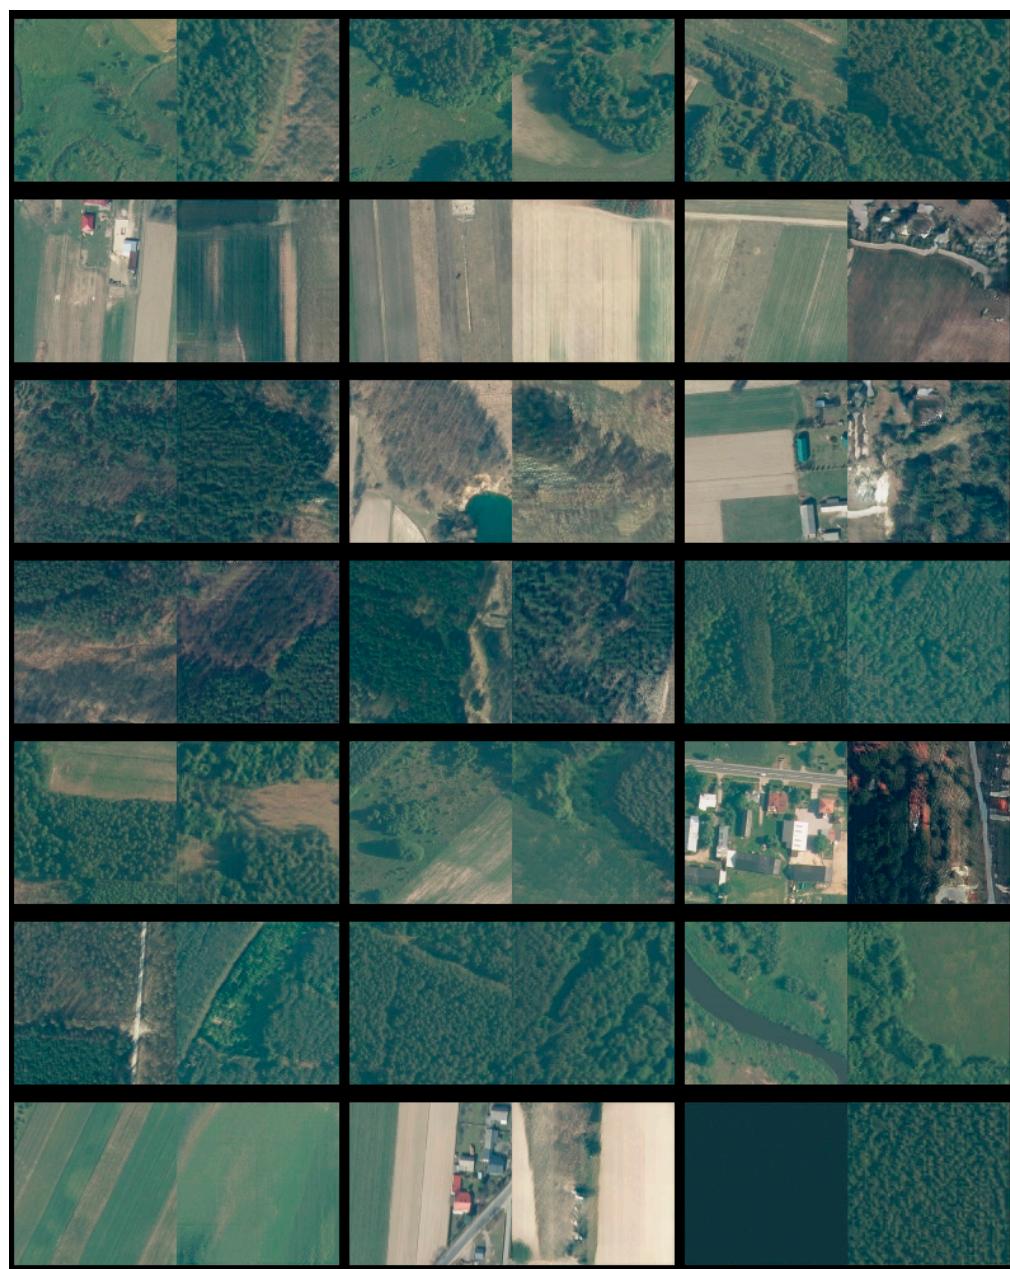


Figure 6. Reconstruction result of 21 validation samples. Ground truth is represented by real tile images placed on the left. Images on the right were reconstructed by the generator from real images latent codes acquired through the encoder.

3.3. Feature Engineering

BigBiGAN encoder possesses an interesting capability that enables it to shift the input image into the latent space constructed during network training. The encoding, a 120-dimensional vector, should be considered simultaneously a compressed version of the input orthophoto and a recipe for generating a similar artificial image in terms of spatial features. The latter phenomenon is called representation learning. What is important, due to the nature of latent space, similar data points, i.e., those that were encoded from similar images, are closer to each other. This opens an interesting possibility to understand the structural similarity between images by performing the analysis not on the raw image input but only using latent codes.

In the research, the authors utilized the trained encoder to perform inference on a set of 256 px × 256 px test patches (see Figure 7). The 1224 test patches were converted into their latent space codes and represented as a geopandas [57] data frame containing 1224 rows, 120 encoding value columns, identifier, and a geometry column. Afterward, distance weights between patch centroids were calculated utilizing the *k*-NN algorithm [58]. The data frame and distance weights served as input parameters to the agglomerative clustering algorithm. Figure 8 represents the results for a specified number of clusters.

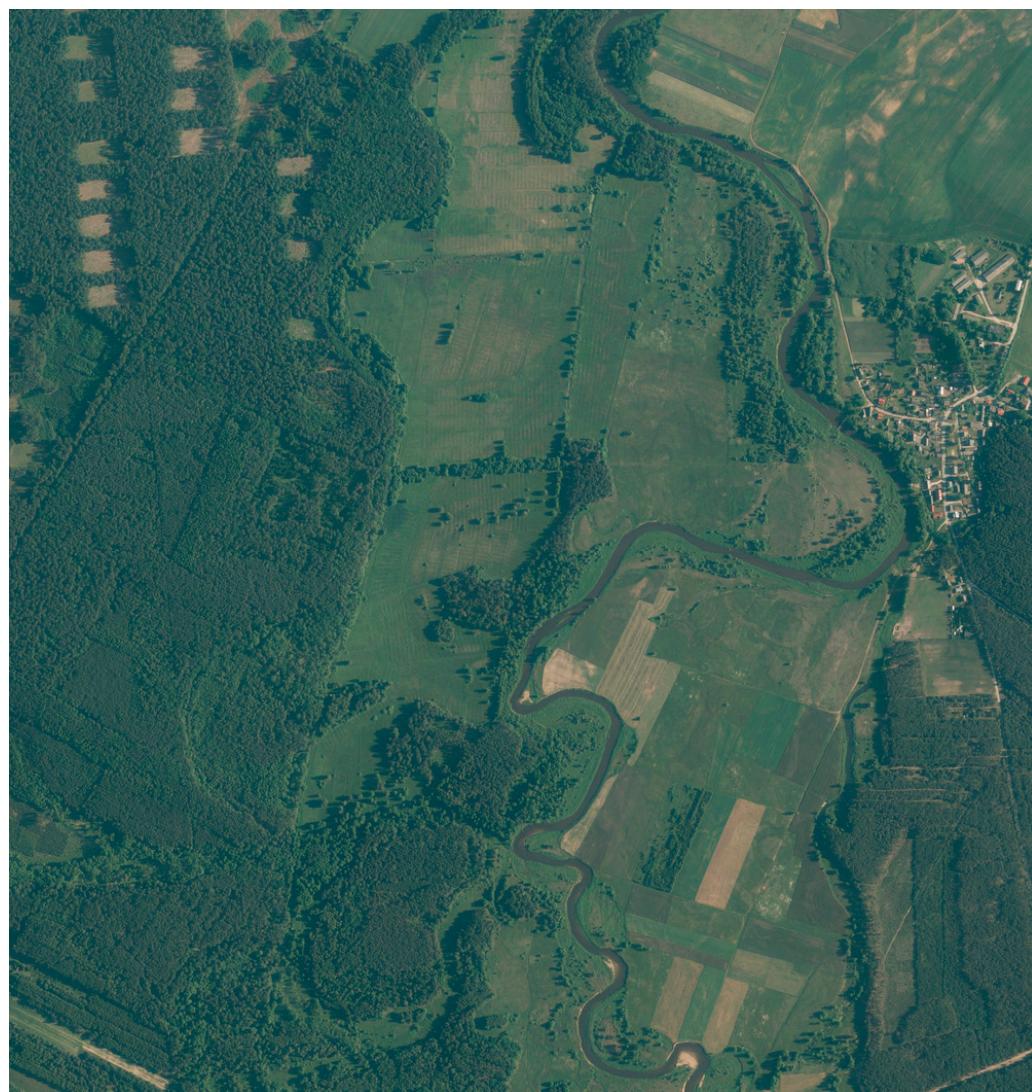


Figure 7. Test area 72961_840430_M-34-40-B-a-2-3 [42].

Simultaneously, ground truth segmentation masks were prepared by manually dividing the test image into a fixed number of regions. For the number of clusters between 2 and 10, there was an average of $17.97\% \pm 8.7\%$ patch-wise difference between ground truth and the unsupervised approach results. The more clusters were predicted the difference was larger. Figure 9 represents the best result, which was acquired for six clusters where the unsupervised approach misclassified 6% of patches.



Figure 8. Agglomerative clustering of 72961_840430_M-34-40-B-a-2-3 sample encoded patches using different cluster numbers.

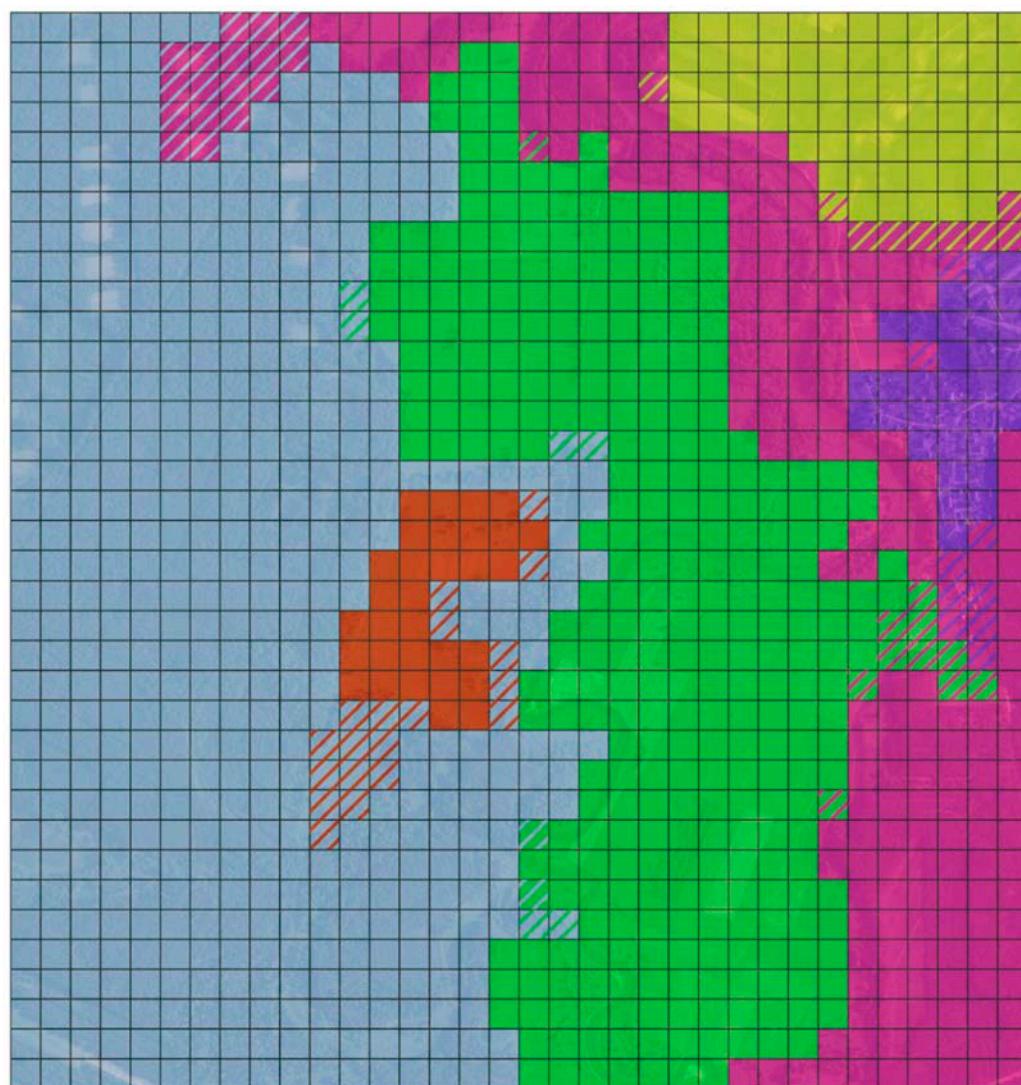


Figure 9. Clustering results of sample orthophoto (72961_840430_M-34-40-B-a-2-3 [42]) patches for fixed number of clusters (n clusters = 6). Each color represents a different cluster. Filled squares are the result of latent space clustering. The line pattern indicates the difference between the latent space clustering results and ground truth prepared by manual annotation.

4. Discussion

Utilizing a neural network as a key element of a feature engineering pipeline is a promising idea. The concept of learning the internal representation of data is not new and was extensively studied after the introduction of autoencoders (AE) [59]. Unlike regular autoencoders, bidirectional GANs do not make assumptions about the structure or distribution of the data making them agnostic to the domain of the data [38]. This makes them perfectly suited for use beyond working with RGB images and opens the opportunity to apply them in remote sensing where processing hyperspectral imagery is a standard use case.

One of the main challenges when utilizing a GAN is determining how big a research dataset is needed to feed the network to obtain the required result. The performance of the generator and, therefore, the overall quality of the reconstruction process and network encoding capabilities are tightly coupled with the input data. To be able to properly encode an image, BigBiGAN needs to learn different types of spatial features and discover how they interact with each other. In the early stages of the research, we identified that the size of the dataset had a positive influence on reconstruction quality. We initially worked with around 10% of the final dataset in order to rapidly prototype the solution. The results

were not satisfying, i.e., we were not able to produce artificial samples that resembled ground truth data. This prompted us to gradually increase the dataset's size. Authors are far from estimating the correct size of the dataset that could yield the best possible result for a specific research area. We are sure that addressing this issue will be important in the future development of this method.

The method of measuring the training progression of generative models still remains a problematic issue. The standard approach of monitoring the loss value during training and validation is not applicable due to the fact that all GAN components interact with each other, and the loss value is calculated against a specific point in time during the training process and, therefore, is ephemeral and incomparable with previous epochs. There are multiple ways of controlling how the training should progress, e.g., by using Wasserstein loss [60], applying gradient penalty [61], or spectral normalization [62]. Nevertheless, it is difficult to make a clear statement of what loss value identifies a perfectly trained network. Furthermore, applying GAN to tackle the problems within the remote sensing domain is still a novelty. It is difficult to find references in the scientific literature or open-source projects that could be helpful in determining the proper course of model training.

