

ANDRZEJ TUCKI

<https://orcid.org/0000-0002-6062-0004>

Uniwersytet Marii Curie-Skłodowskiej w Lublinie

Wydział Nauk o Ziemi i Gospodarki Przestrzennej

al. Kraśnicka 2D, 20-718 Lublin, Polska

[andrzej.tucki@mail.umcs.pl](mailto:andrzej.tucki@mail.umcs.pl)

JACEK OSOJCA

<https://orcid.org/0009-0009-2706-8738>

Politechnika Świętokrzyska

Wydział Zarządzania i Modelowania Komputerowego

al. Tysiąclecia Państwa Polskiego 7, 25-314 Kielce, Polska

DARIUSZ DOBROWOLSKI

<https://orcid.org/0000-0003-3676-9957>

Politechnika Świętokrzyska

Wydział Zarządzania i Modelowania Komputerowego

al. Tysiąclecia Państwa Polskiego 7, 25-314 Kielce, Polska

[d.dobrowolski@tu.kielce.pl](mailto:d.dobrowolski@tu.kielce.pl)

## Analiza ruchu turystycznego w mieście na podstawie danych portalu Flickr. Studium przypadku miasta Kielce

---

Analysis of Tourist Behavior in the City Based on Flickr Data: Kielce Case Study

**Abstract:** Although nowadays tourists generate huge amounts of data online, so-called Big Data, little is known about their behavior in urban spaces. However, these sources of data are increasingly being used with modern technology to track the presence of tourists in urban areas that are attractive to tourists. The article aims to analyze urban tourist behavior using data from the social networking site Flickr. Machine learning methods were used to illustrate the temporal and spatial activities of the portal's users. It was assumed that these activities could serve as an indicator of the volume of tourist traffic and interest in the urban space. The results of the analysis showed that in most cases the activity of the portal users in the form of the number of georeferenced photos was in line with the actual number of visitors to the most important tourist attractions in Kielce. The study can be seen

as a contribution to a new stream of research in the field of digital geography. The limitations of the applied research methodology are also included in the conclusions.

**Keywords:** urban tourist; machine learning; Flickr; tourist traffic; urban space; Kielce

**Abstrakt:** Wiedza na temat zachowań turystów w przestrzeni miejskiej jest niewielka, mimo że turyści generują ogromne ilości danych w sieci, tzw. Big Data. Te źródła danych wykorzystywane są jednak coraz częściej przy użyciu nowoczesnych technologii do śledzenia obecności turystów w atrakcyjnych turystycznie obszarach miejskich. Celem artykułu jest rozpoznanie zachowań turystów miejskich przy wykorzystaniu danych zawartych w serwisie społecznościowym Flickr. Dla zobrazowania aktywności czasowo-przestrzennej użytkowników portalu – przy założeniu, że mogą one stanowić wskaźnik wielkości ruchu turystycznego i zainteresowania przestrzenią miasta – zastosowano metody uczenia maszynowego. Wyniki analiz pokazały, że w większości przypadków aktywność użytkowników portalu w postaci liczby geolokalizowanych zdjęć pokrywała się z rzeczywistą liczbą odwiedzających najważniejsze atrakcje turystyczne Kielc. Opracowanie może stanowić przyczynek do nowego nurtu badań w geografii cyfrowej. W podsumowaniu zawarto także ograniczenia przyjętej metodyki badań.

**Słowa kluczowe:** turysta miejski; uczenie maszynowe; Flickr; ruch turystyczny; przestrzeń miasta; Kielce

## WSTĘP

Analiza i zrozumienie właściwości ruchu turystycznego są podstawą opracowania odpowiedniego planu zarządzania dla regionów i miejscowości turystycznych. Ruch turystyczny odnosi się do przestrzennego wykorzystania środowiska geograficznego przez turystów i odzwierciedla ich wzorce podróży w określonym regionie, umożliwiając praktyczne implikacje w zakresie alokacji atrakcji i infrastruktury turystycznej czy skutecznego planowania turystyki w obszarze recepcji turystycznej (Domènech i in., 2020; Zhong i in., 2019).

