

Artykuł naukowy

## **Identyfikacja obszarów miejskich na zobrażowaniach SAR i w bazie danych Urban Atlas**

Identification of urban areas on SAR imagery and in Urban Atlas  
database

**Joanna Pluto-Kossakowska<sup>1</sup>, Sandhi Wangiyana<sup>2</sup>**

<sup>1</sup>Zakład Fotogrametrii, Teledetekcji i Systemów Informacji Przestrzennej,  
Politechnika Warszawska

<sup>2</sup>Szkoła Doktorska, Instytut Systemów Elektronicznych, Politechnika Warszawska

### ***Abstract***

*This study aimed to evaluate the usefulness of Synthetic Aperture Radar (SAR) data in the X and C bands for classifying built-up areas based on the Urban Atlas classification scheme. The research focused on the ability to distinguish between land cover classes of varying building density and land use, using both backscatter intensity and texture features derived from the Grey Level Co-occurrence Matrix (GLCM) method. Satellite imagery from Sentinel-1 and ICEYE was used for two urban agglomerations: Warsaw and London, with the Urban Atlas database serving as a reference layer after thematic aggregation into seven classes. The results indicate that SAR imagery enables effective identification of key land cover types, particularly dense urban fabric, vegetation, and water. The high spatial resolution of X-band imagery enhances the representation of urban structure, while texture images improve class separability in areas with similar scatter intensities. It has also been demonstrated that VV and VH polarizations differentiate classes with different urban density and function. The study confirms the potential of SAR data as a complementary source for updating reference databases and for automating the classification of urbanized zones.*


**Słowa kluczowe: Urban Atlas, SAR, gęstość zabudowy, tekstura, obszar zurbanizowany**

**Keywords: Urban Atlas, SAR, building density, classification, texture, urban area**

## Wstęp

Motywacją podjętych badań jest potrzeba cyklicznej analizy terenów zabudowanych w kontekście dynamicznych zmian w miastach. Elementy zwarte miasta można rozumieć jako fizyczną obecność obiektów szarej infrastruktury, a tym samym pokrycie powierzchniami nieprzepuszczalnymi (ang. *imperviousness*) takimi jak zabudowa, trasy komunikacyjne, obszary przemysłowe lub inne obszary pokryte sztucznymi materiałami. Detekcja takich obszarów jest już obecnie stosowana na obrazowaniach satelitarnych z wykorzystaniem uczenia maszynowego i udostępniana jako produkty satelitarne (HRL Copernicus 2024). Ułatwia to i znacząco przyspiesza automatyzację analiz przestrzennych lub analizę zmian w czasie (Lefebvre, Sannier, and Corpetti 2016). Brakuje jednak metod analizy i przetwarzania danych teledetekcyjnych w skalach szczegółowych, gdzie ważne jest rozróżnienie klas pod względem zawartości i funkcji zabudowy podobnie jak to jest zdefiniowane w różnych bazach danych, w tym m.in. w Urban Atlas (UA). Baza danych Urban Atlas rozróżnia klasy pokrycia terenu pod względem zajętości danego obszaru (poligonu) przez budynki oraz inne obiekty szarej infrastruktury. W definicji klas baza ta uwzględnia pokrycie jak i funkcję danego obszaru. Dla interpretatora zagadnienie jednoczesnej oceny pokrycia i użytkowania terenu może być złożone, ale wykonalne. Jednak dla algorytmów uczenia maszynowego, w tym przygotowania danych treningowych, uwzględnienie funkcji lub innych cech niż tylko pokrycie terenu jest wyzwaniem. Niniejsze badanie ma wskazać w jakim stopniu dane rejestrowane w różnych zakresach mikrofalowych mogą wspomóc automatyczną detekcję i rozróżnienie klas na obszarach miejskich. Wstępne wyniki wcześniej podjętych badań wskazują na możliwość rozróżnienia klas zabudowy (Pluto-Kossakowska, Giczán 2023).

Satelitarne dane SAR (Synthetic Aperture Radar) rejestrują odmienną od danych optycznych informację, która może wspomóc rozróżnienie klas w terenach zabudowanych. Różny mechanizm rozpraszania sygnału przez obiekty antropogeniczne oraz naturalne powoduje, że obszary te są możliwe do identyfikacji i rozróżnienia pod względem intensywności rozproszenia sygnału (Rys. 1).



**Rys. 1.** Podstawowe mechanizmy odbicia mikrofal i interakcji z obiektami w obszarze zurbanizowanym (zmodyfikowane na podstawie: Meyer, 2025).

Obserwacje dla poszczególnych polaryzacji i ich konfiguracji pokazują, że silne rozpraszanie w polaryzacji HH powoduje podwójne odbicia (np. budynki). Natomiast wysokie wartości w polaryzacji VV odnoszą się do rozpraszania na szorstkiej powierzchni (np. goła ziemia, trawa). Różnice w polaryzacji krzyżowej wskazują na układ rozpraszaczy objętościowych (np. roślinność wysoka). Można te zależności ująć w następujące formuły:

Odbicie powierzchniowe:  $|S_{VV}| > |S_{HH}| > |S_{HV}|$  lub  $|S_{VH}|$

Odbicie podwójne:  $|S_{HH}| > |S_{VV}| > |S_{HV}|$  lub  $|S_{VH}|$

Odbicie objętościowe: głównie  $|S_{HV}|$  oraz  $|S_{VH}|$  (NASA 2019).