Although nontrivial, measuring the quality of bidirectional GAN image reconstruction capabilities seems to be a valid approach to the task of model quality assurance. An encoder, by design, always yields a result. It is just as true for a state-of-the-art model and its poorly trained counterparts. Encoder output cannot be directly interpreted, which makes it hard to evaluate its quality. The generator, on the other hand, produces a visible result that can be measured. According to the assumptions of bidirectional models, the encoding and decoding process should to some extent be reversible [38]. Hence, the artificially produced image should resemble, in terms of features, its reconstruction origin, i.e., the real image in which latent code was used to create an artificial sample. In other words, checking generator results operating on strictly defined latent codes determines the quality of the entire GAN.

A naive method of verification of the degree to which an orthophoto generated image looks realistic would be to directly compare it to its reconstruction origin. Pixel-wise mean absolute error (MAE) or a similar metric can give the researchers insight, to a limited extent, regarding the quality of produced samples. Unfortunately, this technique only allows getting rid of obvious errors such as a significant mistake in the overall color of the land cover. This is due to MAE not promoting textural and structural correctness, which may lead to poor diagnostic quality in some conditions [63]. One can approach a similar problem when using PNSR. To some extent, SSIM addresses the issue of measuring absolute errors by analyzing structural information. On the other hand, this method is not taking into account the location of spatial features. BigBiGAN reconstruction process only preserves features and their interaction not their specific placement in the analyzed image. Inception score (IS) and Fréchet inception distance (FID) address this problem by measuring the quality of the artificial sample by scoring the GAN capability to produce realistic features [34]. The main drawback of the IS is that it can be misinterpreted in case of mode collapse [64], i.e., the generator is able to produce only a single sample despite the latent code used as input. FID is much stronger in terms of assessing the quality of the generator. What is important, both metrics utilize a pre-trained Inception classifier [50] to capture relevant image features and therefore are dependent on its quality. There are multiple pre-trained models of Inception available. Many of them were created using large datasets such as ImageNet [65]. The authors are not aware of whether a similar dataset for aerial imagery exists. The use of FID is advisable and, as confirmed during the research, it is valuable in proving the capabilities of the generator, but it needs an Inception network trained on a dedicated aerial imagery dataset to be reliable. This way, the score calculated would depend on real spatial features existing in the geographical space. What is more, this approach is only applicable to RGB images. To perform FID calculation for hyperspectral images, a fine-tailored classifier should be trained. Not surprisingly, one of the most effective ways of verifying the quality of artificial images is

through human judgment. This takes on even greater importance when approaching the research subject requires specialized knowledge and skills, as exemplified by the analysis of aerial or satellite imagery. Unfortunately, qualitative verification is time-consuming and has to be supported by a quantitative method, which can aid in preselecting potentially good samples.

BigBiGAN accompanied by hierarchical clustering can be effectively used as a building block of an unsupervised orthophoto segmentation pipeline. The results of performing this procedure on a test orthophoto (see Figure 9) proves that the solution is powerful enough to divide the area into a meaningful predefined number of regions. Particularly noteworthy is the precise separation of forests, arable lands, and build-up areas. There is also room for improvement. Currently, the network is not capable of segmenting out tree felling areas located in the northwest and the river channel, which would be very beneficial from the point of view of landscape analysis. Furthermore, it also incorrectly combined pastures and arable lands. The main drawback of this method is the need to predefine the number of clusters. What is more, when increasing the number of clusters, artifacts started to occur, and the algorithm predicted small areas that were not identified as distinct regions in the ground truth image (Figure 8, n clusters = 7–10). Further analysis of latent codes and features that they represent is needed to understand the origin of this issue.

BigBiGAN clustering procedure results resemble, to some extent, the segmentation of the area performed during the Corine Land Cover project in 2018 (Figure 10). It is interesting that the proposed GAN procedure shows a better fit with the boundaries of individual areas than CLC. Nevertheless, CLC has a great advantage over the result generated using GAN, i.e., each tile possesses information about the land cover types that it represents. CLC land cover codes are consistent across all areas involved in the study, which makes this dataset very useful in terms of even sophisticated analysis. This does not mean, however, that the GAN cannot be rearmed to carry information about the land cover types. In the initial BigGAN paper, the authors proposed a solution to enrich each part of the neural network with a mechanism that would enable working with class embeddings [44]. The authors did not use the aforementioned solution to maintain the unsupervised nature of the procedure. An interesting solution would be to compare the latent codes of patches located within different regions to check how similar they are and use this information to join similar, distant regions. To achieve this, a more advanced dataset is needed to cover a larger area and prevent undersampling of occurring less frequently but spatially significant features. Comparison with CLC is also interesting due to the differences in the creation of both sets. CLC is prepared using a semi-supervised procedure that involves multiple different information sources. In contrast, the GAN approach utilizes only orthophotos and is fully unsupervised. Another interesting approach would be to utilize Corine Land Cover (CLC) as the source of model labels and retrain the network to also possess the notion of land cover types. This way, we would gain an interesting solution that would offer a way of producing CLC-like annotations in different precision levels and using different data sources.

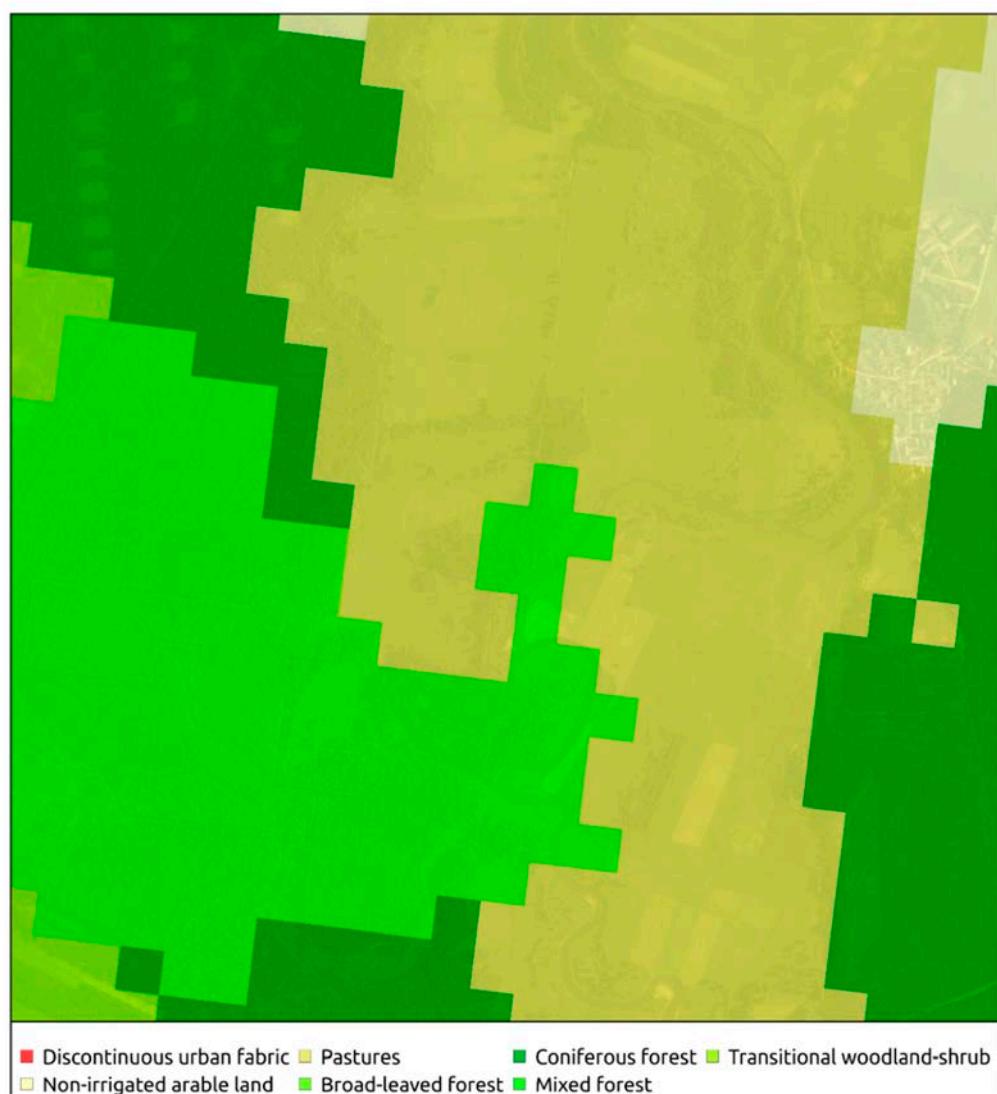


Figure 10. Orthophoto sheet 72961_840430_M-34-40-B-a-2-3 and Corine Land Cover Project (2018) segmentation [66].

5. Conclusions

Generative adversarial networks are a powerful tool that definitely found their place in both geographical information systems (GIS) and machine learning toolboxes. In the case of remote sensing imagery processing, they provide a data augmentation mechanism of creating decent quality artificial data samples, enhancing, or even fixing existing images, and also can actively participate in feature extraction. The latter gives the researchers access to new information encoded in the latent space. During the research, authors confirmed that the bidirectional generative adversarial network (BigBiGAN) encoder module can be successfully used to compress RGB orthophoto patches to lower-dimensional latent vectors.

The encoder performance was assessed indirectly by evaluating the network reconstruction capabilities. Pixel-wise comparison between ground truth and reconstruction output yielded the following results: mean absolute error (MAE) 27.213, structural similarity index (SSIM) 0.942, peak signal-to-noise ratio (PSNR) 42.731, and Fréchet inception distance (FID) 86.36 ± 7.28 . Furthermore, the encoder was tested by utilizing output latent vectors to perform geospatial clustering of a chosen area from the Pilica River region (94% patch-wise accuracy against manually prepared segmentation mask). The case study proved that orthophoto latent vectors, combined with georeferences, can be used during spatial analysis, e.g., in region delimitation or by producing reliable segmentation masks.

The main advantage of the proposed procedure is that the whole training process is unsupervised. The utilized neural network is capable of discovering even complex spatial features and code them in the network underlying latent space. In addition, handling relatively lightweight latent vectors during analysis rather than raw orthophoto proved to significantly facilitate the study. During processing and analysis, there was no need to possess a real image (37MB) but only a recipe to compute in on the fly (3MB). The authors think this feature has great potential in the commercial application of the procedure to lower disk space and network transfer requirements when processing large remote sensing datasets.

On the other hand, the presented method is substantially difficult to implement, configure, and train; it is prone to errors and is demanding in terms of computation costs. To achieve a decent result, one must be ready for a long run of trials and errors mainly related to tuning the model and estimating the required dataset size. Regarding latent vectors, authors have identified a major flaw related to the lack of possibility to precisely describe the meaning of each dimension. The main disadvantage of the proposed procedure is that the majority of steps during the evaluation of the model involves human engagement.

The authors are certain that utilizing BigBiGAN on a more robust and rich dataset, like multispectral imagery, backed by digital terrain model (DTM) and at the same time working on reducing the internal complexity of the network to enable processing larger patches will result in a handful of valuable discoveries. The main focus of the research team in the future will be the verification of the proposed method on a greater scale. Future work will involve performing geospatial clustering of latent codes acquired for all Polish geographic regions and presenting the comparison between classically distinguished regions and their automatically generated counterparts.

Supplementary Materials: The following are available online at <https://www.mdpi.com/2072-4292/13/2/306/s1>. Encoder model in h5 format with sample data is available on [github.com](https://github.com/maciej-adamiak/bigbigan-feature-engineering) (maciej-adamiak/bigbigan-feature-engineering).

Author Contributions: Conceptualization, M.A.; Methodology, M.A.; Software, M.A.; Validation, K.B. and A.M.; Formal analysis, M.A.; Investigation, M.A.; Resources, M.A.; Data curation, M.A.; Writing—original draft preparation, M.A., K.B. and A.M.; Writing—review and editing, M.A., K.B. and A.M.; Visualization, M.A.; Supervision, K.B and A.M.; Project administration, M.A. All authors have read and agreed to the published version of the manuscript.

Funding: This research received no external funding.

Institutional Review Board Statement: Not applicable.

Informed Consent Statement: Not applicable.

Data Availability Statement: Publicly available datasets were analyzed in this study. This data can be found here: <https://www.geoportal.gov.pl/>.

Acknowledgments: We would like to thank Mikołaj Koziarkiewicz, Maciej Opała, Kamil Rafałko and Tomasz Napierała for helpful remarks and an additional linguistic review.

Conflicts of Interest: The authors declare no conflict of interest.

References

1. Kussul, N.; Lavreniuk, M.; Skakun, S.; Shelestov, A. Deep Learning Classification of Land Cover and Crop Types Using Remote Sensing Data. *IEEE Geosci. Remote Sens. Lett.* **2017**, *14*, 778–782. [[CrossRef](#)]
2. Landsat 8—Landsat Science. Available online: <https://landsat.gsfc.nasa.gov/landsat-8/> (accessed on 24 October 2020).
3. Sentinel-2—ESA Operational EO Missions—Earth Online—ESA. Available online: <https://earth.esa.int/web/guest/missions/esa-operational-eo-missions/sentinel-2> (accessed on 24 October 2020).
4. Pleiades—eoPortal Directory—Satellite Missions. Available online: <https://earth.esa.int/web/eoportal/satellite-missions/p/pleiades> (accessed on 24 October 2020).
5. Dziennik Ustaw 2020 r. poz. 1086. Available online: <https://www.dziennikustaw.gov.pl/DU/2020/1086> (accessed on 24 October 2020).