Jak pokazuje literatura przedmiotu, miasta zawsze były celem podróży, ale dopiero od drugiej połowy XX w. odwiedzanie ich stało się zjawiskiem masowym. Obok tradycyjnych form turystyki w miastach: wypoczynkowej, poznawczej i religijnej, współcześnie obserwuje się dynamiczny rozwój nowych form, takich jak np. handlowa, gastronomiczna, rozrywkowa, kongresowa czy sportowa. Odnosi się to szczególnie do dużych miast i aglomeracji miejskich (zob. m.in. Ashworth i Page, 2011; Kowalczyk, 2001; Page, 1995).

Najważniejszą grupą uwarunkowań geograficznych rozwoju zjawiska turystyki, w tym w przestrzeni miejskiej, jest atrakcyjność turystyczna (Kurek, 2012; Warszzyńska i Jackowski, 1978). Może być ona definiowana jako siła, z jaką dane miejsce, obiekt lub zjawisko przyciąga odwiedzających, obejmując elementy stanowiące podstawę do wzrostu aktywności turystycznej i zaspokajania potrzeb turystów (Ko-

walczyk, 2001). Inne ujęcie określa ją jako stopień nasycenia wydzielonych układów przestrzennych takimi czynnikami jak: wachlarz i jakość walorów turystycznych, będących pierwotną siłą warunkującą powstanie i rozwój turystyki na danym obszarze; stopień zagospodarowania turystycznego czy dostępność komunikacyjna regionu; zapewnienie turyście odpowiedniej mobilności w regionie (Gardzińska i in., 2010).

W świetle literatury przedmiotu (Gołębski, 2011; Jażdżewska, 2008; Liszewski, 1999; Matczak, 1989) wykorzystanie turystyczne miast można scharakteryzować za pomocą wielu zmiennych, w tym liczbą wizyt, sposobem korzystania z udogodnień czy długością pobytu. Jednak uzyskanie aktualnych informacji o tym, w jaki sposób turyści wykorzystują przestrzeń miasta, jest często pracochłonne i kosztowne przy użyciu tradycyjnych metod, takich jak badania ankietowe, wywiady. W rezultacie do analiz geograficznych, w tym badań ruchu turystycznego, zaczęto coraz częściej wykorzystywać dane tzw. społecznościowej informacji geograficznej (*volunteered geographic information*; zob. Beiqi i in., 2016; Elwood i in., 2012; Goodchild, 2007; Rahmadian i in., 2021). Jest to efekt większej liczby osób korzystających z oprogramowania umożliwiającego rejestrację ich pozycji w terenie oraz dzielących się tą informacją w internecie.

Dane społecznościowej informacji geograficznej (dotyczy to głównie użytkowników portali społecznościowych, takich jak Facebook, Instagram, Twitter czy Flickr) udostępniane są w postaci cyfrowych zdjęć oraz wiadomości z zarejestrowaną informacją o czasie i miejscu ich wykonania. Jak pokazuje literatura przedmiotu, dane te są coraz częściej wykorzystywane w celu badania wzorców zachowań turystycznych na terenach rekreacyjnych i obszarach chronionych (zob. m.in. Sinclair i in., 2018; Wilkins i in., 2020; Wood i in., 2013). Zapisy geolokalizowanych zdjęć można wykorzystać nie tylko do identyfikacji miejsc do zwiedzania, lecz także do analizy przestrzennych i czasowych wzorców przepływu turystów w miastach (Domènech i in., 2020; Girardin i in., 2009).

Niniejsze badania wpisują się w nurt studiów geografii cyfrowej (zob. m.in. Ash i in., 2018), sygnalizując nowe podejście do analiz czasowo-przestrzennych turystów i tym samym stwarzając możliwość wyjścia naprzeciw potrzebom związanym z gromadzeniem danych dla instytucji odpowiedzialnych za planowanie i zarządzanie rozwojem turystyki.

Celem głównym opracowania jest rozpoznanie wykorzystania najważniejszych atrakcji turystycznych Kielc przy użyciu geolokalizowanych zdjęć z serwisu Flickr. Za cele szczegółowe przyjęto: (1) zbadanie możliwości wykorzystania danych z mediów społecznościowych jako wskaźnika wielkości ruchu turystycznego, (2) modelowanie przestrzennych i czasowych wzorców wykorzystania przestrzeni turystycznej miasta oraz (3) zbadanie wpływu atrakcyjności turystycznej miasta na przestrzenne i czasowe rozkłady ruchu turystycznego.