Nie tylko sama wartość wstecznego rozproszenia pozwala zidentyfikować kategorie pokrycia, także dodatkowe miary, jak tekstura obrazu, która reprezentuje układ przestrzenny obiektów. Odwzorowanie zabudowy zależy od intensywności rozpraszania wstecznego, która jest konsekwencją różnych parametrów fizycznych, w tym orientacji budynków do kierunku padania wiązki. Charakterystyka klas pod względem zwartości i gęstości zależy od rozmieszczenia i układu zabudowy, obrazy SAR mogłyby zatem wspierać rozpoznanie klas w obszarach zabudowanych. Badanie ma na celu ocenę możliwości zastosowania danych SAR w zakresie mikrofalowym X i C do detekcji zabudowy na obszarze miejskim. Głównym zadaniem badawczym było przetwarzanie i analiza zobrazowań SAR pod kątem ich przydatności do identyfikacji klas na obszarach zurbanizowanych.

## Metodyka

Odwzorowanie obszaru zabudowanego na obrazie SAR zależy od orientacji budynków względem kierunku wiązki mikrofal. Orientacja w kierunku prostopadłym do wiązki fal powoduje bardzo silne rozpraszanie wsteczne. Natomiast budynki zorientowane w kierunku innym niż prostopadły mogą być odwzorowane znacznie słabiej ze względu na odbicie zwierciadlane od ich ścian. Intensywność rozpraszania wstecznego zależy również od geometrii budynku, wysokości, materiałów i otoczenia np. bliskość innych budynków, czy wysoka roślinność. W przypadku obszaru mieszkalnego z rozproszoną zabudową wartość zarejestrowanego promieniowania odbitego jest niższa, wyższa dla obszaru o wysokiej gęstości, a najwyższa dla obszaru przemysłowego. Ponadto tekstura jako funkcja układu przestrzennego budynków może być wykorzystana jako miara chropowatości i kierunkowości. Wspomniane charakterystyki rozproszenia i tekstury dla obszarów zabudowanych zostały wykorzystane do opisu klas pod względem pokrycia i gęstości zabudowy. Stąd istotnym etapem badań było zdefiniowanie i zamodelowanie gęstości zabudowy. W tym celu posłużono się bazą danych wektorowych Urban Atlas (UA) jako zbiorem referencyjnym.

UA to baza danych przestrzennych opracowana na obszarach aglomeracji miejskich w Europie. Powstała i jest aktualizowana głównie metodami fotointerpretacji satelitarnych zobrazowań optycznych VHR (Very High Resolution). Pełna nomenklatura uwzględnia podział na 27 klas, z czego na obszarach badawczych występowało 20 klas (Tabela 1). Minimalna jednostka powierzchni wydzielenia to 0,25 ha na obszarach miejskich oraz 1 ha na obszarach wiejskich. Dokładność pozycyjna zależy od dokładności zdjęć satelitarnych (średnio 2 m). Minimalna odległość między dwoma obiektami kartowania to 10 m. Te parametry są istotne nie tylko w procesie budowania bazy danych i rozpoznania klas, ale też mają swoje konsekwencje dla dalszego procesu pozyskania danych treningowych i wyników automatycznej klasyfikacji na zobrazowaniach SAR. Ogólna dokładność interpretacji (klasyfikacji manualnej) wynosi 85% w klasach miejskich (kategoria 1) oraz 80% w klasach pozostałych (od 2 do 5) (Urban Atlas 2021).

Klasyfikacja w bazie danych Urban Atlas dla obszarów mieszkalnych uwzględnia aż 6 klas rozróżnionych pod względem gęstości zabudowy czyli nieprzepuszczalności (ang. imperviousness) lub inaczej uszczelnienia (soil sealing). Klasa 11100 to *ciągła tkanka miejska* czyli obszary zabudowane i związane z nimi grunty o stopniu uszczelnienia gleby >80%. Dominujące użytkowanie jest mieszkaniowe i obejmuje obszary śródmiejskie, centra miast oraz dzielnice biznesowe, jeśli są one częściowo wykorzystywane do celów mieszkalnych. Klasa 1120 *nieciągła tkanka miejska* to głównie budynki mieszkalne, drogi i inne obszary o sztucznej nawierzchni, ale jest podzielona na kolejne podklasy.

**Tabela 1.** Nazwy i kody klas w Urban Atlas, klasy po agregacji i udział procentowy w obszarach badawczych. Wyjaśnienie skrótów: MMU (minimum mapping unit) – minimalna powierzchnia wydzielonego poligonu [ha], MinMW (minimum mapping width) – minimalna szerokość wydzielonego poligonu [m], SL (soil sealing) – zasklepienie gruntu w stosunku do wydzielonego poligonu [%]

Nazwy i kody klas w bazie danych Urban Atlas	Nowe kody i nazwy klas po agregacji	Udział procentowy klas w obszarze badań	
		Warszawa	London
1.1 Urban Fabric <i>MMU 0,25 ha</i>			
11100 Continuous Urban Fabric (SL > 80%)	1. duża gęstość zabudowy >80%	26,5	0,3
11210 Discontinuous Dense Urban Fabric (SL 50% - 80%)	2. średnia gęstość zabudowy (30-80%)	6,1	32,8
1122 11220 Discontinuous Medium Density Urban Fabric (SL 30% - 50%)			
11230 Discontinuous Low Density Urban Fabric (SL 10% - 30%)	3. mała gęstość zabudowy <30%	0,2	0,3
11240 Discontinuous Very Low Density Urban Fabric (SL < 10%)			
11300 Isolated structures			
1.2 Industrial, commercial, public, military, and transport units <i>MMU 0,25 ha</i>			
12210 Fast transit roads and associated land	4. drogi i linie kolejowe	10,4	7,5
12220 Other roads and associated land			
12230 Railways and associated land			
12100 Industrial, commercial, public, military and private units	5. obszary przemysłowe lub w budowie	18,4	17,2
12300 Port areas			
12400 Airports			
1.3 Mine, dump and construction sites			
13100 Mineral extraction and dump sites			
13300 Construction sites			
13400 Land without current use			
1.4 Artificial non-agricultural vegetated areas			
14100 Green urban areas <i>MMU 0,25 ha, MinMW: 10 m</i>	6. roślinność	30,5	33,6
14200 Sports and leisure facilities <i>MMU 0,25 ha, MinMW: 10 m</i>			
20000 Agricultural areas, semi-natural areas, and wetlands <i>MMU 1 ha</i>			
30000 Forests <i>MMU 1 ha</i>			
50000 Water <i>MMU 1 ha</i>	7. woda	2,3	5,1