6. Olędzki, J.R. *Geographical Conditions of the Diversity of the Satellite Image of Poland and Its Division into Photomorphic Units*; Wydawnictwa Uniwersytetu Warszawskiego: Warszawa, Poland, 1992.
7. Olędzki, J.R. Geographical regions of Poland. *Teledetekcja Środowiska* **2001**, *38*, 302.
8. Haralick, R.M.; Shanmugam, K.; Dinstein, I. Textural Features for Image Classification. *IEEE Trans. Syst. Man Cybern.* **1973**, *610–621*. [CrossRef]
9. Haralick, R.M.; Shapiro, L.G. Image segmentation techniques. *Comput. Vis. Graph. Image Process.* **1985**, *29*, 100–132. [CrossRef]
10. eCognition | Trimble Geospatial. Available online: <https://geospatial.trimble.com/products-and-solutions/ecognition> (accessed on 12 November 2020).
11. Węzyk, P.; De Kok, R.; Kozioł, K. Application of the object-based image analysis of VHR satellite images in land-use classification. *Rocz. Geomatyki-Ann. Geomat.* **2006**, *4*, 227–238.
12. Kondracki, J. *Physical and Geographic Regions of Poland*; Wydawnictwa Uniwersytetu Warszawskiego: Warszawa, Poland, 1977.
13. Solon, J.; Borzyszkowski, J.; Bidłasik, M.; Richling, A.; Badura, K.; Balon, J.; Brzezińska-Wójcik, T.; Chabudziński, Ł.; Dobrowolski, R.; Grzegorczyk, I.; et al. Physico-geographical mesoregions of Poland: Verification and adjustment of boundaries on the basis of contemporary spatial data. *Geogr. Pol.* **2018**, *91*, 143–170. [CrossRef]
14. Lewiński, S. Identification of land cover and land use forms on landsat ETM+ satellite image using the method of object-oriented classification. *Rocz. Geomatyki-Ann. Geomat.* **2006**, *4*, 139–150.
15. Lewiński, S. Comparison of object-oriented classification to traditional pixel-based classification with reference to automation of the process of land cover and land use data base creation. *Rocz. Geomatyki-Ann. Geomat.* **2007**, *5*, 63–70.
16. Kosiński, K. Application of Region Growing procedure to meadow classification based on Landsat ETM+ images. *Rocz. Geomatyki-Ann. Geomat.* **2005**, *3*, 69–76.
17. Kosiński, K. Application of structural features in the Landsat ETM+ image in object classification of landscape-vegetation complexes. *Archiwum Fotogram. Kartografii i Teledetekcji* **2007**, *17a*, 385–394.
18. Lang, S.; Burnett, C.; Blaschke, T. Multiscale object-based image analysis—A key to the hierarchical organisation of landscapes. *Ekológia* **2004**, *23*, 148–156.
19. Adamczyk, J.; Będkowski, K. Object-based analysis as a method of improving classification quality. *Rocz. Geomatyki-Ann. Geomat.* **2006**, *4*, 37–46.
20. Adamczyk, J. The effect of scaling methods on the calculation of environmental indices. *Ecol. Quest.* **2013**, *17*, 9–23. [CrossRef]
21. Białousz, S.; Chmiel, J.; Fijałkowska, A.; Różycki, S. Application of satellite images and GIS technology for updating of soil-landscape units—Examples for small scales mapping. *Archiwum Fotogram. Kartografii i Teledetekcji* **2010**, *21*, 21–32.
22. Kot, R. Application of the geodiversity index for defining the relief's diversity based on the example of the Struga Toruńska representative basin, Chełmno Lakeland. *Probl. Ekol. Kraj.* **2012**, *33*, 87–96.
23. Solon, J. Assessment of diversity of landscape on the basis of analysis of spatial structure of vegetation. *Pr. Geogr.* **2002**, *185*, 193–209.
24. Atkinson, P.M.; Tatnall, A.R.L. Introduction Neural networks in remote sensing. *Int. J. Remote Sens.* **1997**, *18*, 699–709. [CrossRef]
25. Chen, Y.; Lin, Z.; Zhao, X.; Wang, G.; Gu, Y. Deep Learning-Based Classification of Hyperspectral Data. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2014**, *7*, 2094–2107. [CrossRef]
26. Luus, F.P.S.; Salmon, B.P.; van den Bergh, F.; Maharaj, B.T.J. Multiview Deep Learning for Land-Use Classification. *IEEE Geosci. Remote Sens. Lett.* **2015**, *12*, 2448–2452. [CrossRef]
27. Adamiak, M.; Biczkowski, M.; Leśniewska-Napierała, K.; Nalej, M.; Napierała, T. Impairing Land Registry: Social, Demographic, and Economic Determinants of Forest Classification Errors. *Remote Sens.* **2020**, *12*, 2628. [CrossRef]
28. Cabezas, M.; Kentsch, S.; Tomhave, L.; Gross, J.; Caceres, M.L.L.; Diez, Y. Detection of Invasive Species in Wetlands: Practical DL with Heavily Imbalanced Data. *Remote Sens.* **2020**, *12*, 3431. [CrossRef]
29. Sobczak, M.; Folbrier, A.; Kozłowska, A.; Pabjanek, P.; Wrzesien, M.; Zagajewski, B. Assessment of the potential of hyperspectral data and techniques for mountain vegetation analysis. In *Imaging Spectroscopy: New Quality in Environmental Studies*; EARSeL & Warsaw University: Warsaw, Poland, 2005; pp. 763–780.
30. Zagajewski, B. Assessment of neural networks and Imaging Spectroscopy for vegetation classification of the High Tatras. *Teledetekcja Środowiska* **2010**, *43*, 1–113.
31. Iwaniak, A.; Krówczyńska, M.; Paluszynski, W. Applying neural networks to urban area classification in satellite images. *Acta Scientiarum Polonorum. Geodesia et Descriptio Terrarum* **2002**, *1*, 5–13.
32. Krawiec, K.; Wyczałek, I. Supervised road detection using machine learning methodology. *Archiwum Fotogram. Kartografii i Teledetekcji* **2006**, *16*, 361–371.
33. Goodfellow, I.J.; Pouget-Abadie, J.; Mirza, M.; Xu, B.; Warde-Farley, D.; Ozair, S.; Courville, A.; Bengio, Y. Generative Adversarial Networks. *arXiv* **2014**, arXiv:1406.2661.
34. Salimans, T.; Goodfellow, I.; Zaremba, W.; Cheung, V.; Radford, A.; Chen, X. Improved Techniques for Training GANs. *arXiv* **2016**, arXiv:1606.03498.
35. Dong, R.; Li, C.; Fu, H.; Wang, J.; Li, W.; Yao, Y.; Gan, L.; Yu, L.; Gong, P. Improving 3-m Resolution Land Cover Mapping through Efficient Learning from an Imperfect 10-m Resolution Map. *Remote Sens.* **2020**, *12*, 1418. [CrossRef]
36. Burdziakowski, P. A Novel Method for the Deblurring of Photogrammetric Images Using Conditional Generative Adversarial Networks. *Remote Sens.* **2020**, *12*, 2586. [CrossRef]

37. Zhao, W.; Chen, X.; Chen, J.; Qu, Y. Sample Generation with Self-Attention Generative Adversarial Adaptation Network (SaGAAN) for Hyperspectral Image Classification. *Remote Sens.* **2020**, *12*, 843. [[CrossRef](#)]
38. Donahue, J.; Krähenbühl, P.; Darrell, T. Adversarial Feature Learning. *arXiv* **2017**, arXiv:1605.09782.
39. Żelaźniewicz, A.; Aleksandrowski, P.; Buła, Z.; Karnkowski, P.H.; Konon, A.; Ślączka, A.; Żaba, J.; Żytko, K. *Tectonic Regionalization of Poland*; Komitet Nauk Geologicznych PAN: Wrocław, Poland, 2011; ISBN 978-83-63377-01-4.
40. Head Office of Geodesy and Cartography. Data for the Numerical Terrain Model with a Grid Interval of at Least 100 m. Available online: http://www.gugik.gov.pl/pzgik/dane-bez-oplat/dane-dotyczace-numerycznego-modelu-terenu-o-interwale-siatki-co-najmniej-100-m-nmt_100 (accessed on 9 January 2021).
41. Krysiak, S. Ecological aspects of land use changes in chosen types of natural landscapes in Central Poland. *Probl. Ekol. Kraj.* **2008**, *21*, 299–310.
42. Geoportal.gov.pl. Available online: <http://geoportal.gov.pl> (accessed on 11 November 2020).
43. Domingos, P. A few useful things to know about machine learning. *Commun. ACM* **2012**, *55*, 78–87. [[CrossRef](#)]
44. Donahue, J.; Simonyan, K. Large Scale Adversarial Representation Learning. *arXiv* **2019**, arXiv:1907.02544.
45. Mukherjee, S.; Asnani, H.; Lin, E.; Kannan, S. ClusterGAN: Latent Space Clustering in Generative Adversarial Networks. *arXiv* **2019**, arXiv:1809.03627. [[CrossRef](#)]
46. 2.3. Clustering—Scikit-Learn 0.23.2 Documentation. Available online: <https://scikit-learn.org/stable/modules/clustering.html#hierarchical-clustering> (accessed on 24 October 2020).
47. Ward, J.H. Hierarchical Grouping to Optimize an Objective Function. *J. Am. Stat. Assoc.* **1963**, *58*, 236–244. [[CrossRef](#)]
48. Radford, A.; Metz, L.; Chintala, S. Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks. *arXiv* **2016**, arXiv:1511.06434.
49. He, K.; Zhang, X.; Ren, S.; Sun, J. Deep Residual Learning for Image Recognition. *arXiv* **2015**, arXiv:1512.03385.
50. Szegedy, C.; Liu, W.; Jia, Y.; Sermanet, P.; Reed, S.; Anguelov, D.; Erhan, D.; Vanhoucke, V.; Rabinovich, A. Going Deeper with Convolutions. *arXiv* **2014**, arXiv:1409.4842.
51. Brock, A.; Donahue, J.; Simonyan, K. Large Scale GAN Training for High Fidelity Natural Image Synthesis. *arXiv* **2019**, arXiv:1809.11096.
52. Landau, B.V. The Fréchet distance between multivariate normal distributions. *J. Multivar. Anal.* **1982**, *12*, 450–455. [[CrossRef](#)]
53. Zhou, S.; Gordon, M.L.; Krishna, R.; Narcomey, A.; Fei-Fei, L.; Bernstein, M.S. HYPE: A Benchmark for Human eYe Perceptual Evaluation of Generative Models. *arXiv* **2019**, arXiv:1904.01121.
54. Wang, Z.; Bovik, A.C.; Sheikh, H.R.; Simoncelli, E.P. Image quality assessment: From error visibility to structural similarity. *IEEE Trans. Image Process.* **2004**, *13*, 600–612. [[CrossRef](#)] [[PubMed](#)]
55. Korhonen, J.; You, J. Peak signal-to-noise ratio revisited: Is simple beautiful? In Proceedings of the 2012 Fourth International Workshop on Quality of Multimedia Experience, Yarra Valley, Australia, 5–7 July 2012; pp. 37–38.
56. Head Office of Geodesy and Cartography Integrated Copies of Databases of Topographic Objects. Available online: <http://www.gugik.gov.pl/pzgik/zamow-dane/baza-danych-objektow-topograficznych-bdot-10k> (accessed on 11 November 2020).
57. GeoPandas 0.8.0—GeoPandas 0.8.0 Documentation. Available online: <https://geopandas.org/> (accessed on 24 October 2020).
58. sklearn.neighbors.KNeighborsClassifier—Scikit-Learn 0.23.2 Documentation. Available online: <https://scikit-learn.org/stable/modules/generated/sklearn.neighbors.KNeighborsClassifier.html> (accessed on 24 October 2020).
59. Kingma, D.P.; Welling, M. An Introduction to Variational Autoencoders. *FNT Mach. Learn.* **2019**, *12*, 307–392. [[CrossRef](#)]
60. Frogner, C.; Zhang, C.; Mobahi, H.; Araya-Polo, M.; Poggio, T. Learning with a Wasserstein Loss. *arXiv* **2015**, arXiv:1506.05439.
61. Gulrajani, I.; Ahmed, F.; Arjovsky, M.; Dumoulin, V.; Courville, A. Improved Training of Wasserstein GANs. *arXiv* **2017**, arXiv:1704.00028.
62. Miyato, T.; Kataoka, T.; Koyama, M.; Yoshida, Y. Spectral Normalization for Generative Adversarial Networks. *arXiv* **2018**, arXiv:1802.05957.
63. Deora, P.; Vasudeva, B.; Bhattacharya, S.; Pradhan, P.M. Structure Preserving Compressive Sensing MRI Reconstruction using Generative Adversarial Networks. *arXiv* **2020**, arXiv:1910.06067.
64. Thanh-Tung, H.; Tran, T. On Catastrophic Forgetting and Mode Collapse in Generative Adversarial Networks. *arXiv* **2020**, arXiv:1807.04015.
65. ImageNet: A Large-Scale Hierarchical Image Database—IEEE Conference Publication. Available online: <https://ieeexplore.ieee.org/document/5206848> (accessed on 26 October 2020).
66. Forslund, L. CLC 2018—Copernicus Land Monitoring Service. Available online: <https://land.copernicus.eu/pan-european/corine-land-cover/clc2018> (accessed on 11 November 2020).

Publikacja nr 5:

Adamiak, M. (2021). *Głębokie uczenie w procesie teledetekcyjnej interpretacji przestrzeni geograficznej – przegląd wybranych zagadnień*, Czasopismo Geograficzne, 92(1), 49, <https://doi.org/10.12657/czageo-92-03>

MEiN: 70.



POLSKIE Towarzystwo Geograficzne • POLISH GEOGRAPHICAL SOCIETY

**czasopismo
geograficzne**

geographical
journal

GŁĘBOKIE UCZENIE W PROCESIE TELEDETEKCYJNEJ INTERPRETACJI PRZESTRZENI GEOGRAFICZNEJ – PRZEGŁĄD WYBRANYCH ZAGADNIEŃ

DEEP LEARNING IN THE GEOGRAPHICAL SPACE REMOTE SENSING INTERPRETATION – REVIEW OF SELECTED ISSUES

Maciej Adamiak

SoftwareMill, ul. Na Uboczu 8/87, 02-791, Warszawa, Polska, ORCID: 0000-0002-8229-9661,
e-mail: maciej.adamiak@softwaremill.com

Streszczenie

Zastosowanie uczenia maszynowego (ML, ang. *machine learning*) oraz uczenia głębokiego (DL, *deep learning*), zwłaszcza głębokich konwolucyjnych sieci neuronowych (DCNN, ang. *deep convolutional neural network*), w przetwarzaniu oraz interpretacji obrazu jest obecnie szeroko omawianym zagadnieniem wśród przedstawicieli aktywnie rozwijającego się środowiska naukowego skupionego w ramach takich dziedzin, jak teledetekcja oraz geoinformacja. Niniejsza publikacja jest próbą usystematyzowania wiedzy dotyczącej DL oraz jego zastosowania we wspomaganiu interpretacji przestrzeni geograficznej na podstawie zobrazowań lotniczych i satelitarnych. Przeglądem zagadnień DL zainteresowani będą przede wszystkim geografowie, którzy chcieliby wzbogacić prowadzone badania naukowe o metody oparte na sztucznych sieciach neuronowych. W tekście przedstawione zostały główne koncepcje DL oraz metody wraz z przykładowymi kategoriami zadań, które można zrealizować za ich pomocą. Mowa o semantycznej segmentacji, klasyfikacji, augmentacji materiału badawczego i inżynierii cech. Prezentacja każdej z tych kategorii została wzbogacona o opis przypadku użycia i przegląd literatury, co umożliwiło wykonanie pierwszego kroku ku zastosowaniu danej techniki w przyszłych projektach badawczych. Zakończenie artykułu stanowi dyskusja nad nowymi kierunkami rozwoju DL w ramach dyscypliny nauk o Ziemi i środowisku.

Adamiak M. (2021). Głębokie uczenie w procesie teledetekcyjnej interpretacji przestrzeni geograficznej – przegląd wybranych zagadnień. *Czasopismo Geograficzne* 92(1): 49–72. <https://doi.org/10.12657/czageo-92-03>



OPEN
ACCESS

Otrzymano/Received: 24.05.2021
Zaakceptowano/Accepted: 31.08.2021

Słowa kluczowe: konwolucyjna sieć neuronowa, przestrzeń geograficzna, teledetekcja, uczenie głębokie, uczenie maszynowe.