## OBSZAR BADAŃ

Za podstawę przeprowadzonych badań wybrano obszar miasta Kielce w granicach administracyjnych. Według podziału administracyjnego stanowi ono stolicę województwa świętokrzyskiego. Pod względem fizyczno-geograficznym miasto jest położone na zachodnim krańcu Doliny Kielecko-Łagowskiej w zachodniej części mezoregionu Gór Świętokrzyskich, nad rzeką Silnicą – prawobrzeżnym dopływem rzeki Bobrzy (Strzyż, 2018). Według Banku Danych Lokalnych Głównego Urzędu Statystycznego (BDL GUS) obszar miasta zajmuje powierzchnię 109,45 km<sup>2</sup>, którą w 2022 r. zamieszkiwało 183,9 tys. osób.

Wśród walorów przyrodniczych na terenie miasta wyróżniają się pasma górskie Kadzielniańskie oraz Dymińskie oraz sześć rezerwatów przyrody: Kadzielnia, Biesak, Białogon, Karczówka, Ślichowice im. Jana Czarnockiego oraz Wietrznia im. Zbigniewa Rubinowskiego (Strzyż, 2018). Unikatowe wartości przyrodnicze, w tym wyjątkowe dziedzictwo geologiczne, sprawiły, że już w 1996 r. część miasta została objęta ochroną jako Chęcińsko-Kielecki Park Krajobrazowy. Dało to podstawę do utworzenia w 2015 r. pierwszego w kraju geoparku – Geoparku Świętokrzyskiego. Warto podkreślić fakt, że międzynarodowa ranga tego dziedzictwa została oficjalnie zatwierdzona przez UNESCO w trakcie procedury aplikacyjnej Geoparku do Światowej Sieci Geoparków (Global Geoparks Network) i ostatecznie przypieczętowana w 2021 r. poprzez nadanie obszarowi statusu Światowego Geoparku UNESCO (<https://geopark.pl>).

Potencjał turystyczny miasta uzupełniają walory historyczno-kulturowe i przestrzeń zabytkowa. Zgodnie z rejestrem Narodowego Instytutu Dziedzictwa (Otwarte Dane, 2023) liczba obiektów zabytkowych wynosi ponad 100 (92, grupując obiekty w zespoły). Zdecydowana ich większość znajduje się w centralnej części miasta, gdzie zlokalizowane są najstarsze zabudowania, układy urbanistyczne, kościoły i pałace.

## METODY BADAŃ

Dane wykorzystane w badaniu zostały pobrane z serwisu internetowego Flickr, dającego możliwość uzyskania geolokalizowanych zdjęć za pośrednictwem udostępnionego interfejsu API (<https://www.flickr.com/services/api>). Wykorzystane dane obejmują okres 21 lat (od stycznia 2002 r. do grudnia 2022 r.). Metoda flickr.photos.search została użyta do zebrania i przechowywania zestawu 2295 zdjęć wykonanych przez 122 użytkowników w granicach administracyjnych miasta. Dane zostały przefiltrowane według określonych kryteriów, takich jak data wykonania, dostępność publiczna oraz obecność współrzędnych geograficznych.

Każde geolokalizowane zdjęcie ma następujące atrybuty:

- ID (unikalny identyfikator przesłanego zdjęcia);
- *owner* (unikalny identyfikator użytkownika, który przesłał zdjęcie);
- *longitude* (długość geograficzna);
- *latitude* (szerokość geograficzna);
- *URL\_n* (link zdjęcia).

Na podstawie tych atrybutów zdjęcia zostały poddane procesowi oczyszczania, a następnie zostały przetworzone przez napisany w Pythonie algorytm uczenia nienadzorowanego DBSCAN. Python jest językiem programowania wysokiego poziomu, kładącym nacisk na czytelność kodu przy użyciu wcięć (Gągolewski i in., 2016). Język ten oparty jest na wielu paradygmatach programowania, takich jak programowanie strukturalne, obiektowe i funkcjonalne. Jest jednym z tych języków programowania, które oferują liczne i różne biblioteki, co czyni go otwartym na wszystkie możliwości pracy nad zagadnieniami związanymi ze sztuczną inteligencją.