Klasa 11210 *nieciągła gęsta tkanka miejska* gdzie stopień uszczelnienia gleby jest między 50%-80%. Klasa 11220 *nieciągła tkanka miejska o średniej gęstości* gdzie stopień uszczelnienia gleby jest między 30%-50%, a obszary porośnięte roślinnością są dominujące. Klasa 11230 *nieciągła tkanka miejska o małej gęstości* gdzie stopień uszczelnienia gleby jest między 10%-30%, obszary porośnięte roślinnością są dominujące, ale ziemia nie jest przeznaczona pod rolnictwo. Ostatnia podklasa to 11240 *nieciągła tkanka miejska o bardzo małej gęstości* gdzie stopień uszczelnienia gleby jest <10% to budynki mieszkalne i inne obszary o sztucznej nawierzchni z dominacją obszarów porośniętych roślinnością, np. domy mieszkalne z dużymi ogrodami. Ostatnia klasa to 11300 *odizolowane struktury* z komponentem mieszkalnym, takie jak małe, indywidualne gospodarstwa rolne i powiązane budynki. Zawiera zwykle kilka rozproszonych lub pojedynczych domów.

Tak zdefiniowane klasy w UA stanowiły podstawę do agregacji tematycznej klasy 1 o bardzo gęstej zabudowie (klasa 11100), klasy 2 o gęstości średniej (klasy 11210 i 11220) i klasy 3 o gęstości małej (klasy 11230, 11240 i 11300). Agregacja była niezbędnym krokiem to przygotowania danych treningowych oraz danych walidacyjnych wyników klasyfikacji nadzorowanej. Kolejna kategoria to obszary przemysłowe, handlowe, wojskowe i transportowe, które także zagregowano do dwóch klas tj. sieć dróg i szlaków kolejowych (klasa 4) oraz obszarów przemysłowych i w budowie (klasa 5). Ta agregacja była podyktowana specyfiką układu liniowych obiektów transportowych, a z drugiej strony wielkopowierzchniowych obiektów przemysłowych. Klasy z roślinnością tj. 14100 zielone obszary miejskie, 14200 obiekty sportowe i rekreacyjne, 20000 obszary rolnicze, półnaturalne i podmokłe, 30000 lasy stanowiły jedną wspólną klasę 6 – roślinność. Ta agregacja obszarów z roślinnością była podyktowana zadaniem rozróżnienia klas zabudowy i zbliżonym mechanizmem wstecznego rozpraszania na zobrażowaniach SAR.

W eksperymencie uwzględniono wszystkie klasy Urban Atlas po agregacji do 7 klas występujące na obszarach badawczych dwóch aglomeracji Warszawy i Londynu. Wartości w kolumnie C i D w tabeli 1 wskazują procentowy udział klas występujących w terenie. Proporcjonalnie większą powierzchnię zajmuje klasa 1 o dużej gęstości zabudowy w Warszawie (33%) niż w Londynie (26%). Natomiast klasa 2 o średniej gęstości ma większy udział w Londynie (7%) niż w Warszawie (0,4%). Pozostałe kategorie tj. klasa 3 – drogi, klasa 5 – obszary przemysłowe, klasa 6 – roślinność mają podobny udział w obu miastach. Klasa 7 ma większy udział w mieście Londyn, ale może to wynikać z dużego zbiornika, który znalazł się na wybranym obszarze.