Abstract

The use of machine learning (ML) and deep learning (DL), especially deep convolutional neural networks (DCNN) in image processing and interpretation is currently a widely discussed topic among representatives of actively developing remote sensing and geoinformation scientific community. This article is an attempt to systematize the knowledge of DL in its supportive role in the aerial and satellite imagery interpretation of geographical space. The target audience of this overview are geographers who would like to enrich their research with methods based on artificial neural networks. The text presents main concepts and methods of DL along with example tasks that can be completed with their help i.e.: semantic segmentation, classification, augmentation of research dataset and feature engineering. The description of each task category was enriched with a use case and a literature review, thus making it possible to take the first step towards applying the specified technique in future research. The article conclusion includes a discussion on new directions and opportunities of applying DL in the discipline of Earth and environmental sciences.

Keywords: convolutional neural networks, deep learning, geographical space, machine learning, remote sensing.

WPROWADZENIE

Ostatnią dekadę należy uznać za wybitnie interesujący okres w dziedzinie badań nad uczeniem maszynowym (ML, ang. *machine learning*), a w głównej mierze nad uczeniem głębokim (DL, ang. *deep learning*). W relatywnie krótkim czasie wiele wcześniej opracowanych koncepcji matematycznych zostało zmaterializowanych w postaci ogólnodostępnych narzędzi informatycznych, by wreszcie znaleźć praktyczne zastosowanie w aktywnie rozwijających się dyscyplinach nauki i techniki.

Mówimy, że program komputerowy uczy się podczas nabycia doświadczenia w odniesieniu do pewnej klasy zadań przy jednoczesnym pomiarze skuteczności, jeśli jego skuteczność w trakcie wykonywania tych zadań poprawia się wraz z doświadczeniem (Mitchell, 1997). Innymi słowy, model ML, będący głównym elementem składowym programu, dopasowuje się do danych wejściowych. Uczenie głębokie (znane również jako uczenie głębokie strukturalne) jest częścią rodziny metod ML opartych na złożonych sztucznych sieciach neuronowych i z zastosowaniem zestawu technik, które umożliwiają systemowi automatyczne wykrywanie cech (Bengio i in., 2014; Schmidhuber, 2015). Do najważniejszych osiągnięć należą tu głębokie konwolucyjne sieci neuronowe (DCNN, ang. *deep convolutional neural networks*), które dzięki upowszechnieniu się dostępu do znaczących zasobów ob-

liczeniowych na stałe zasiliły arsenał metodyczny naukowców na całym świecie. Innym znamienitym przykładem, obok DCNN, jest *Visual Transformer* (Vaswani i in., 2017). Jedną z dyscyplin, która w wyraźny sposób zyskała na rozwoju DL, jest widzenie komputerowe (CV, ang. *computer vision*), a wraz z nim teledetekcja (RS, ang. *remote sensing*) i tym samym nauki o Ziemi i środowisku (Chen Y. i in., 2014; Kussul i in., 2017; Kamaris, Prenafeta-Boldu, 2018).

Rozwój technologii teledetekcji, wsparty znaczną poprawą dostępności i jakości repozytoriów danych przestrzennych, doprowadził do wzrostu zainteresowania wykorzystaniem zebranego materiału w badaniach naukowych i pracach rozwojowych. Doskonałym przykładem takich zbiorów są wysokiej jakości obrazy udostępniane w ramach programów Landsat 8 (*Landsat 8 – Landsat Science*, 2020), Sentinel-2 A/B (*Sentinel-2 – ESA Operational EO Missions – Earth Online – ESA*, 2020) oraz Pléiades (*Pleiades – eoPortal Directory – Satellite Missions*, 2020), a w Polsce uwolnienie zasobów ortofotomap w ramach Tarczy antykryzysowej 4.0 (Dziennik Ustaw, 2020). Systematycznie odbierany i gromadzony jest olbrzymi zbiór danych wytworzony w trakcie pracy zaawansowanych sensorów optycznych oraz radarów zainstalowanych na pokładach platform operujących w przestrzeni kosmicznej, atmosferze ziemskiej i na Ziemi. Różnorodność nagromadzonego materiału ze względu na jego tematykę, typ, format, czas przydatności do użycia, rozdzielcość przestrzenną, czasową i spektralną stawia przed badaczami niezliczoną liczbę wyzwań, z których znacząca większość ma na celu automatyzację procesu przetwarzania obrazu i wspomaganie procesu jego interpretacji. Nie budzi zaskoczenia skierowanie uwagi badaczy i inżynierów na możliwości strumieniowego przetwarzania wielkich zbiorów danych (ang. *big data*) oraz interpretacji z użyciem wysokowydajnych algorytmów i modeli opartych na ML i DL (Boyd, 2009).

Zobrazowania lotnicze i satelitarne Ziemi są źródłem cennych informacji o przestrzeni geograficznej. Oferują rozszerzenie analizy poza to, co widoczne (Lillesand i in., 2015), dzięki dostępności do kanałów spoza spektrum światła widzialnego i zwiększenie rozdzielcości spektralnej dzięki obrazowaniu hiper-spektralnemu. Ich wykorzystanie pozwala na lepsze zrozumienie zjawisk zachodzących w skali makro bez ograniczeń wynikających z tradycyjnych obserwacji w skali lokalnej (Tang i in., 2009). Z technicznego punktu widzenia na uwagę zasługują następujące cechy danych pochodzących z obrazowania: wysoka jakość związana ze stale zwiększana rozdzielcością przestrzenną, spektralną, radiometryczną i czasową, standaryzacja materiału w obrębie jednego lub kilku systemów teledetekcyjnych umożliwiająca porównywanie różnych obszarów, systematyczność transmisji materiału sprzyjająca prowadzenia badań w dłuższym horyzoncie czasowym, dostępność danych aktualnych oraz historycznych w ramach usług komercyjnych i repozytoriów publicznych, wsparcie i integracja z ogólnodostępymi systemami informacji geograficznej (GIS, ang. *geographic information system*), a także ciągły rozwój i ulepszenie metod oraz technologii obrazowania.

Niniejsza publikacja jest próbą zaprezentowania aktualnego stanu wiedzy dotyczącej DL oraz jego zastosowania w interpretacji przestrzeni geograficznej. Autor podejmuje się w niej:

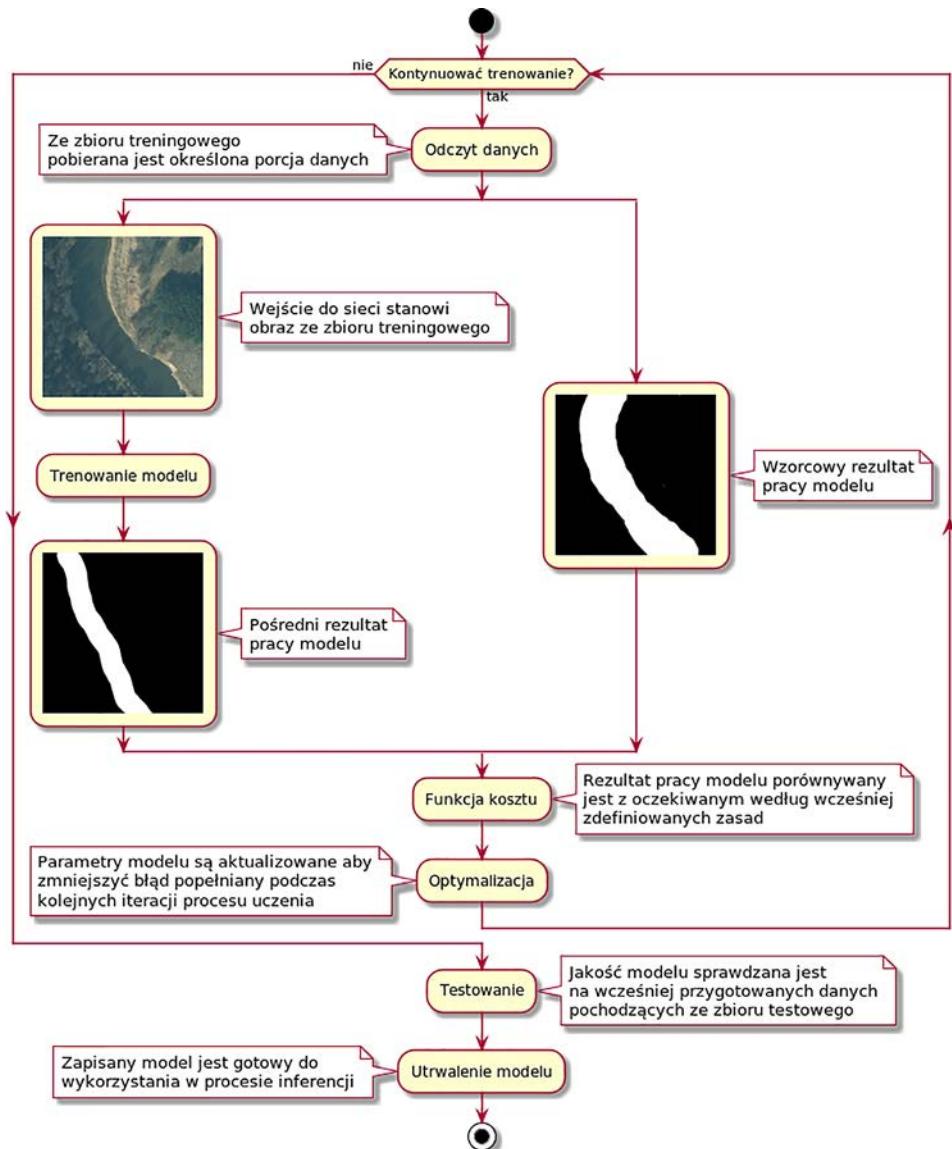
1. Przedstawienia w syntetyczny oraz przystępny sposób koncepcji leżących u podstaw DL i ich powiązania z CV. Szczególną uwagę zwrócono na pojęcia związane z głębokimi konwolucyjnymi sieciami neuronowymi (DCNN).
2. Przybliżenia czytelnikowi metod i technik interpretacji materiału pozyskanego podczas obrazowania lotniczego i satelitarnego z wykorzystaniem metod DL wraz z przykładami ich zastosowania.
3. Podjęcia dyskusji o przyszłych kierunkach w zastosowaniu DL w ramach dyscypliny nauk o Ziemi i środowisku, a przede wszystkim w geografii.

PRZEGŁĄD METOD I TECHNIK DL

Uczenie sztucznej sieci neuronowej

Uczenie maszynowe nieroźłącznie związane jest z danymi. To dzięki odpowiednio dobranemu i zarządzanemu zbiorowi danych sieć neuronowa może doskonalić się w procesie uczenia. Tradycyjnie zbiór ten dzielony jest na dwa podzbiory. Pierwszy, zwany treningowym, używany jest w procesie uczenia. Drugi testowy, zawiera próbki, które nie wezmą udziału w trenowaniu i posłużą jedynie do sprawdzenia skuteczności modelu.

Proces trenowania sieci neuronowej (ryc. 1) sprowadza się, w znacznym uproszczeniu, do zadania optymalizacyjnego polegającego na minimalizacji zdefiniowanej funkcji kosztu. Zadaniem funkcji kosztu jest pomiar błędu, jaki popełnia sieć w porównaniu do przyjętego wzorca. Przykładem funkcji kosztu są: średni błąd kwadratowy (ang. *mean squared error*), indeks Jaccarda (ang. *Jaccard Index*), dywergencja Kullbacka-Leiblera i inne. Informacja o błędzie propagowana jest z każdą iteracją procesu w głąb sieci. Sieć neuronowa ma budowę warstwową, w której każda z warstw przechowuje skończony zestaw parametrów. Parametry te, inicjalizowane losowymi wartościami, zostają dostosowane zgodnie z informacją o obliczonym błędzie. Konsekwencją jest ewolucja modelu, który w kolejnych etapach coraz lepiej radzi sobie z postawionym przed nim problemem. Uczenie sieci przerywane jest, gdy model osiąga założoną skuteczność albo upłynął czas przeznaczony na jego trenowanie, nie poprawia swoich rezultatów lub przeuczy się (ang. *overfitting*). Skuteczność modelu mierzona jest na zbiorze testowym według wcześniej wybranych miar, np.: dokładności (ang. *accuracy*), czułości (ang. *recall*), precyzji (ang. *precision*) i wielu innych metryk dostosowanych do konkretnego zadania. Częstym przypadkiem jest przeuczenie modelu, w którym mimo doskonałej skuteczności mierzonej na zbiorze treningowym model osiąga słabe rezultaty na zbiorze testowym. Jest to oznaka modelu o niskiej jakości, który



Ryc. 1. Proces trenowania modelu uczenia maszynowego (nadzorowany)
 Źródło: opracowanie własne.

będzie miał problem z pracą z nowymi obserwacjami. Istnieje również możliwość, że model nie jest w stanie osiągnąć postawionych przed nim wymagań i nie poprawia swoich osiągów lub uczy się na tyle wolno, że uzyskanie zadowalającego rezultat jest kosztowne lub niemożliwe. Wytrenowany model jest gotowy do użycia w procesie inferencji, tj. wnioskowania w oparciu o dane, które badacz zdecy-

dował się poddać transformacji z jego użyciem. Model utrwalany jest w postaci pliku i może zostać wykorzystany wielokrotnie, a także udostępniany w postaci usługi w sieci web.

Zagadnienia leżące u podstaw uczenia maszynowego i konstrukcji sieci neuronowych są złożone. Doskonałym wprowadzeniem do tematu są podręczniki: *Pattern Recognition and Machine Learning* (Bishop, 2006) *Hands-On Machine Learning* (Gron, 2019) oraz kurs *Deep Learning Specialization* (*DeepLearning.AI*, 2021) dostępny w serwisie Coursera.

Reprezentacja obrazu w głębokiej konwolucyjnej sieci neuronowej (DCNN)

Przykładem wykorzystania głębokiej konwolucyjnej sieci neuronowej (DCNN) jest analiza fragmentu terenu zurbanizowanego, znajdującego się w granicach Łodzi. Utworzono w tym celu kwadratowy wycinek przez selektywne scalenie dwóch arkuszy ortofotomapy wykonanej w 2019 r. (*Geoportal*, 2020): M-34-3-D-b-4-2-3 CIR oraz M-34-3-D-b-4-2-3 RGB (ryc. 2). Bok wycinka ma długość 5000 px, co przekłada się na 250 m w terenie przy rozmiarze piksela równym 0,05 m. Jego środek znajduje się w punkcie 51°46'24.3 N 19°28'52.9 E. Obraz zawiera informacje pochodzące z czterech kanałów spektralnych: czerwonego (R), zielonego (G), niebieskiego (B) oraz bliskiej podczerwieni (NIR). Obraz poddano wstępnej interpretacji, ograniczając się jedynie do wyrazistych cech badanego obszaru. Mamy do czynienia ze zróżnicowanym terenem zabudowanym zlo-



Ryc. 2. Wycinek arkusza M-34-3-D-b-4-2-3 (Łódź) w kompozycji RGB (lewy) oraz CIR (prawy)

Źródło: opracowanie własne na podstawie geoportal.gov.pl.

kalizowanym w pobliżu ruchliwego ciągu komunikacyjnego. Budynki tworzą uporządkowany układ poprowadzony wzduż kilku prostopadłych do siebie osi. Zabudowa jest zwarta. Pokrywa roślinna jest szczegółowa. Występują pojedyncze drzewa. Analizę można poprowadzić dalej, wyznaczając powierzchnię danego typu pokrycia terenu, a nawet szacować liczbę kondygnacji budynków oraz określić liczbę samochodów. Zrozumienie treści przedstawionego obrazu jest dla człowieka procesem naturalnym. Z jakich mechanizmów musi skorzystać maszyna w celu przeprowadzenia podobnej analizy obrazu?