Do najpopularniejszych bibliotek dla analizy i zastosowań sztucznej inteligencji zalicza się (Rogacewicz, 2018):

- **TensorFlow** (Han i in. 2018) – zaawansowana biblioteka, wykorzystywana głównie do tworzenia modeli głębokiego maszynowego uczenia się. Możliwości, jakie oferuje, uwzględniają rozpoznawanie obrazów oraz przetwarzanie języka naturalnego;
- **Pytorch** (Rath, 2022) – pozwala na tworzenie i szkolenie modeli samo-uczenia maszyn, w tym na wykonywanie zadań optymalizacyjnych i prognozowanie;
- **Pandas** (Palaniappan, 2023) – zadaniem jest przetworzenie i analiza danych, zanim zostaną wykorzystane do trenowania maszyn. Dodatkową zaletą jest zdolność do łączenia zbiorów danych, obsługa brakujących informacji oraz wykorzystanie funkcji klasyfikacji indeksowanych danych;
- **SciKit-Learn** (Rodrigo i Ortiz, 2021) – biblioteka o otwartym kodzie źródłowym, która została stworzona na podstawie SciPy i jest wykorzystywana do konkretnych zastosowań, jak m.in. przetwarzanie obrazu, klasyfikacje i klastrowanie.

Obok wspomnianych wyżej bibliotek do analiz grupowania gęstościowego najczęściej wykorzystywany jest algorytm DBSCAN (*Density Noise-Based Spatial Clustering of Applications with Noise*), który powstał w 1996 r. i w dalszym ciągu jest rozwijany i wykorzystywany w badaniach naukowych o tematyce grupowania gęstościowego (Panourgias, 2023). Grupowanie gęstościowe polega na budowaniu segmentów na podstawie informacji o zagęszczeniu obserwacji w przestrzeni. Poprzez zagęszczenie należy rozumieć odległości dzielące poszczególne obserwacje

w danym obszarze. Grupowanie gęstościowe najlepiej sprawdza się przy identyfikacji segmentów o nieregularnych (niewypukłych) kształtach; wymaga przy tym zdefiniowania minimalnej liczby obserwacji potrzebnych do zbudowania grupy i nie wszystkie obserwacje muszą zostać przypisane do grup. Obserwacje niespełniające zakładanych kryteriów są uznawane za obserwacje odstające.

Przedstawicielem algorytmów do grupowania gęstościowego jest algorytm DBSCAN posiadający dwa główne parametry wejściowe, od ustawienia których zależy powodzenie procesu grupowania (Grzyb, 2019):

- epsilon (w środowisku  $R$ -owym oznaczany jako *Eps*) – promień sąsiedztwa, czyli minimalna odległość dzieląca dwie obserwacje, konieczna do tego, by zostały one uznane za sąsiadów;
- min\_samples (nazywany również *MinPts*) – minimalna liczba obserwacji, potrzebna do tego, by wybrana obserwacja została uznana za punkt centralny danej grupy (punkt centralny również jest liczony).

Niezwykle ważną funkcjonalnością algorytmu DBSCAN jest wykrywanie grup o złożonych kształtach, lokalizowanie punktów otoczonych przez inne klastry, ale też detekcje szumu, do których należą punkty znajdujące się w obszarze o niskiej gęstości, bez konieczności podawania liczby grup, jakie mają zostać znalezione (Panourgias, 2023).

## ANALIZA WYKORZYSTANIA ATRAKCJI TURYSTYCZNYCH KIELC PRZY ZASTOSOWANIU TECHNIK UCZENIA NIENADZOROWANEGO


Pierwszym krokiem wymaganym w procesie analizy jest dostęp do odpowiedniej bazy, w której znajdują się szczegółowe informacje o zawartych w niej zdjęciach, m.in. dacie i miejscu wykonania, współrzędnych geograficznych i prawach własnościowych. Zdjęcia, które spełniają powyższe kryteria filtrowania, znajdują się na platformie Flickr, udostępniającej możliwość wykonywania zapytań do interfejsu programowania aplikacji (API) wraz z wykorzystaniem metod pozwalających na pobranie zdjęć według wspomnianych kryteriów.

Niezbędnych analiz do badań dokonano w języku Python, w środowisku programistycznym JupyterLab, przy wykorzystaniu bibliotek analitycznych (m.in. matplotlib, sklearn, seaborn). W pierwszym kroku, przy zastosowaniu wymienionych bibliotek, stworzono obiekt, na podstawie którego zostało wykonane zapytanie pobierające wszystkie zdjęcia według założonych w nim kryteriów (ryc. 1).