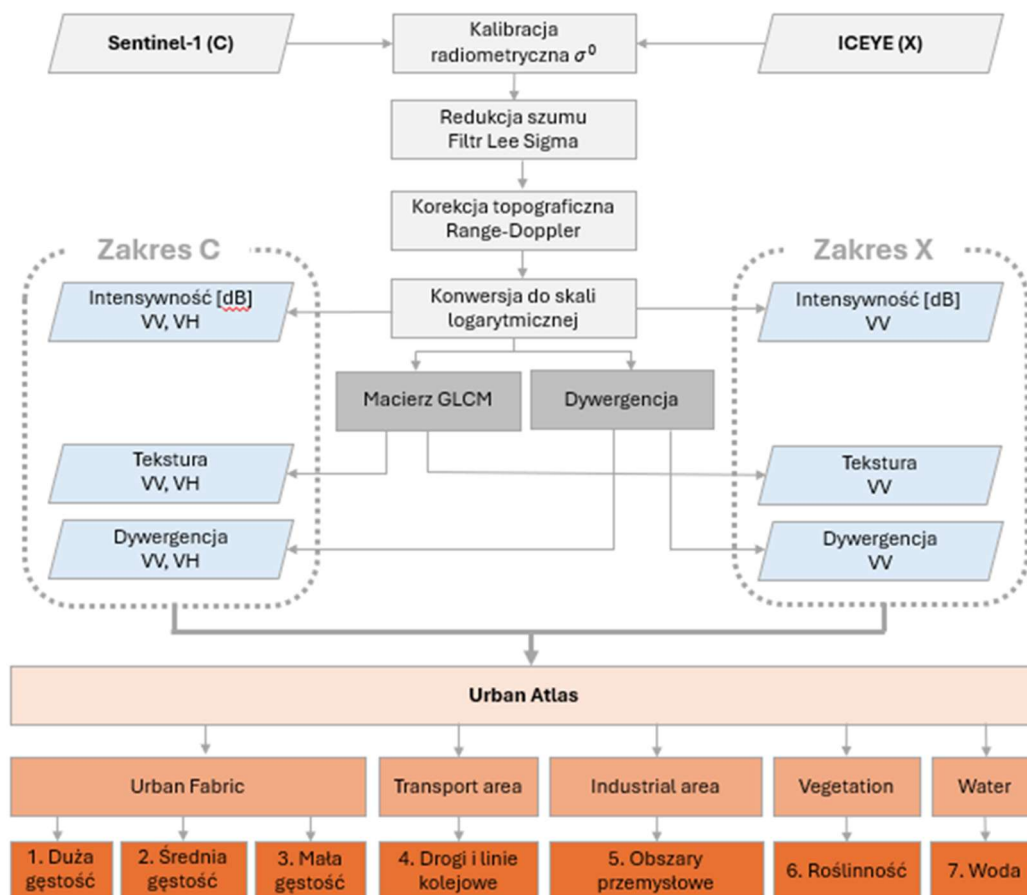
Do badań wykorzystano obrazy z różnych sensorów SAR, aby zapewnić różnorodność danych w zakresie polaryzacji (pojedynczej i podwójnej) oraz długości fal (pasmo X i C). Zobrażenia z satelitów ICEYE (VV) i Sentinel-1 (VV i VH) dobrano tak, aby terminy

pozyskiwanych zobrażeń pokrywały się ze sobą i obejmowały okres poza sezonem wegetacyjnym (Tabela 2). W przypadku obrazów z ICEYE zobrazenia wykonano w trybie Spot Extended Area (SLEA) dla Londynu i StripMap (SM) dla Warszawy, zobrazenia z Sentinel-1 wykonano w trybie Interferometric Wide (IW). Tryby pozyskiwania danych skutkują różną rozdzielczością przestrzenną produktów obrazowych SAR, co ma swoje odzwierciedlenie w wizualizacji i wynikach porównawczych, szczególnie dla obszarów z zabudową.

**Tabela 2.** Specyfikacja wykorzystanych produktów SAR

	<b>Londyn</b>		<b>Warszawa</b>	
System i tryb zobrazenia	ICEYE SLEA	Sentinel-1 IW	ICEYE SM	Sentinel-1 IW
Kanał (częstotliwość GHz)	X (9,6)	C (5,4)	X (9,6)	C (5,4)
Format zapisu danych	GRD	GRD	GRD	GRD
Polaryzacja	VV	VV, VH	VV	VV, VH
Kierunek	Right	Right	Right	Right
Rozdzielczość (m)	0,5 x 0,5	10 x 10	2,5 x 2,5	10 x 10
Data pozyskania	2021-12-20	2021-12-18	2019-09-18	2019-09-19
Obszar (km <sup>2</sup> )	253	253	267	267


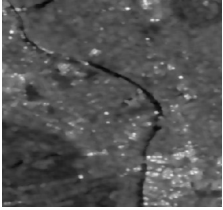
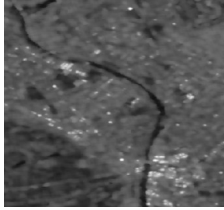
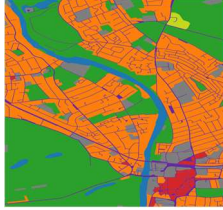

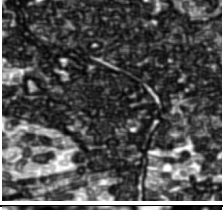
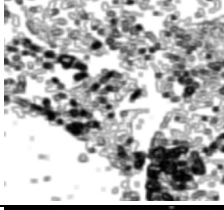

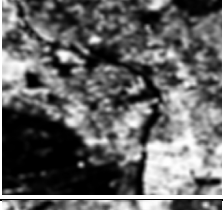
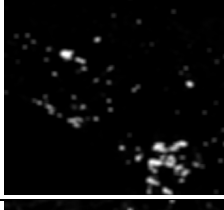
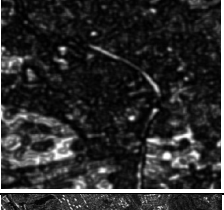
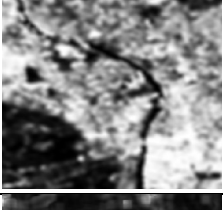
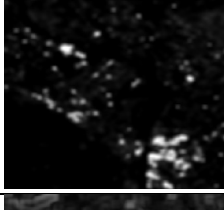
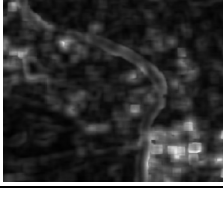
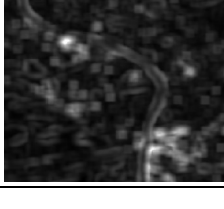
Metodyka badań obejmowała przetwarzanie danych SAR, przygotowanie i agregację klas z Urban Atlas oraz analizę porównawczą. Schematycznie przedstawiono ją na rysunku 2. Etap wstępnego przetwarzania danych SAR obejmował kolejno: kalibrację radiometryczną, korekcję topograficzną, filtrację likwidującą szumy (filtr Lee Sigma, okno 7 x 7) oraz obliczenie intensywności odbicia (rys. 2). Drugi etap to wygenerowanie obrazów teksturowych podejściem macierzy współwystępowania poziomów szarości (ang. GLCM – Grey Level Co-occurrence Matrix) z użyciem okna 9 x 9. Były to korelacja, energia, jednorodność, kontrast i wariancja oraz dywergencja. Na rysunku 2 przedstawiono wybrane obrazy teksturowe prezentujące największe zróżnicowanie.