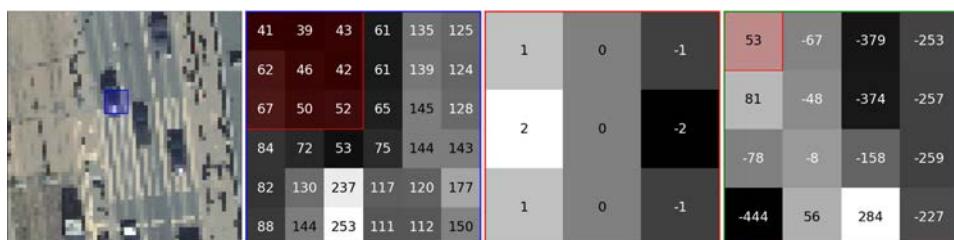
Jedną z form reprezentacji cyfrowej obrazu oraz sposobu zaopatrzenia algorytmu ML w dane wejściowe jest wielowymiarowa tablica o zadanej wysokości, szerokości oraz głębokości wynikającej z wymiarów analizowanego obrazu oraz liczby dostępnych kanałów. Dla przykładowego obrazu jest to $5000 \times 5000 \times 4$. Każdemu elementowi tablicy przypisana jest dokładnie jedna wartość liczbową, pochodząca z pewnego skończonego zakresu, reprezentująca intensywność odbicia światła w danym kanale i położeniu. Innymi słowy, obraz tworzony jest przez zbiór uporządkowanych wartości. Algorytmy ML, takie jak: maszyna wektorów nośnych (SVM, ang. *support vector machine*), lasy losowe (RF, ang. *random forests*), algorytm k-średnich (ang. *k-means*), pracują w oderwaniu od narzuconego porządku przestrzennego, używając jedynie informacji zawartych w wartościach pikseli. Inne algorytmy, takie jak grupowanie przestrzenne (ang. *spatial clustering*), używają informacji o lokalizacji wartości w celu określenia sąsiedztwa. Bez względu na podejście algorytmy te osiągają interesujące rezultaty (Dabija i in., 2021; Kałużna, Będkowski, 2020; Malinowski i in., 2020) i są szeroko stosowane w interpretacji przestrzeni geograficznej. Analizowanie obrazu w formie tablicy ma jednak istotne ograniczenie. Staje się ono widoczne podczas przetwarzania obrazu o dużej rozdzielczości. Nie chodzi jedynie o wydajność, która drastycznie spada wraz ze zwiększeniem rozmiaru tablicy, ale o bogactwo treści, którego opisanie nie jest możliwe jedynie za pomocą analizy bezpośrednio sąsiadujących ze sobą pikseli. Podobnie jak człowiek miałby problem z analizą obrazu piksel po pikselu, bez szerszego kontekstu, jakim są złożone kształty i wzajemna relacja między nimi, tak i maszyna może jedynie ograniczyć się do rozwiązania w obrębie pewnej wybranej klasy problemów. Uczenie z wykorzystaniem DCNN rozwiązuje ten problem przez wprowadzenie dodatkowego kroku przed rozpoczęciem procesu analitycznego. Tak jak w przypadku klasycznych algorytmów na wejściu znajduje się tablica zawierająca informacje o wartości pikseli. Jednak przed podjęciem właściwych działań przekształcana jest ona w reprezentację umożliwiającą zapis cech przestrzennych występujących na obrazie. Sam obraz nie podlega modyfikacji. Zmienia się sposób, w jaki jest on zapisywany oraz przekazywany do algorytmu zajmującego się właściwą interpretacją. W zależności od zaawansowania reprezentacji może ona przechowywać informacje o prostych kształtach, liniach o różnym układzie oraz złożonych cechach obiektów, takich jak dachy budynków, drzewa

czy pojazdy. Reprezentacja obrazu opisana jest w wielu, następujących po sobie, warstwach ukrytych sieci neuronowej (ang. *hidden layers*).

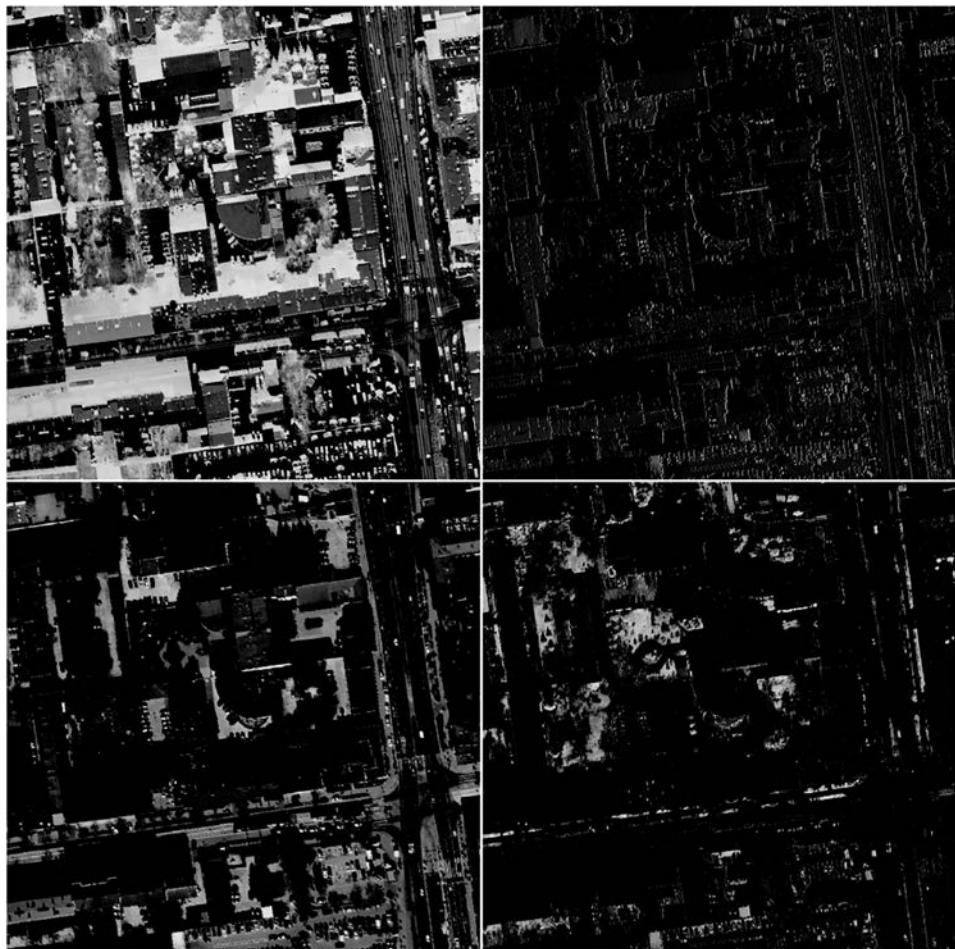
Kodowanie cech obrazu jest możliwe przez zastosowanie operacji konwolucji (splotu), w której zestaw filtrów używany jest, aby poddać obraz wejściowy charakterystycznej, z punktu widzenia sieci neuronowej, transformacji. W zależności od doboru wartości macierzy opisującej dany filtr może on uwydatnić pewne cechy obrazu lub je wygaszać. Przykładem może być operacja, której rezultatem jest wykrycie krawędzi obiektów widocznych na obrazie. Rycina 3 przedstawia zastosowanie wybranego filtra konwolucyjnego o rozmiarze 3×3 (Sobel, 1968) na wybranym wycinku pojedynczego kanału przykładowego obrazu o rozmiarze 6×6 . Rezultatem jest tablica 4×4 , w której każda wartość została obliczona jako suma iloczynów wartości parametrów filtra oraz odpowiedniej części badanego wycinka.

Aby trafnie opisać obraz przy użyciu zbioru jego cech, musi on zostać zakodowany wieloma odmiennymi filtrami. Co więcej, sposób opisu musi być spójny dla całego materiału badawczego trafiającego do algorytmu, co oznacza, że każdy przetworzony obraz przejdzie przez ten sam zestaw transformacji. Intuicyjnie o filtrach można myśleć w kategorii mechanizmów tworzenia nowych kanałów, w których nie są zakodowane intensywności odbicia, lecz różnorodne cechy obrazu (ang. *feature map*). Rycina 4 przedstawia przykładowy obraz poddany działaniu czterech różnych filtrów, uwydatniających specyficzne cechy obrazu: lewy górny – obszary kontrastujące i cienie, prawy górny – krawędzie biegnące wertykalnie, lewy dolny – obszar pokryty specyficznym typem nawierzchni, prawy dolny – tereny zielone. Filtry zostały wytrenowane podczas procesu uczenia sieci neuronowej opartej na architekturze Xception (Chollet, 2016).

Kluczowym zagadnieniem jest odkrycie takich parametrów transformacji, aby jak najlepiej pasowały one do problemu badawczego oraz danych wejściowych. Nie istnieje uniwersalny zestaw filtrów, ich określona liczba czy konfiguracja, która sprawdzi się w każdych warunkach. Odkrycie odpowiednich wartości i kombinacji filtrów jest niezmiernie trudne. Rozwiązaniem są sieci neuronowe,



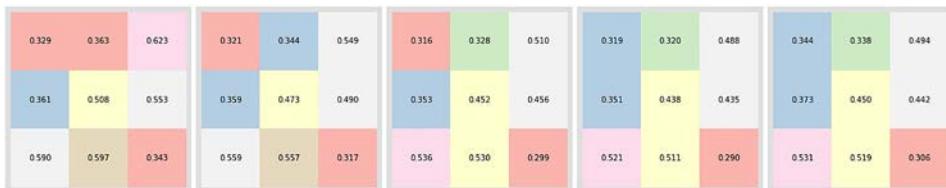
Ryc. 3. Zastosowanie filtra konwolucyjnego (od lewej: obraz poddawany transformacji, wycinek obrazu, filtr konwolucyjny, rezultat transformacji wycinka)
 Źródło: opracowanie własne.



Ryc. 4. Obraz (por. z ryc. 2) poddany transformacji z wykorzystaniem czterech różnych filtrów.

Źródło: opracowanie własne.

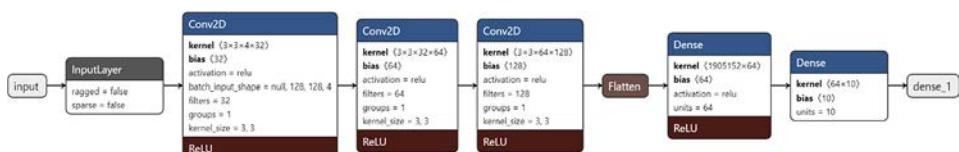
które dzięki możliwości trenowania są w stanie w iteracyjnym procesie odkryć odpowiednie wartości parametrów, ze względu na wybraną funkcję kosztu, i tym samym stworzyć dogodną dla procesu analizy reprezentację obrazu. Ryciną 5 przedstawia postęp w trenowaniu wybranego filtra o rozmiarze 3×3 dla pojedynczego kanału w sieci Xception. Pierwsza macierz od lewej przedstawia filtr zainicjalizowany losowymi wartościami. Każda kolejna to udoskonalona w procesie uczenia wersja poprzedniego stanu. Komponentem sieci neuronowej umożliwiającym odnajdywanie optymalnego zestawu filtrów konwolucyjnych jest warstwa konwolucyjna (ang. *convolutional layer*).



Ryc. 5. Trenowanie filtra konwolucyjnego 3×3

Źródło: opracowanie własne.

Warstwy konwolucyjne można ze sobą łączyć. W przypadku pierwszego poziomu za wejście posłuży surowy obraz zapisany w postaci tablicy. Na kolejnych poziomach warstwy konsumują rezultaty wcześniejszych transformacji i uzyskując możliwość wydobycia coraz to większej liczby różnorodnych cech. Mówimy, że rośnie głębokość sieci, która tworzy w ten sposób trzon DCNN. W tym stanie sieć jest gotowa, aby poddać ją konfiguracji i przygotować do badania. Dla przykładu może stać się ona klasyfikatorem umożliwiającym przypisanie wejściowemu obrazowi jednej z kilku predefiniowanych klas (ryc. 6), detektorem odnajdującym wybrane obiekty znajdujące się na obrazie, rekonstruktorem poprawiającym jakość materiału wejściowego i wiele więcej. Warstwy konwolucyjne są głównym, ale nie jedynym komponentem, z których powstaje architektura sieci neuronowej. W celu nadania sieci pewnych właściwości należy uzbroić ją w dodatkowe komponenty umożliwiające modelowi skupienie się na pewnych aspektach obrazu, wytworzenie rezultatu w odpowiednim formacie, łączenie ze sobą kilku wcześniejszych warstw, redukcji wymiarowości i regularyzacji. Istnieje cały zestaw operacji oprócz konwolucji, tj.: *max pooling*, *dropout*, *concatenate*, *flattening*, *convolutional transpose*, *upsampling* i więcej, będących częściami składowymi modeli DL. Niektóre charakterystyczne złożenia operacji tworzą moduły, takie jak *residual Block* (He i in., 2015), *inception* (Szegedy i in., 2014) czy *attention* (Vaswani i in., 2017), które stosowane są w celu nadania ostatecznemu rozwiązań wymaganych właściwości. Dodatkowe informacje odnośnie do powszechnie stosowanych operacji czytelnik znajdzie w dokumentacji bibliotek wspierających DL, takich jak TensorFlow czy PyTorch.



Ryc. 6. DCNN o trzech warstwach konwolucyjnych, o liczbie filtrów 32, 64, 128,

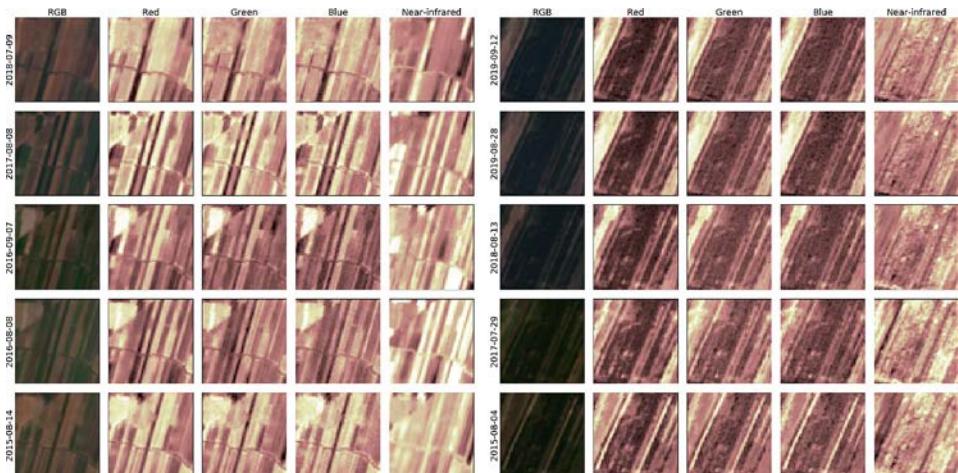
umożliwiający klasyfikację obrazu do 10 kategorii
Źródło: opracowanie własne przy użyciu aplikacji netron.app.