Ryc. 1. Lokalizacja fotografii wykonanych w latach 2002–2022 na terenie Kielce (opracowanie własne)  
*Fig. 1. Location of photographs taken between 2002 and 2022 in Kielce (Authors' own elaboration)*

Tak otrzymane dane stanowią podstawę działania algorytmu DBSCAN, z dobranymi w sposób intuicyjny hiperparametrami  $\epsilon = 0,007$  oraz minimalną liczbą punktów równą 6. Taka kombinacja parametrów daje najlepsze rezultaty w kontekście wykrycia jak największej liczby szczegółowych klastrów (ryc. 2). Celem graficznej prezentacji danych jest odseparowanie wszelkich sygnałów od szumu występującego w tych danych oraz wykorzystanie możliwości wizualnych do skutecznego przekazywania znalezionych sygnałów. Według definicji szumem nazywamy cokolwiek, co zakłóca, przyciemnia relację między cechami obiektu a jego klasą; innymi słowy, jest to niesystematyczny błąd (Hickey, 1996). Zbyt duża wartość  $\epsilon$  zmniejsza liczbę wykrycia klastrów, a zbyt mała powoduje duplikacje wygenerowanych klastrów, natomiast ustawienie zbyt małej wartości punktów zwiększa możliwość wykrycia duplikatów, gdzie duża ich wartość ogranicza wykrycie.



Ryc. 2. Wykryte klastry z pozostałymi zdjęciami – metoda DBSCAN (opracowanie własne)


*Fig. 2. Detected clusters with other images – DBSCAN method (Authors' own elaboration)*

W kolejnym kroku nastąpiło wygenerowanie wszystkich wykrytych punktów centralnych przez algorytm. Wartości nieujemne całkowite są traktowane jako klastry, natomiast ujemne jako punkty odstające. W ten sposób zlokalizowanych zostało 49 klastrów.

Na ryc. 3 przedstawiono wykres punktowy z wyłączeniem wartości odstających. Same klastry różnią się od siebie pod względem wielkości i położenia. Centrum wykresu ukazuje ich największą gęstość.

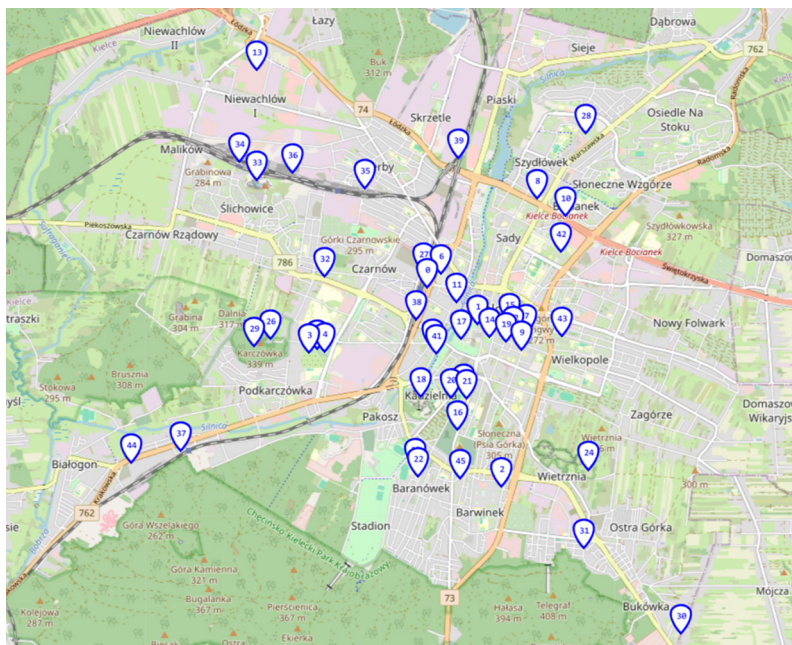
Jednym z końcowych etapów analizy jest wygenerowanie mapy wraz z nałożeniem na nią klastrów. Ma to na celu dokładną wizualizację konkretnych miejsc, w tym przypadku wybranych obszarów Kielc, z nałożonymi klastrami gęstościowo wykrytych zdjęć (ryc. 4).