**Rys. 2.** Schemat metodyki badań. W kolorze szarym oznaczono etap wstępnego przetwarzania danych SAR. W kolorze niebieskim oznaczono obrazy teksturowe objęte analizą. W kolorze pomarańczowym oznaczono klasy z bazy danych Urban Atlas.

## Wyniki

Obraz intensywności (Intensity) reprezentuje wartość wstecznego rozproszenia ( $\sigma^0$ ). W paśmie X, w porównaniu z pasmem C, widoczne są dodatkowe szczegóły jak np. krawędzie reprezentujące drogi i bloki budynków (Rys. 2). W przypadku intensywności w paśmie C klasa woda jest lepiej rozróżniana niż inne klasy, charakteryzując się małą wartością  $\sigma^0$  zarówno w polaryzacji VV, jak i VH. Klasy zabudowy dla obu polaryzacji nie różnią się znacznie między sobą. Niektóre obszary z budynkami są jaśniejsze w polaryzacji VV, ze względu na ich zwartość i orientację względem sensora (Rys. 3).

	ICEYE [X] VV	Sentinel-1 [C] VV	Sentinel-1 [C] VH	Urban Atlas legenda
Intensywność (Intensity)				
Jednorodność (Homogeneity)				<ul style="list-style-type: none"> <li><span style="color: red;">■</span> 1. High-Dense</li> <li><span style="color: orange;">■</span> 2. Medium-Dense</li> <li><span style="color: yellow;">■</span> 3. Low-Dense</li> <li><span style="color: purple;">■</span> 4. Roads</li> <li><span style="color: grey;">■</span> 5. Industry</li> <li><span style="color: green;">■</span> 6. Vegetation</li> <li><span style="color: blue;">■</span> 7. Water</li> </ul>
Wariancja (Variance)				
Energia (Energy)				
Dywergencja (Divergence)				

**Rys. 3.** Obrazy intensywności, teksturowe oraz analiza rozproszenia wygenerowane z danych SAR dla Iceye (X-band) i Sentinel-1 (C-band), przykładowy fragment Londynu. W prawej górnej części tabeli Urban Atlas z agregowanymi klasami i legendą.


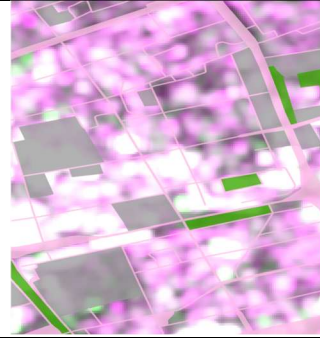


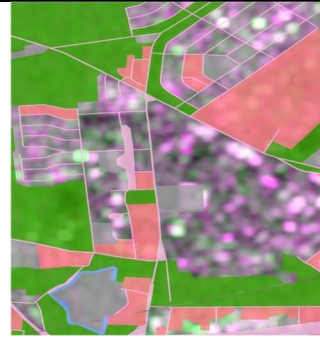

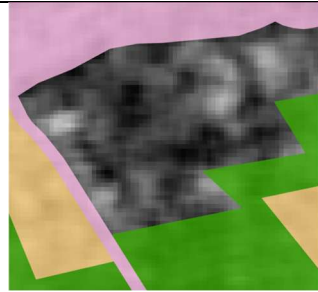
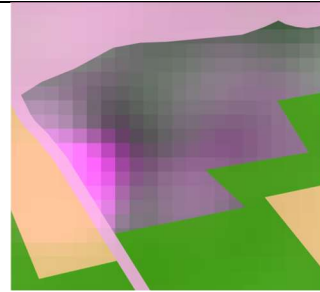

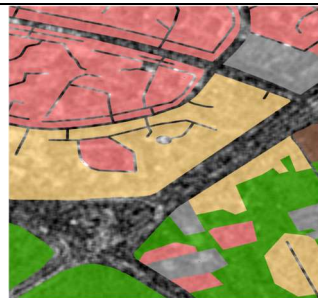
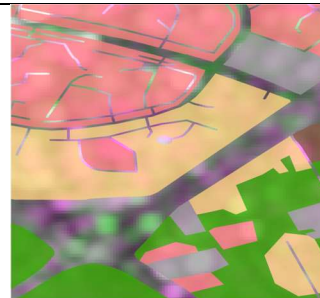

W obrazach teksturowych uwidacznia się jeszcze bardziej układ przestrzenny obiektów i ich heterogeniczność. Obszary z budynkami o regularnym układzie i kształcie oraz linie komunikacyjne wykazują dużo wyższe wartości w obrazach wariancji i energii, a dużo niższe w obrazie jednorodności, co potwierdzają także inne badania (Zhai et al. 2016). Dużą jednorodność mają natomiast takie klasy jak woda i roślinność ze względu na


podobieństwo sąsiadujących ze sobą pikseli. Widoczne są też różnice w wartościach klas na obrazach teksturowych dla dwóch różnych polaryzacji VV i VH Sentinel-1 (pasmo C). Z kolei obraz energii w VV przyjmuje wysokie wartości dla klasy woda, podczas gdy inne klasy przyjmują niskie wartości. Cechy dużej dywergencji prezentują obszary z zabudową gęstą i zwartą. Kontrastuje to z obszarami naturalnymi, takimi jak pola uprawne, woda lub las, które często wykazują jednorodność i słabą dywergencję. Podobne wnioski znalazły się w badaniach nad wyznaczeniem obszarów osadniczych (Thiel, Esch i Schenk 2008). Histogramy wskazują na słabą separatywność między klasami o średniej i niskiej gęstości zabudowy oraz roślinnością – lepszą natomiast dla klasy woda.