Klasyfikacja

Celem klasyfikacji jest pogrupowanie materiału wejściowego przez przyporządkowanie każdego z jego elementów do pewnej kategorii. Zestaw kategorii lub inaczej klas jest ściśle określony. Klasyfikacja może odbywać się na poziomie całego obrazu, jego fragmentu albo każdego piksela z osobna. Praca na pojedynczym pikselu, często zawierającym informacje o wielu kanałach spektralnych, weszła do kanonu przetwarzania zdjęć lotniczych oraz obrazu satelitarnego i jest z powodzeniem stosowana w rozwiązańach opartych na klasycznych metodach ML. Na uwagę zasługuje klasyfikator oparty na maszynie wektorów nośnych (ang. *support vector classifier*, SVC) oraz regresja logistyczna (ang. *logistic regression*) (Chen Y. i in., 2014). Wspomniane metody używane są również w odniesieniu do całego obrazu. Wymagają one jednak zaaplikowania potężnego warsztatu z zakresu inżynierii cech (ang. *feature engineering*). Poddany analizie zbiór pikseli reprezentujących zdjęcie musi ulec takiemu przetworzeniu, aby jednocześnie spełniał wymagania algorytmu i był adekwatny do postawionego problemu badawczego. Zadanie to sprowadza się do przedstawienia cech obrazu w postaci liczbowej. Dla przykładu już proste policzenie długości obiektów liniowych na obrazie, zliczenie punktów charakterystycznych czy wyrażenie obiektów przez zajmowaną przez nie powierzchnię jest przykładem inżynierii cech. Praktyka pokazuje, że w tym przypadku lepiej sprawdza się podejście z użyciem DCNN. Zakłada ono, że poznanie cech obrazu nastąpi w trakcie procesu trenowania sieci neuronowej. Zakres problemów badawczych możliwych do rozwiązania za pomocą klasyfikacji jest olbrzymi. Metody i techniki DL nie tylko wspomagają prace z zakresu analizy pokrycia terenu (Zhang i in., 2020), ale również umożliwiają rozpoznawanie gatunków flory i fauny (Kellenberger i in., 2019), detekcję zjawisk ekstremalnych (Anantrasirichai i in., 2019), a także identyfikowanie form geomorfologicznych (Ghorbanzadeh i in., 2019).

Przykładem zastosowania DCNN do wspomagania interpretacji przestrzeni geograficznej jest badanie występowania odłogów w województwie łódzkim (Krysiak i in., 2020). Zaprojektowano klasyfikator umożliwiający określenie, z jakim prawdopodobieństwem obraz obszaru o powierzchni 15÷25 ha przedstawia odłog. Wykorzystano ogólnodostępne dane pochodzące z obrazowania satelitarnego (ryc. 7) oraz rezultaty projektu badawczego dotyczącej ekologicznej roli odłogów (Krysiak i in., 2016), na podstawie których opracowano szczegółową mapę ich występowania w strefach otaczających parki krajobrazowe w województwie łódzkim. Cyfrowa wersja mapy posłużyła do przypisania obrazom klas wymaganych podczas procesu uczenia nadzorowanego.

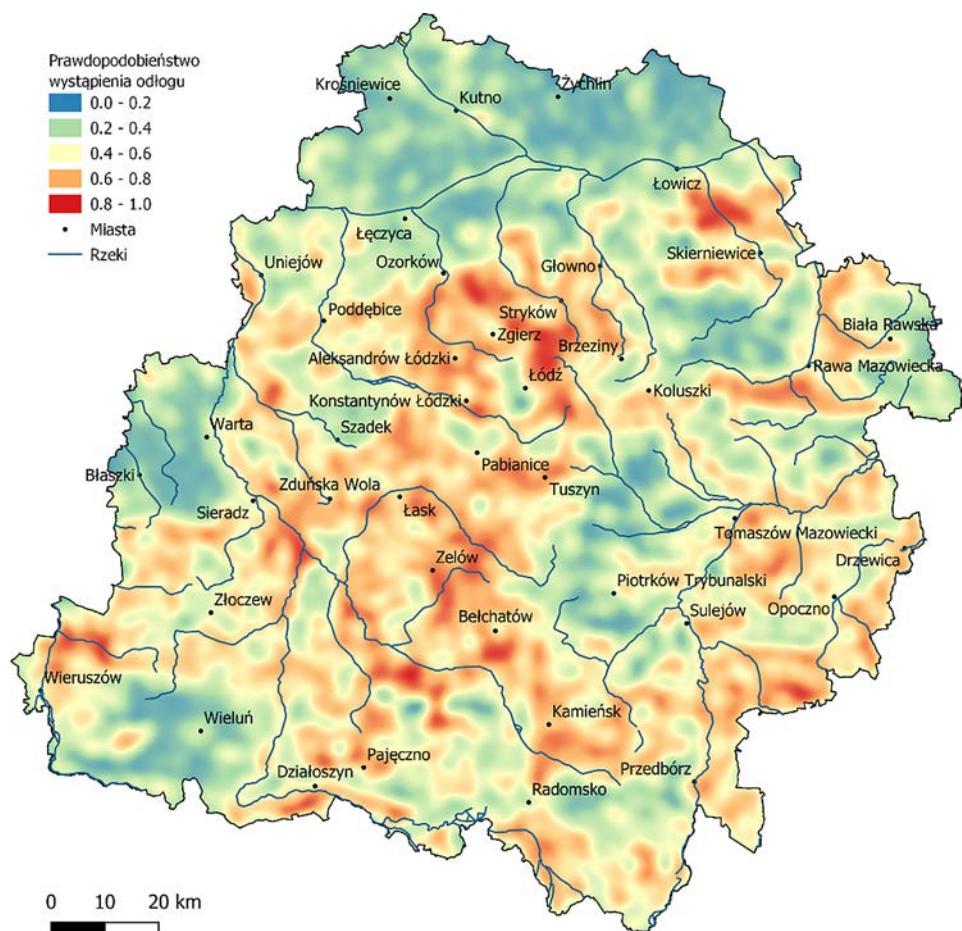
Automatycznej analizie poddano obszar przekraczający 18 000 km². Zrealizowanie podobnego projektu w sposób niezautomatyzowany nie byłoby możliwe ze względu na czas oraz koszty. Badanie to jest ciekawym przykładem



Ryc. 7. Dane wejściowe (Sentinel-2) do klasyfikatora odłogów w kompozycji barwnej RGB oraz kanałów spektralnych: R, G, B, NIR (od lewej: pola uprawne bez śladów odłogów i odłogi)

Źródło: Krysiak i in. (2020).

powrotu do wcześniej rozpatrywanego problemu badawczego w celu powtórzenia badań przy użyciu innej metody i jednoczesnym rozszerzeniu obszaru badawczego. Głównym zadaniem modelu DL jest wspomaganie badacza w interpretacji oraz dostarczenie mu dodatkowego materiału umożliwiającego opracowanie problemu badawczego. W badaniu wykorzystano standardową architekturę klasyfikatora opartą na DCNN. Różnica między przykładowym klasyfikatorem (ryc. 6) a użytym w badaniu polegała na głębokość sieci, tj. liczbie wykorzystanych warstw konwolucyjnych. Wejście do sieci stanowiły czterokanałowe wycinki obrazu satelitarnego o rozmiarze $50 \text{ px} \times 50 \text{ px}$. Rezultatem jest przypisanie każdemu wycinkowi wartości z przedziału 0 i 1 reprezentującego prawdopodobieństwo bycia odłogiem. Każdy z wycinków posiada georeferencję, dzięki czemu rezultat można nanieść na mapę (ryc. 8), a także poddać dalszemu procesowi analizy przestrzennej, jak to miało miejsce w cytowanym artykule, w którym obliczono statystykę lokalną Getisa i Orda (Gi^*). Jest to przykład zastosowania ML jako kroku pośredniego umożliwiającego zdobycie lub przygotowanie danych do finalnego badania. Należy podkreślić, że rozwiązanie to nie zastępuje eksperta, którego wiedza posłużyła do poprawnego wytrenowania modelu. Wymaga również zbioru treningowego o dużej liczebności.



Ryc. 8. Mapa prawdopodobieństwa, że dany superpixsel jest odłogiem w województwie łódzkim wykonana z użyciem klasyfikatora opartego na DCNN
 Źródło: Krysiak i in. (2020).

Semantyczna segmentacja

Celem segmentacji jest podział obrazu na charakterystyczne, rozłączne obszary, zwane regionami. Każdy region przypisany jest do co najmniej jednej ze ścisłe określonych kategorii. W ramach pojedynczej kategorii może znaleźć się więcej niż jeden region lub może pozostać ona bez przypisania do niej regionu. W przypadku gdy dodatkowo można rozróżnić regiony wyznaczone w obrębie jednej kategorii, mówimy o segmentacji instancji. Dla przykładu proces wyznaczania obszaru zabudowanego widocznego na zdjęciu satelitarnym można nazwać segmentacją instancji, gdy istnieje możliwość wyznaczenia granicy między dwoma

ma sąsiadującymi lub nachodzącymi na siebie budynkami. W przypadku gdy informacja o indywidualnych jednostkach nie jest dostępna i analiza przebiega tylko w obrębie kategorii, inaczej klasy, mowa jest o semantycznej segmentacji. Segmentacja może zostać przeprowadzona w sposób nadzorowany (gdy liczba kategorii oraz warunki przynależności do każdej z nich są znane) lub nienadzorowany (gdy poznanie warunków przypisania do klasy jest również celem badania). Semantyczna segmentacja jest szczególnym typem klasyfikacji, w której opracowaniu podlegają pojedyncze piksele. Wytrenowany model DL umożliwia wtedy przypisanie prawdopodobieństwa, z jakim każdy z pikseli należy do danej klasy. W zależności od oczekiwanej rezultatu końcowego dokonuje się wyboru kategorii z najwyższym prawdopodobieństwem, ustala wartości progowe lub zakłada, że dany obszar może należeć do więcej niż jednej kategorii. Poniżej zaprezentowano rezultat segmentacji obszarów leśnych w postaci mapy prawdopodobieństwa, tj. rastra o wartościach piksela z zakresu 0÷1 (ryc. 9). Im wyższa wartość, tym większa szansa, że dany piksel przedstawia las.

Segmentacja wspiera rozwiązywanie szeregu bardzo ciekawych problemów badawczych. Doskonałymi przykładami jej zastosowania są: rozpoznawanie typów pokrycia terenu, wykrywanie stopnia oraz typu zachmurzenia, delimitacja obszarów zabudowanych lub pomiar i kontrola zasiewów. Intuicyjnym wykorzystaniem segmentacji we wspomaganiu interpretacji przestrzeni geograficznej jest uzyskiwanie informacji o powierzchni zajmowanej przez określony typ pokrycia terenu. Rozwiązywanie to należy brać pod uwagę w przypadku, gdy badany obszar

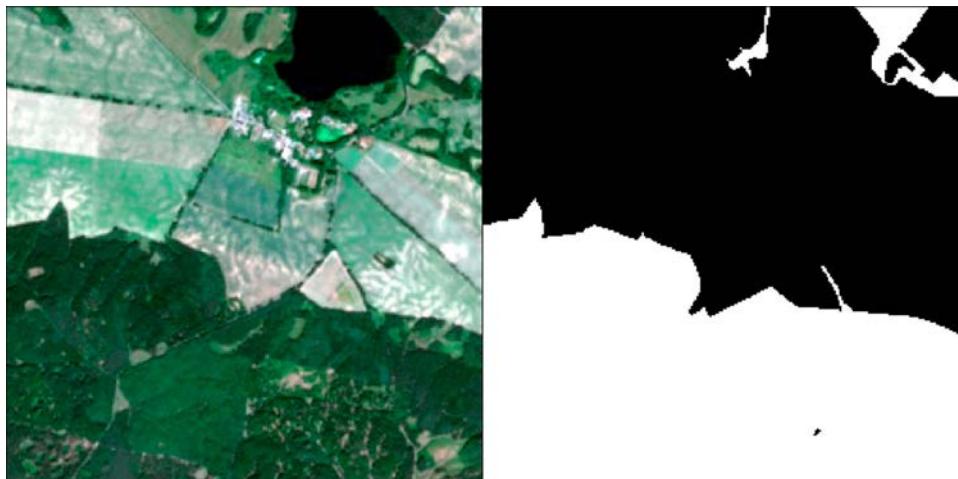


Ryc. 9. Mapa segmentacyjna (po lewej) oraz mapa prawdopodobieństwa (po prawej) uzyskana podczas analizy zdjęcia satelitarnego (Sentinel-2) obszaru Polski z użyciem modelu semantycznej segmentacji (U-Net)

Źródło: opracowanie własne.

jest znaczących rozmiarów, jak obszar województwa czy kraju. Ze względu na dużą złożoność cech pokrycia terenu, wielkość i różnorodność informacji oferowanych przez obrazy satelitarne, opracowanie modelu zdolnego do określenia przynależności do danej kategorii jest zadaniem nietrywialnym. Tradycyjnie wykorzystywany algorytmami są SVM oraz *maximum likelihood classification* (MLC) (Hu i in., 2018). W porównaniu do modeli opartych na DCNN klasyfikatorom tym brakuje jednak dokładności. Olbrzymią zaletą DCNN jest tworzenie bogatego kontekstu powiązań między wydobytymi cechami obrazu. Jednocześnie DCNN wymaga dłuższego czasu trenowania oraz często większego zbioru danych wejściowych niż klasyczne algorytmy.