Ryc. 3. Wykryte klastry – metoda DBSCAN (opracowanie własne)

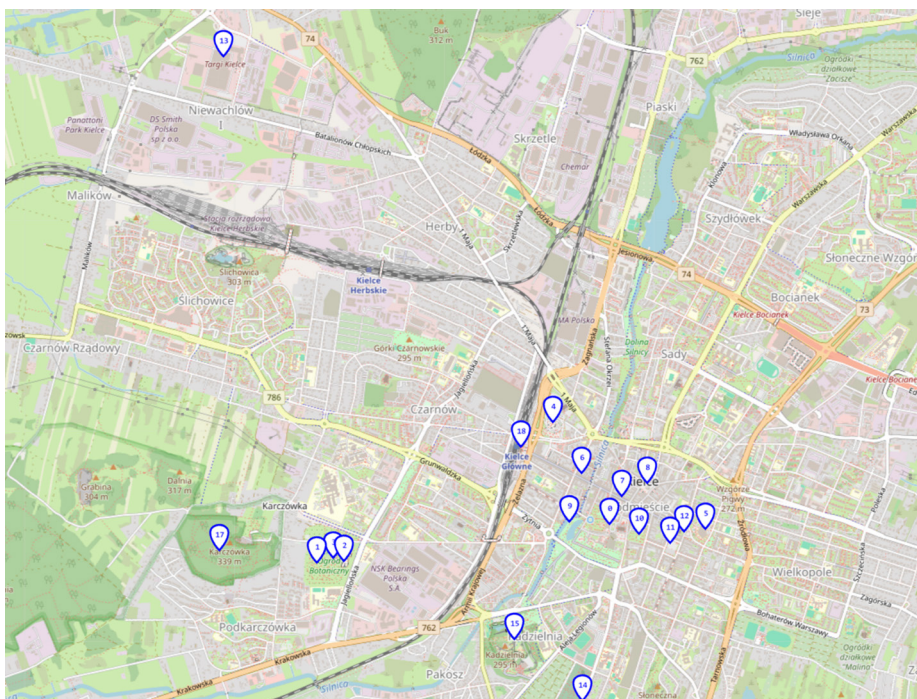
Fig. 3. Detected clusters – DBSCAN method (Authors' own elaboration)



Ryc. 4. Mapa Kielce z nałożonymi klastrami bez filtracji (opracowanie własne)

Fig. 4. Map of Kielce with superimposed clusters without filtering (Authors' own elaboration)

Następnie przeprowadzono proces eliminacji punktów centralnych niebędących atrakcjami turystycznymi. Dodano też warstwę filtrującą do zbioru wszystkich zdjęć, na podstawie której algorytm nie brał pod uwagę zdjęć niekwalifikujących się jako atrakcja turystyczna. Dane zostały ponownie poddane pod działanie algorytmu, w efekcie czego uzyskano końcowe wyniki klastrów.



Ryc. 5. Mapa Kielce z nałożonymi klastrami po filtrowaniu (opracowanie własne)

*Fig. 5. Map of Kielce with superimposed clusters after filtering (Authors' own elaboration)*

Nakładając na mapę etykiety klastrów, wygenerowano obraz najpopularniejszych (16) atrakcji turystycznych w Kielcach (tab. 1, ryc. 5). Wyniki analiz pozwoliły na wygenerowanie mapy ciepła – graficzną prezentację gęstości zdjęć – jako efekt końcowy proponowanej nowej metodyki analiz wielkości i rozmieszczenia ruchu turystycznego (ryc. 6). Im cieplejszy kolor, tym większe zgrupowanie zdjęć, a kolor zbliżający się do niebieskiego obrazuje małą ich gęstość (Awati, 2023).

Tab. 1. Największe atrakcje turystyczne Kielce (opracowanie własne)