Analiza obrazów SAR dla wybranych klas zabudowy wskazuje na ich istotne zróżnicowanie w zakresie intensywności rozproszenia i cech teksturowych, co ma znaczenie dla automatycznego rozpoznania klas. Obserwacje różnic pomiędzy pasmem X a C potwierdzają większą szczegółowość przestrzenną i wrażliwość pasma X na elementy infrastruktury, w tym krawędzie budynków i układ liniowy zabudowy. W paśmie C, mimo mniejszej rozdzielczości, klasy o odmiennej strukturze przestrzennej – jak woda czy roślinność – są dobrze rozróżnialne zarówno w zakresie intensywności, jak i tekstury.

Wyniki wskazują, że najistotniejsze cechy różnicujące klasy zabudowy to tekstura (szczególnie wariancja, kontrast i energia) oraz kombinacje polaryzacyjne (VV i VH) – co może być wykorzystane przy konstrukcji cech wejściowych do algorytmów uczenia maszynowego. Klasy o wysokiej gęstości zabudowy (jak np. w UA klasa 11100) charakteryzują się wyższymi wartościami  $\sigma_0$  i wyraźną strukturą w obrazach GLCM, co pozwala je odróżnić od klas z roślinnością i klas niskiej gęstości. Z kolei klasy o bardzo rozproszonej zabudowie (np. klasy 11240 i 11300) wykazują większe podobieństwo do powierzchni naturalnych, co może skutkować większą liczbą błędnych klasyfikacji bez danych wspomagających.

Zidentyfikowane zróżnicowanie przestrzenne klas Urban Atlas w obu aglomeracjach (Warszawa, Londyn) ma wpływ na skuteczność rozpoznania – m.in. ze względu na różnice w udziale klas oraz strukturze urbanistycznej. Obszary w Londynie wykazują większe zróżnicowanie w obrębie klas średniej i małej gęstości, co może prowadzić do większych trudności klasyfikacyjnych bez zastosowania bardziej złożonych wskaźników teksturowych. Wyniki te korespondują z wcześniejszymi badaniami nad rozróżnianiem klas (Thiel et al. 2008; Pluto-Kossakowska i Giczán 2023), wskazując na kluczową rolę geometrii oraz układu przestrzennego obiektów w obrazie SAR. Rys. 4 prezentuje fragment miasta o zróżnicowanej gęstości zabudowy na obrazach intensywności oraz obrazach teksturowych wygenerowanych dla poszczególnych polaryzacji danych w pasmach X i C.

Klasa	ICEYE [VV]	Sentinel-1 RGB [VV, VH, VV]	Bing Maps (ESRI)
1			
2			
3			
4			



**Rys. 4.** Przykłady klas (od 1 do 7) na zobrazowaniu Iceye (VV) oraz kompozycji RGB Sentinel-1 (VV, VH, VV). W ostatniej kolumnie wizualizacja z ortofotomapy. Obszary zdefiniowane jako pozostałe klasy wymaskowano kolorami. Numery klas zgodnie z opisem na Rys. 2.

## Dyskusja

Opracowanie wzorców na podstawie przetworzonych danych SAR jest niezbędnym etapem w klasyfikacji nadzorowanej, szczególnie z wykorzystaniem metod uczenia głębokiego. Zestaw danych treningowych uwzględniający intensywność oraz teksturę daje możliwość dalszego rozróżnienia klas pod kątem gęstości zabudowy. Jest to szczególnie widoczne na danych w paśmie X. Ograniczona rozdzielczość danych Sentinel 1 powoduje słabszą zdolność do identyfikowania drobnych detali miejskich, takich jak wąskie drogi lub małe budynki. Skutkiem tego trudno jest odróżnić zbliżone klasy, co również potwierdzono w innych badaniach (Zhao et al. 2020).

Otwartych zbiorów treningowych nie ma obecnie dostępnych zbyt wiele i mają dodatkowe ograniczenia. Z istniejących opracowań należy wymienić: “OpenSARUrban Dataset” (Zhao et al. 2020). Jest to zbiór 30 tysięcy danych treningowych pozyskanych z SAR z lat 2016-2017 dla dwóch różnych polaryzacji z 21 miast Chin. Jest to baza treningowa do klasyfikacji obszarów miejskich o specyficznej bardzo gęstej i wysokiej zabudowie (w sumie 10 różnych klas), która umożliwia transfer wiedzy między sensorami i regionami na obszarze Chin. Ograniczeniem jest tu brak różnorodności geograficznej i brak wzorców z obszarów o innym układzie urbanistycznym oraz nierównowaga klas. Kategorie takie jak lotniska, autostrady i kolej są słabo reprezentowane w porównaniu do innych kategorii. Kolejną słabą stroną tego zestawu danych jest automatyczna adnotacja