Spójrzmy, w jaki sposób semantyczna segmentacja oparta na modelu DL została zastosowana w badaniu związanym z wykrywaniem przyczyn rozbieżności między ewidencją lasów a stanem faktycznym (Adamiak i in., 2020). Główną metodą wykorzystaną w badaniu jest regresja ważona geograficznie (ang. *geographically weighted regression*, GWR), dla której zmienną objaśnianą jest różnica w wartościach wskaźnika lesistości obszaru gminy otrzymanego przez zastosowanie semantycznej segmentacji oraz jego wartości dostępnej w rejestrze gruntów. Badanie obejmowało obszar Polski. W procesie uczenia maszynowego użyto danych pochodzących z bazy danych obiektów topograficznych (BDOT) (Główny Urząd Geodezji i Kartografii, 2021) oraz obrazów satelitarnych Sentinel-2 z 2018 r., które to zostały wykorzystane odpowiednio do wykonania map segmentacyjnych oraz



Ryc. 10. Przykład danych wejściowych segmentacyjnej sieci neuronowej będących połączeniem wycinka arkusza obrazu satelitarnego Sentinel-2 (po lewej) obszaru Polski oraz mapy segmentacyjnej powstałej przez przetworzenie odpowiedniej warstwy BDOT (po prawej)

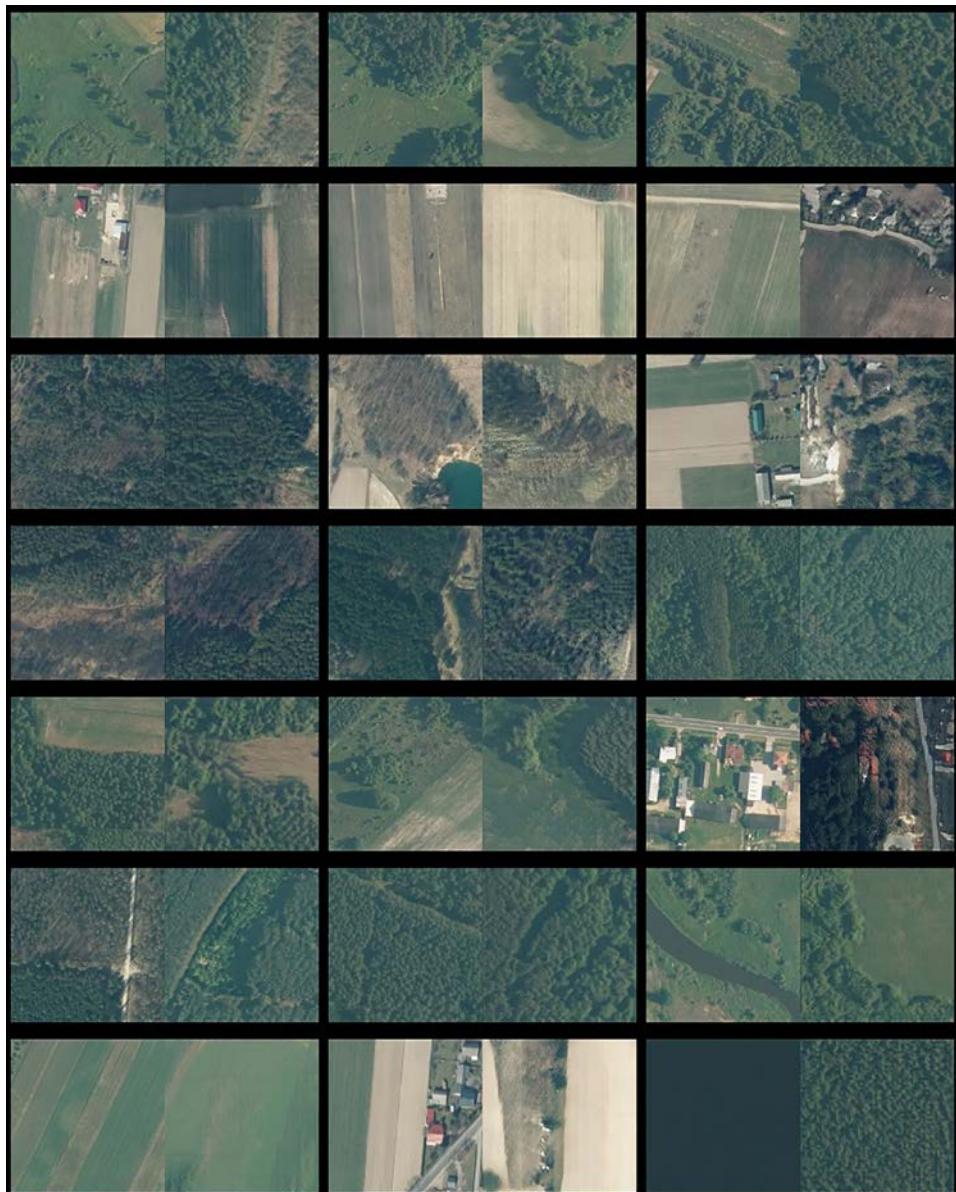
Źródło: Adamiak i in. (2020).

jako materiał wejściowy do sieci neuronowej (ryc. 10). Mapa segmentacyjna (ang. *segmentation map*) zawiera informacje o przypisaniu każdego piksela badanego rastra do wybranej kategorii. Każdy z obrazów stanowiący zbiór uczący model ma odrębną mapę segmentacyjną. Piksel reprezentujący las oznaczono jedynką, a zatem w innym przypadku. Do segmentacji zdecydowano się wykorzystać model sieci neuronowej U-Net (Ronneberger i in., 2015). U-Net dostosowuje koncepcję DCNN do procesu wyznaczania homogenicznych regionów. Składa się z dwóch ścieżek: kontrakcyjnej i ekspansywnej. Ścieżka kontrakcyjna zbudowana jest z wielu następujących po sobie warstw konwolucyjnych, które konsekwentnie zmniejszają rozmiar obrazu i reprezentują jego cechy w coraz to większej liczbie kanałów (ang. *feature map*) (Ćiçek i in., 2016). Ścieżka ekspansywna odwraca proces zmniejszania i stara się przy tym doprowadzić obraz do pierwotnego rozmiaru przy jednoczesnym przypisaniu jednolitych obszarów do osobnych kanałów. Każdy wyjściowy kanał tożsamy jest z inną kategorią pokrycia terenu. Bardziej złożoną alternatywą dla U-Net są: FPN (Lin i in., 2017), Linknet (Chaurasia, Culurciello, 2017), PSPNet (Zhao H. i in., 2017) oraz DeepLabV3+ (Chen L.-C. i in., 2017).

Augmentacja

Wydobywanie cech obrazu jest wpisane w mechanizm uczenia modelu DL. Informacje uzyskane w procesie tworzenia reprezentacji można wykorzystać dwojako. W sposób pośredni opis cech obrazu może być użyty jako forma przejściowa między wejściem do modelu, czyli surowym obrazem, a właściwym zadaniem analitycznym, jakim dla przykładu są klasyfikacja i segmentacja. Istnieje również możliwość wykorzystania reprezentacji jako docelowego obiektu badania. Warstwy ukryte sieci neuronowej udostępniają mechanizm kodujący obraz. Kodowanie jest możliwe, ponieważ sieć neuronowa w procesie uczenia opartego na zbiorze treningowym (ang. *training set*) pozyskuje z każdą iteracją coraz to więcej informacji o badanej domenie. Dzięki temu jest w stanie poddać interpretacji również obiekty, z którymi nie miała styczności podczas uczenia się. Sieć nasycona informacjami o przestrzeni geograficznej pochodzących z obrazowania lotniczego lub satelitarnego zapewnia nie tylko możliwość klasyfikacji czy segmentacji, ale stanowi również źródło nowych próbek. Innymi słowy, może stać się generatorem. Właściwość ta umożliwia realizację szeregu niezmiernie interesujących zadań, jakimi są: augmentacja, czyli wzmacnianie zbioru przez tworzenie nowych, syntetycznych, ale realistycznie wyglądających obrazów (Adamiak, Nalej, 2020; Zhao W. i in., 2020), usunięcie szumów i artefaktów (Burdziakowski, 2020), redukcja pokrycia obrazu chmurami przez wrysowanie w ich miejsce danych (*inpainting*) i wreszcie nienadzorowana segmentacja oraz inżynieria cech.

Siecią neuronową, której architektura oparta jest na DCNN i która umożliwia generowanie obrazu, jest GAN (ang. *generative adversarial network*). GAN zbudu-



Ryc. 11. Rezultat rekonstrukcji 21 próbek testowych ortofotomapy przedstawiającej okolice rzeki Pilicy. Każda z sekcji zawiera oryginalny obraz (po lewej) oraz jego rekonstrukcję (po prawej)

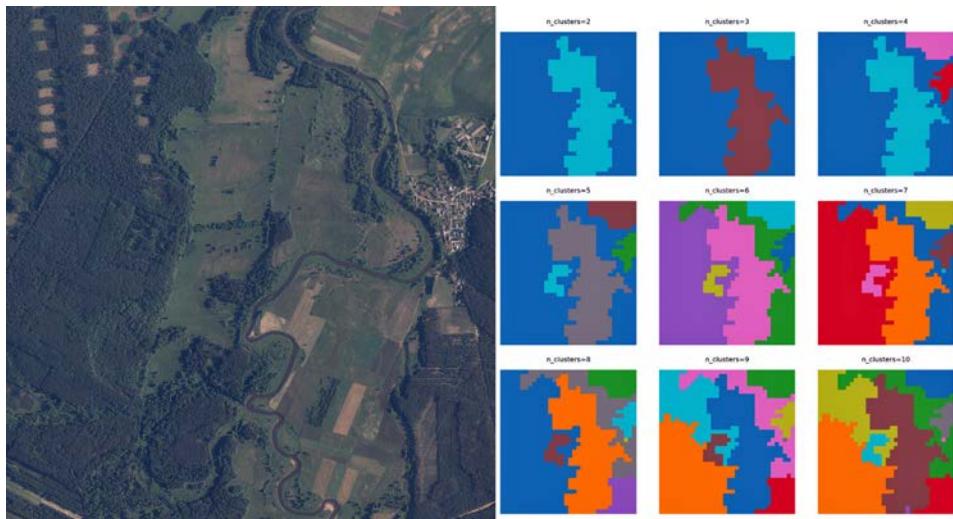
Źródło: Adamiak i in. (2021), geoportal.gov.pl.

wany jest z co najmniej jednego dyskryminatora i jednego generatora. Zadaniem generatora jest wytworzenie takiego rezultatu, aby oszukać dyskryminator. Jednocześnie dyskryminator stara się być coraz lepszy w odgadywaniu zamiarów generatora. W trakcie procesu uczenia GAN obie sieci konkurują ze sobą, tworząc z czasem coraz doskonalsze rezultaty (Goodfellow i in., 2014). Rycina 11 jest rezultatem pracy modelu BigBiGAN (Donahue, Simonyan, 2019) wytrenowanego w oparciu o wycinki ortofotomapy przedstawiającej okolice rzeki Pilicy. Pierwszy wycinek każdej pary zawiera obraz referencyjny (prawdziwy). Drugi to rezultat procesu rekonstrukcji, w którym zdjęcie referencyjne zostało sprowadzone do uproszczonej reprezentacji w formie kodu liczbowego. Kod ten został następnie użyty, aby stworzyć syntetyczny obraz. Należy zauważać, że w tym konkretnym przypadku rekonstrukcja nie zachodzi na poziomie pojedynczych piksel, lecz cech badanego obszaru. Innymi słowy, jej rezultatem nie jest identyczny wycinek względem referencyjnego, ale obraz o podobnej treści i tematyce. Możliwość tworzenia syntetycznego obrazu jest nie do przecenienia w przypadku ograniczonej dostępności danych wynikającej z kosztu ich pozyskania lub opracowania. Wygenerowane próbki mogą stać się częścią zbioru treningowego innego modelu ML lub zostać przeznaczone jedynie do jego testowania. Ostatnie rozwiązanie jest popularne ze względu na możliwość tworzenia próbek przedstawiających rzadko występujące zjawiska, umożliwiając w ten sposób sprawdzenie modelu w skrajnych warunkach.

Inżynieria cech

Inżynieria cech to złożony proces, którego zadaniem jest transformacja zbioru danych i jego utrwalenie w formie adekwatnej do wybranej metody analitycznej. Przykładami tego procesu są: analiza obrazu w celu ekstrakcji cech lub wyodrębnienia informacji o występowaniu pewnego zjawiska, redukcja wymiarowości zbioru z użyciem analizy głównych składowych (ang. *principal component analysis*, PCA), usuwanie zbędnych lub kreowanie nowych atrybutów i wiele innych. Od jakości zabiegów przeprowadzonych na zbiorze w ramach inżynierii cech bezpośrednio zależy skuteczność opracowywanego modelu ML.

Dostęp do zaawansowanej inżynierii cech dostarcza GAN. W projekcie badawczym dotyczącym nienadzorowanego procesu segmentacji ortofotomap obszaru położonego nad środkowym biegiem Pilicy opracowano rozwiązanie (Adamiak i in., 2021), które w oparciu o GAN umożliwia wyrażanie badanego obszaru jako zbioru, wspominanych wcześniej kodów liczbowych. Kody te są ściśle powiązane z reprezentacją obrazu opisaną wewnątrz generatora. Pojedynczy kod zawiera informacje o sile, występowaniu i interakcji cech przestrzeni, której obraz posłużył do wytrenowania sieci. Kod ten wraz z możliwością przypisania georeferencji jest przydatny do wykorzystania w dalszej analizie. W cytowanym artykule na



Ryc. 12. Obszar testowy 72961_840430_M-34-40-B-a-2-3 (Bobrowniki, województwo świętokrzyskie) oraz rezultat grupowania oparty na sztucznie wytworzonych kodach

Źródło: Adamiak i in. (2021), geoportal.gov.pl.

zbiorze georeferencjonowanych kodów liczbowych przeprowadzono proces segmentacji z wykorzystaniem aglomeracyjnego grupowania metodą Warda (ryc. 12). Rezultat jest o tyle interesujący, że powstał w pełni automatycznie tylko na podstawie materiału wejściowego, jakim było 39 826 kwadratowych wycinków 512 px × 512 px przy rozmiarze piksela równym 0,25 m. Tego typu rozwiązania, choć mniej dokładne niż ręczna lub nadzorowana segmentacja, umożliwiają pracę z dużymi obszarami badawczymi. Mogą również prowadzić do odkrywania nieuchwytnych dla ludzkiej percepcji zależności, co ma wielkie znaczenie w analizie skomplikowanego materiału z obrazowania hiperspektralnego, a także stanowić specyficzny rodzaj kompresji. Mają też ograniczenia, z których główne związane jest ze stopniem skomplikowania procesu i trudnością precyzyjnego wyjaśnienia, w jaki sposób dany model, zastosowany w inżynierii cech, doszedł do otrzymanego rozwiązania.

PODSUMOWANIE

Uczenie maszynowe udostępnia badaczom potężny zestaw metod przetwarzania oraz interpretacji przestrzeni geograficznej. Współcześnie możliwość wieloaspektowej i precyzyjnej analizy materiału pochodzącego z obrazowania lotniczego i satelitarnego jest nie do przecenienia. Możliwości pracy niewspieranej przez zautomatyzowany mechanizm badawczy są znaczaco utrudnione w przypadku

częstej konieczności przetwarzania olbrzymiego wolumenu wysokiej jakości danych. Staje się ona jeszcze trudniejsza, gdy opracowanie danych wymagane jest w czasie rzeczywistym. Wykorzystanie ML w teledetekcji oraz naukach o Ziemi nie jest nowym zagadnieniem. Jednak dopiero współcześnie, głównie dzięki możliwościom obliczeniowym komputerów personalnych zaopatrzonych w wydajne karty graficzne (GPU, ang. *graphics processing unit*), można wykorzystać ich cały potencjał. Kryje się on bezsprzecznie w uczeniu głębokim z użyciem sztucznych sieci neuronowych. Zaletą DL jest możliwość wsparcia pracy badacza w obrębie szerokiego spektrum problemów badawczych. Niniejsza praca traktuje o trzech powszechnie stosowanych technikach, tj.: klasyfikacji, semantycznej segmentacji, augmentacji oraz inżynierii cech w kontekście pracy z materiałem pochodząącym z obrazowania lotniczego i satelitarnego. Wśród innych wartych uwagi zagadnień są również: segmentacja instancji, rozpoznawanie aktywności, wykrywanie obiektów, detekcja nowości i anomalii, redukcja szumów i wiele więcej. Przykłady przybliżone w pracy potwierdzają, że elastyczność rozwiązań opartych na DL jest na tyle duża, że z powodzeniem można wpisać je w najbardziej zaawansowane projekty badawcze. Co więcej, umożliwiają one podejmowanie problemów, które wcześniej były niedostępne ze względu na swoją złożoność lub zakres przestrzenny opracowania.