(etykiety) wykonana na zobrazeniach optycznych, co może prowadzić do błędów przy reprojekcji i pojawienia się artefaktów. Dlatego bardzo ważnym elementem jest wykonanie etykiet na podstawie zweryfikowanych baz danych przestrzennych jak np. Urban Atlas wykorzystana w niniejszym badaniu. Niemniej jednak sama baza danych Urban Atlas wykazuje ograniczenia wynikające m.in. z jej kontynentalnego zakresu opracowania. Zastosowanie jednolitej legendy klasyfikacyjnej dla obszaru całej Europy wymusza uproszczenia oraz ujednoczenie definicji klas, co może obniżać poziom szczegółowości oraz precyzję ich interpretacji w skalach lokalnych. W niniejszym badaniu zaobserwowano zróżnicowanie sposobu realizacji Urban Atlas pomiędzy poszczególnymi państwami. Przykład Warszawy i Londynu wskazuje na istotne różnice w interpretacji przyjętych definicji klas, wynikające prawdopodobnie z odmiennych uwarunkowań lokalnych. Ograniczeniem w wykorzystaniu tej bazy jest również niska częstotliwość aktualizacji co 6 lat i opóźnienia w publikacji danych. Także heterogeniczność tematyczna i ograniczone pokrycie obszarów miejskich z niższą rozdzielczością geometryczną.

Jak istotnym elementem automatycznego rozpoznania klas jest opracowanie rzetelnego i wiarygodnego zbioru uczącego wskazuje otwarta polemika w openreview.net nad projektem Sar2EO <https://sar2earth.github.io>. Jest to zestaw danych treningowych zbudowany z około 100000 par danych SAR i optycznych, który umożliwia translację danych SAR do optycznych, i pozwala zastosować klasyfikatory stworzone dla danych optycznych również na SAR. Publikacja pozostaje otwarta w serwisie „International Conference on Learning Representations, 2024”, ale została odrzucona jako niewiarygodna i wymagająca dalszego dopracowania metodycznego.

Inne istniejące bazy danych o globalnym zasięgu m.in. ESA WorldCover (<https://esa-worldcover.org/en>) czy Dynamic World (Brown, 2022) również napotykają problemy z rozszerzoną identyfikacją klas zabudowy przy zastosowaniu metod uczenia maszynowego. W żadnej z tych baz nie ma rozróżnienia na typy zabudowy, brak informacji o gęstości zabudowy oraz wyróżnienia infrastruktury transportowej. Ich atutem jest za to częstość aktualizacji (Dynamic World co 2-5 dni, ESA WorldCover 1/rok), pełne pokrycie globalne i dostępny kod źródłowy (<https://dynamicworld.app/>). W opracowaniu ESA WorldCover są wykorzystywane zobrazenia optyczne i SAR, ale zmienność metodyczna ogranicza porównania zmian w czasie. Ciekawym kolejnym wątkiem badawczym byłaby integracja tych baz. Z jednej strony dająca wysoką szczegółowość z Urban Atlas, monitorowanie dynamicznych zmian z Dynamic World i spójność metodyczną z ESA WorldCover.

Wnioski wynikające z przeprowadzonych analiz wskazują, że cechy GLCM poprawiają rozpoznawalność różnych klas zabudowy na zobrazeniach SAR. Potwierdzają to badania (Amarsaikhan 2020), w których uzyskano lepszą dokładność w klasyfikacji

nadzorowanej, dowodząc, że cechy teksturowe SAR wzbogacają rozpoznanie klas miejskich. Kolejne rekomendacje do dalszych badań to uzupełnienie danych o istniejące otwarte zbiory uczące oraz połączenie SAR z danymi optycznymi do opisu cech poszczególnych klas. Taka możliwość istnieje poprzez transfer wiedzy z modeli uczących.

### **Podsumowanie**

W badaniu przeanalizowano możliwość opisu terenów miejskich z podziałem na gęstość zabudowy przy użyciu obrazów SAR. Uwzględniono siedem klas, agregowanych z Urban Atlas, oraz porównano dane ICEYE i Sentinel 1. Badanie potwierdziło przydatność danych SAR w zakresie pasm X i C do opisu klas zabudowy. W szczególności wykazano, że cechy teksturowe obrazów SAR – obliczane na podstawie GLCM – stanowią istotne uzupełnienie klasycznej analizy intensywności rozproszenia. Pozwalają one skuteczniej rozróżniać gęstość zabudowy, zwartość i strukturę przestrzenną obiektów antropogenicznych.

Wykazano, że:

- pasmo X zapewnia większą szczegółowość zabudowy,
- polaryzacje VV i VH różnicują klasy o odmiennym układzie i funkcji,
- cechy teksturalne (kontrast, wariancja, energia) stanowią wartościowe dane wejściowe,
- Urban Atlas jako dane referencyjne do klasyfikacji wymaga weryfikacji i ewentualnie agregacji klas.

Badanie przyczynia się do szerszego włączenia danych SAR w analizie miast o większej szczegółowości przestrzennej. Wyniki wspierają dalsze badania nad uczeniem maszynowym i hybrydowymi algorytmami klasyfikacji, umożliwiając budowę bardziej wiarygodnych produktów w skali miasta, np. w monitorowaniu zmian, rozróżnieniu funkcji (np. mieszkaniowa, przemysłowa, transportowa), analizie uszczelnienia powierzchni, identyfikacji różnych typów tkanki miejskiej, czy w badaniu procesów suburbanizacji.

### **Podziękowania**

Prezentowane wyniki badań prowadzono w ramach projektu Politechniki Warszawskiej „Wykorzystanie satelitarnych zobrazowań SAR do analizy szarej infrastruktury” (grant dyscypliny Inżynierii Lądowej, Geodezji i Transportu PW 2023-2024). Autorzy składają podziękowania dostawcom tj. ESA, Iceye, Copernicus za nieodpłatne udostępnienie danych.

## Literatura (References)

- Amarsaikhan, D., 2020: Advanced Classification of Optical and SAR Images for Urban Land Cover Mapping. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences XLIII-B3-2020* (August):1417–21, DOI: <https://doi.org/10.5194/isprs-archives-XLIII-B3-2020-1417-2020>.
- Brown, C.F., Brumby, S.P., Guzder-Williams, B., Birch, T., Brooks Hyde, S., Mazzariello, J., Czerwinski, W., Pasquarella, V.J., Haertel, R., Ilyushchenko, S., Schwehr, K., Weisse, M., Stolle, F., Hanson, C., Guinan, O., Moore R., Tait, A.M., 2022: Dynamic World, Near real-time global 10 m land use land cover mapping. *Sci Data* 9, 251, DOI: <https://doi.org/10.1038/s41597-022-01307-4>.
- Dynamic World: <https://dynamicworld.app/> (dostęp: 25.11.2025).
- ESA World Cover: <https://esa-worldcover.org/en> (dostęp: 25.11.2025).
- HRL Copernicus, 2024: High Resolution Layer Imperviousness. <https://land.copernicus.eu/en/products/high-resolution-layer-imperviousness>.
- Lefebvre, A., Sannier, Ch., Corpetti, T., 2016: Monitoring Urban Areas with Sentinel-2A Data: Application to the Update of the Copernicus High Resolution Layer Imperviousness Degree. *Remote Sensing* 8 (7): 606, DOI: <https://doi.org/10.3390/rs8070606>.
- Meyer, F., 2025: The SAR Handbook. Chapter 2. Chrome extension://efaidnbmnnnibpcajpcgclefindmkaj/<https://gis1.servirglobal.net/TrainingMaterials/SAR/Chp2Content.pdf>.
- NASA, 2019: The SAR Handbook. <https://www.earthdata.nasa.gov/learn/earth-observation-data-basics/sar-handbook>. (dostęp: 20.05.2025).
- Pluto-Kossakowska, J., Cuprjak, M., 2023: Indicators Method of Aesthetics Analysis Using Spatial Datasets. *Space&FORM* 2023 (55): 179–204, DOI: <https://doi.org/10.21005/pif.2023.55.C-03>.
- Pluto-Kossakowska, J., Giczan, J., 2023: Analysis of Built-up Classes in Urbanised Zones Using Radar Images. *Quaestiones Geographicae* 42 (3): 195–211, DOI: <https://doi.org/10.14746/quageo-2023-0032>.
- Pluto-Kossakowska, J., Wangiyana, S., 2025: Supervised semantic segmentation of urban area using SAR, *Remote Sensing*, DOI: <https://doi.org/10.3390/rs17091606>.
- Projekt SAR2Earth: A SAR-to-EO Translation Dataset for Remote Sensing Applications. <https://sar2earth.github.io> (dostęp: 30.07.2024).
- Urban Atlas, Guide, 2021: Urban Atlas — Copernicus Land Monitoring Service. 2 March 2021. <https://land.copernicus.eu/en/products/urban-atlas>.
- Zhao, J., Zhang, Z., Yao, W., Datcu, M., Xiong, H., Yu, W., 2020: OpenSARUrban: A Sentinel-1 SAR Image Dataset for Urban Interpretation. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 13:187–203, DOI: <https://doi.org/10.1109/JSTARS.2019.2954850>.

### Streszczenie

Celem niniejszego badania była ocena przydatności satelitarnych danych SAR (Synthetic Aperture Radar) w pasmach X i C do klasyfikacji terenów zabudowanych w oparciu o klasyfikację Urban Atlas. Skoncentrowano się na możliwości rozróżnienia klas o różnej gęstości zabudowy oraz funkcji terenu z wykorzystaniem zarówno intensywności wstecznego rozproszenia, jak i cech teksturowych generowanych metodą GLCM. Do analiz wykorzystano zobrażenia satelitarne Sentinel-1 i ICEYE dla dwóch aglomeracji miejskich: Warszawy i Londynu, a referencyjną warstwę tematyczną była baza Urban Atlas po tematycznej agregacji do siedmiu klas. Wyniki wskazują, że obrazy SAR pozwalają na identyfikację głównych klas pokrycia terenu, w szczególności gęstej zabudowy miejskiej, roślinności i wody. Wysoka rozdzielczość obrazów w paśmie X umożliwia lepsze odwzorowanie struktury urbanistycznej, natomiast obrazy teksturowe zwiększają zdolność różnicowania klas o zbliżonej intensywności odbicia. Wykazano także, że polaryzacje VV i VH różnicują klasy o odmiennym układzie (gęstości) i funkcji urbanistycznej. Badanie potwierdza potencjał wykorzystania danych SAR jako źródła wspomagającego aktualizację baz danych referencyjnych oraz do automatycznej klasyfikacji obszarów zurbanizowanych.

Dane autorów / Authors details:

Dr inż. Joanna Pluto-Kossakowska

ORCID 0000-0002-6533-1332

joanna.kossakowska@pw.edu.pl

Sandhi Wangiyana

sandhi.wangiyana.dokt@pw.edu.pl

Przesłano / Received

05.10.2024

Zaakceptowano / Accepted

28.11.2025

Opublikowano / Published

10.12.2025



© Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0/>).