DL stanowi nieroziłączną część warsztatu narzędziowego specjalistów zajmujących się przetwarzaniem obrazu. Jest tylko kwestią czasu, gdy na stałe wpisze się w kanon geoinformacji, szeroko pojętej analizy przestrzennej oraz geografii. Nim to jednak nastąpi, DL przejdzie istotną transformację dostosowującą do wymogów współczesnego procesu naukowego. Mowa o możliwości przejrzystego wytłumaczenia działania sieci neuronowej czy algorytmu (*explainable AI*), tworzeniu rozwiązań deterministycznych (*deep evidential learning*) i zapewnieniu o uczciwości modelu (*bias and fairness*) (Amini, 2021). Jednocześnie intensywnie rozwijać się będą dziedziny wspierające, tj.: inżynieria danych (*data engineering*), inżynieria oprogramowania (*software engineering*), geograficzne systemy informacji (GIS), a także wizualizacja i prezentacja. Jeśli chodzi o bezpośredni wpływ na nauki o Ziemi i środowisku to wydaje się, że najwięcej korzyści zastosowanie DL może przynieść takim obszarom nauki, jak geografia fizyczna kompleksowa, hydrografia, gleboznawstwo czy geografia miast, które będą dzięki niemu mogły zwiększyć obszar badań przy jednoczesnym zachowaniu wysokiej precyzji wyników.

Oprogramowanie wykorzystywane współcześnie w pracach badawczych z zakresu geografii, tj.: ArcGIS, QGIS czy SAGA GIS, od dawna umożliwia rozwiązywanie przytoczonych w tekście problemów. Wspomniane aplikacje oferują olbrzymi, jednak skończony, zestaw funkcjonalności, dostępnych w ramach konkretnych wersji oprogramowania. Często dostępne pakiety okazują się nie wystarczające. Rozszerzenie analizy o elementy DL możliwe jest wtedy przez

zaimplementowanie odpowiedniej wtyczki lub pośrednio przez utworzenie samodzielnego skryptu lub usługi współpracującej z popularnymi rozwiązaniami bazodanowymi czy formatami plików, takimi jak TIFF, SHP, CSV czy GeoJSON, np.: numpy, pandas, geo-pandas czy rasterio. Popularnymi bibliotekami wspierającymi uczenie maszynowe i głębokie uczenie są: Scikit-Learn, Apache Spark DL, Tensorflow i PyTorch. Oprócz bogatej dokumentacji popartej wieloma przykładami, badacz znajdzie dostęp do szerokiej oferty szkoleń. Warto również zapoznać się z osiągnięciami dziedziny inżynierii oprogramowania zajmującej się integracją i wdrożeniem rozwiązań uczenia maszynowego, którą jest Machine Learning Operations (MLOps). Doskonałym przykładem mogą być usługi Amazon SageMaker czy Google Vertex AI, które w równym stopniu nadają się do zastosowań komercyjnych, jak i w pracach badawczych.

Mimo przydatności metod DL oraz teledetekcji w interpretacji przestrzeni geograficznej nie należy zapominać o roli, jaką w pracy badawczej odgrywają badania terenowe. Zrozumienie badanego obszaru oraz zjawisk panujących w jego obrębie jest pierwszym i najważniejszym krokiem do wypracowania wysokiej jakości zbioru danych, który posłuży jako materiał do wytrenowania złożonego modelu DL. Proces budowania i trenowania sieci neuronowej bez względu na to, czy odbywa się w sposób nadzorowany czy nienadzorowany, wymaga udziału eksperta. Zadaniem eksperta jest poddać rezultat pracy modelu interpretacji oraz weryfikacji, a także dostarczyć wiedzy, która posłuży modelowi za wzorzec. Innymi słowy, metody DL są tak dobre jak specjalisci zajmujący się ich opracowaniem. Wprawne połączenie współcześnie dostępnych metod uczenia maszynowego z wiedzą z zakresu nauk o Ziemi pozwoli na podejmowanie nowych eksytujących problemów badawczych oraz powracanie do wcześniej postawionych pytań.

Autor ma nadzieję, że niniejszy artykuł umożliwi czytelnikom ogólne zapoznanie się z tematem uczenia głębokiego we wspieraniu interpretacji przestrzeni geograficznej oraz będzie impusem do wnikliwej eksploracji zagadnienia.

Podziękowania

Serdecznie podziękowania dla prof. Krzysztofa Będkowskiego oraz dr Anny Majchrowskiej za nadzór merytoryczny nad pracą oraz dla dr. Stanisława Krysiaka za wartościowe uwagi odnośnie do pracy.

LITERATURA

- Adamiak M., Będkowski K., Majchrowska A. (2021). Aerial Imagery Feature Engineering Using Bidirectional Generative Adversarial Networks: A Case Study of the Pilica River Region, Poland. *Remote Sensing*, 13(2): 306. <https://doi.org/10.3390/rs13020306>

- Adamiak M., Biczkowski M., Leśniewska-Napierała K., Nalej M., Napierała T. (2020). Impairing Land Registry: Social, Demographic, and Economic Determinants of Forest Classification Errors. *Remote Sensing*, 12(16): 2628. <https://doi.org/10.3390/rs12162628>
- Adamiak M., Nalej M. (2020). *Generative adversarial networks in satellite image datasets augmentation*. Medium (<https://blog.softwaremill.com/generative-adversarial-networks-in-satellite-image-datasets-augmentation-b7045d2f51ab>).
- Amini A. (2021). *MIT 6.S191. Deep Learning New Frontiers* (<https://youtu.be/-boCMD0-uF2g>).
- Anantrasirichai N., Biggs J., Albino F., Bull D. (2019). A deep learning approach to detecting volcano deformation from satellite imagery using synthetic datasets. *Remote Sensing of Environment*, 230: 111179. <https://doi.org/10.1016/j.rse.2019.04.032>
- Bengio Y., Courville A., Vincent P. (2014). Representation Learning: A Review and New Perspectives. *arXiv:1206.5538 [cs]* (<http://arxiv.org/abs/1206.5538>).
- Bishop C.M. (2006). *Pattern Recognition and Machine Learning*. Springer-Verlag (<https://www.springer.com/gp/book/9780387310732>).
- Boyd D.S. (2009). Remote sensing in physical geography: A twenty-first-century perspective. *Progress in Physical Geography: Earth and Environment*, 33(4): 451–456. <https://doi.org/10.1177/030913309346645>
- Burdziakowski P. (2020). A Novel Method for the Deblurring of Photogrammetric Images Using Conditional Generative Adversarial Networks. *Remote Sensing*, 12(16): 2586. <https://doi.org/10.3390/rs12162586>
- Chaurasia A., Culurciello E. (2017). LinkNet: Exploiting encoder representations for efficient semantic segmentation. *2017 IEEE Visual Communications and Image Processing (VCIP)*, 1–4. <https://doi.org/10.1109/VCIP.2017.8305148>
- Chen L.-C., Papandreou G., Schroff F., Adam H. (2017). Rethinking Atrous Convolution for Semantic Image Segmentation. *arXiv:1706.05587 [cs]* (<http://arxiv.org/abs/1706.05587>).
- Chollet F. (2016). Xception: Deep Learning with Depthwise Separable Convolutions. *arXiv:1610.02357 [cs]* (<http://arxiv.org/abs/1610.02357>).
- Çiçek Ö., Abdulkadir A., Lienkamp S.S., Brox T., Ronneberger O. (2016). 3D U-Net: Learning Dense Volumetric Segmentation from Sparse Annotation. *arXiv:1606.06650 [cs]* (<http://arxiv.org/abs/1606.06650>).
- Dabija A., Kluczek M., Zagajewski B., Raczkowski E., Kycko M., Al-Sulttani A.H., Tardà A., Pineda L., Corbera J. (2021). Comparison of Support Vector Machines and Random Forests for Corine Land Cover Mapping. *Remote Sensing*, 13(4): 777. <https://doi.org/10.3390/rs13040777>
- DeepLearning.AI. (2021). Coursera (<https://www.coursera.org/specializations/deep-learning?>).
- Donahue J., Simonyan K. (2019). Large Scale Adversarial Representation Learning. *arXiv:1907.02544 [cs, stat]* (<http://arxiv.org/abs/1907.02544>).
- Dziennik Ustaw (2020). Dziennik Ustaw 2020 r. poz. 1086 (<https://www.dziennikustaw.gov.pl/DU/2020/1086>).

- Geoportal* (2020) (<http://geoportal.gov.pl>).
- Ghorbanzadeh O., Blaschke T., Gholamnia K., Meena S.R., Tiede D., Aryal J. (2019). Evaluation of Different Machine Learning Methods and Deep-Learning Convolutional Neural Networks for Landslide Detection. *Remote Sensing*, 11(2): 196. <https://doi.org/10.3390/rs11020196>
- Główny Urząd Geodezji i Kartografii (2021). *Zintegrowane kopie baz danych obiektów topograficznych BDOT10k*. Główny Urząd Geodezji i Kartografii (<http://www.gugik.gov.pl/pzgik/zamow-dane/baza-danych-obiektow-topograficznych-bdot-10k>).
- Goodfellow I.J., Pouget-Abadie J., Mirza M., Xu B., Warde-Farley D., Ozair S., Courville A., Bengio Y. (2014). Generative Adversarial Networks. *arXiv:1406.2661 [cs, stat]* (<http://arxiv.org/abs/1406.2661>).
- Gron A. (2019). *Hands-On Machine Learning with Scikit-Learn and Tensor Flow: Concepts, Tools, and Techniques to Build Intelligent Systems*. Wyd. 2. O'Reilly Media, Inc.
- He K., Zhang X., Ren S., Sun J. (2015). Deep Residual Learning for Image Recognition. *arXiv:1512.03385 [cs]* (<http://arxiv.org/abs/1512.03385>).
- Hu Y., Zhang Q., Zhang Y., Yan H. (2018). A Deep Convolution Neural Network Method for Land Cover Mapping: A Case Study of Qinhuangdao, China. *Remote Sensing*, 10(12): 2053. <https://doi.org/10.3390/rs10122053>
- Kałużna U., Będkowski K. (2020). Klasyfikacja pokrycia terenu z wykorzystaniem obrazów Sentinel-2A przetworzonych za pomocą metody głównych składowych (PCA). *Teledetekcja Środowiska*, 61 (<http://yadda.icm.edu.pl/baztech/element/bwmeta1.element.baztech-2e165147-5471-45fb-9cbe-69e90347749c>).
- Kamilaris A., Prenafeta-Boldu F. (2018). *A review of the use of convolutional neural networks in agriculture*. <https://doi.org/10/gf4w4k>
- Kellenberger B., Marcos D., Lobry S., Tuia D. (2019). Half a Percent of Labels is Enough: Efficient Animal Detection in UAV Imagery Using Deep CNNs and Active Learning. *IEEE Transactions on Geoscience and Remote Sensing*, 57(12): 9524–9533. <https://doi.org/10.1109/TGRS.2019.2927393>
- Krysiak S., Adamczyk J., Majchrowska A., Papińska E., i Sieradzki, J. (2016). *Ekologiczna rola odłogów stref otaczających parki krajobrazowe w województwie łódzkim*. Łódź: Wydawnictwo Uniwersytetu Łódzkiego.
- Krysiak S., Papińska E., Majchrowska A., Adamiak M., Koziarkiewicz M. (2020). Detecting Land Abandonment in Łódź Voivodeship Using Convolutional Neural Networks. *Land*, 9(3): 82. <https://doi.org/10.3390/land9030082>
- Kussul N., Lavreniuk M., Skakun S., Shelestov A. (2017). Deep Learning Classification of Land Cover and Crop Types Using Remote Sensing Data. *IEEE Geoscience and Remote Sensing Letters*, 14(5): 778–782. <https://doi.org/10.1109/LGRS.2017.2681128>
- Landsat 8 – Landsat Science*. (2020) (<https://landsat.gsfc.nasa.gov/landsat-8/>).
- Lillesand T., Kiefer R., Chipman J. (2015). *Remote Sensing and Image Interpretation. W The Geographical Journal*, 146. John Wiley & Sons. <https://doi.org/10.2307/634969>
- Lin T.-Y., Dollár P., Girshick R., He K., Hariharan B., Belongie S. (2017). Feature Pyramid Networks for Object Detection. *arXiv:1612.03144 [cs]* (<http://arxiv.org/abs/1612.03144>).
- Malinowski R., Lewiński S., Rybicki M., Gromny E., Jenerowicz M., Krupiński M., Nowakowski A., Wojtkowski C., Krupiński M., Krätzschmar E., Schauer P. (2020). Auto-

- mated Production of a Land Cover/Use Map of Europe Based on Sentinel-2 Imagery. *Remote Sensing*, 12(21): 3523. <https://doi.org/10.3390/rs12213523>
- Mitchell T.M. (1997). *Machine Learning*. McGraw-Hill.
- Pleiades – EoPortal Directory – Satellite Missions* (2020) (<https://earth.esa.int/web/eoportal/satellite-missions/p/pleiades>).
- Ronneberger O., Fischer P., Brox T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. *arXiv:1505.04597 [cs]* (<http://arxiv.org/abs/1505.04597>).
- Schmidhuber J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61: 85–117. <https://doi.org/10.1016/j.neunet.2014.09.003>
- Sentinel-2 – ESA Operational EO Missions – Earth Online – ESA* (2020) (<https://earth.esa.int/web/guest/missions/esa-operational-eo-missions/sentinel-2>).
- Sobel I. (1968). An Isotropic 3×3 Image Gradient Operator. *Presentation at Stanford A.I. Project 1968*.
- Szegedy C., Liu W., Jia Y., Sermanet P., Reed S., Anguelov D., Erhan D., Vanhoucke V., Rabinovich A. (2014). Going Deeper with Convolutions. *arXiv:1409.4842 [cs]* (<http://arxiv.org/abs/1409.4842>).
- Tang Q., Gao H., Lu H., Lettenmaier D.P. (2009). Remote sensing: Hydrology. *Progress in Physical Geography: Earth and Environment*, 33(4): 490–509. <https://doi.org/10.1177/0309133309346650>
- Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A.N., Kaiser L., Polosukhin I. (2017). Attention Is All You Need. *arXiv:1706.03762 [cs]* (<http://arxiv.org/abs/1706.03762>).
- Zhang X., Han L., Han L., Zhu L. (2020). How Well Do Deep Learning-Based Methods for Land Cover Classification and Object Detection Perform on High Resolution Remote Sensing Imagery? *Undefined (/paper/How-Well-Do-Deep-Learning-Based-Methods-for-Land-on-Zhang-Han/e71c80ed8bb174faed43e7a28a4e07dc2620dbb3)*.
- Zhao H., Shi J., Qi X., Wang X., Jia J. (2017). Pyramid Scene Parsing Network. *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 6230–6239. <https://doi.org/10.1109/CVPR.2017.660>
- Zhao W., Chen X., Chen J., Qu Y. (2020). Sample Generation with Self-Attention Generative Adversarial Adaptation Network (SaGAAN) for Hyperspectral Image Classification. *Remote Sensing*, 12(5): 843. <https://doi.org/10.3390/rs12050843>