Tab. 1. *Top tourist attractions of Kielce (Authors' own elaboration)*


Lp.	Atrakcja turystyczna	Lokalizacja/ Numer klastra	Kategoria atrakcji turystycznej*	Liczba zdjęć	Liczba odwiedzających w latach 2004–2022**
1.	Muzeum Narodowe w Kielcach/Dawny Pałac Biskupów Krakowskich	0	muzeum/zabytek	303	750 503
2.	Ogród Botaniczny	1, 2, 3	ogród	35	190 202
3.	Dworzec autobusowy „UFO”	4	walory krajoznawcze współczesnych osiągnięć	101	b.d.
4.	Kieleckie Centrum Kultury	5	walory krajoznawcze współczesnych osiągnięć	60	b.d.
5.	Ulica Sienkiewicza	6, 7	założenie miejskie	83	b.d.
6.	Rynek	8	założenie miejskie	39	b.d.
7.	Park Miejski im. Stanisława Staszica	9	park miejski	8	b.d.
8.	Pomnik Armii Krajowej	10	zabytek	8	b.d.
9.	Plac Wolności w Kielcach	11	zabytek	53	b.d.
10.	Muzeum Zabawek i Zabawy	12	muzeum	12	688 950
11.	Centrum Kongresowe Targi Kielce	13	infrastruktura turystyczna	529	1 583 521
12.	Cmentarz Stary	1	zabytek	19	b.d.
13.	Rezerwat przyrody Kadzielnia	15	forma ochrony przyrody	7	1 942 381
14.	Centrum Geoedukacji na Wietrzni	16	walory krajoznawcze współczesnych osiągnięć	8	554 367
15.	Galeria Wieża Sztuki	17	walory krajoznawcze współczesnych osiągnięć	11	b.d.
16.	Karczówka	18	forma ochrony przyrody	7	b.d.

\* Podział według Lijewskiego i in. (1985).

\*\* Dane Urzędu Marszałkowskiego Województwa Świętokrzyskiego.

Jak pokazuje ryc. 6, największe natężenie zgrupowania zdjęć (kolor najciemniejszy) wykazano w ścisłym centrum miasta oraz w okolicach Niewachłowa, w którym znajduje się Centrum Kongresowe Targi Kielce. Dodatkowo na mapie wyróżniają się jeszcze dwa obszary: rezerwat geologiczny Kadzielnia (w części południowej) oraz budynek dworca autobusowego „UFO” (w części zachodniej).





Ryc. 6. Ruch turystyczny na terenie Kielce na podstawie zdjęć Flickr – mapa ciepła (opracowanie własne)

*Fig. 6. Tourist traffic in Kielce based on Flickr photos – heat map (Authors' own elaboration)*

Celem weryfikacji poprawności przyjętej metodyki oraz danych posłużono się danymi wielkości ruchu turystycznego analizowanych atrakcji i miejsc na przestrzeni lat. Jak pokazuje zestawienie zamieszczone w tab. 1, największym zainteresowaniem analizowanych elementów przestrzeni turystycznej miasta wśród turystów cieszyły się kolejno rezerwat geologiczny Kadzielnia, Centrum Kongresowe Targi Kielce i Dawny Pałac Biskupów.

## PODSUMOWANIE

Wykorzystanie zdjęć geolokalizowanych wypełnia lukę w źródłach danych ruchu turystycznego, oferując przydatne informacje dla planowania i zarządzania miejscami recepcji turystycznej, a także dla samych turystów. Porównanie klastrów przestrzennych z mapami miasta wykazało, że w większości wyniki te były spójne, a wydzielone poligony pokrywały się z obszarami miasta, o których wiadomo, że przyciągają stosunkowo dużą liczbę odwiedzających. Tym samym potwierdzono wnioski z poprzednich badań miejskich (García-Palomares i in., 2015; Girardin i in.,

2009), które sugerują, że wykorzystywanie danych mediów społecznościowych może stanowić wskaźnik rozmieszczenia turystów w miastach.

Niewątpliwie zastosowanie Big Data w analizach ruchu turystycznego, co pokazuje literatura przedmiotu, stanowi istotny wkład w rozwój badań nad zjawiskami turystycznymi, ale niestety pociąga za sobą pewne ograniczenia, co wykazały wyniki badań niniejszej pracy. Większość danych odnosi się wyłącznie do „modnych” i atrakcyjnych miejsc, przez co nie odzwierciedlają one w pełni atrakcyjności innych, mniej „fotogenicznych” obszarów. Zrealizowane studia sugerują ponadto, że wykorzystanie mediów społecznościowych jako narzędzia do monitorowania odwiedzających jest zależne od stopnia atrakcyjności zarówno całych ośrodków turystycznych i samych atrakcji, jak i ich wielkości. Pewne ograniczenia powoduje również zmienna w czasie ich popularność i dostępność oraz preferencje różnych grup użytkowników (demografia).

Wraz z coraz bardziej powszechnym wykorzystaniem geolokalizowanych danych z mediów społecznościowych w badaniach nad ruchem turystycznym pojawiają się też pytania dotyczące ich etycznego wykorzystania. Dyskusja taka jest kluczowa dla zapewnienia odpowiedniego szacowania i analiz ruchu turystycznego przy jednoczesnym uwzględnianiu prywatności i anonimowości uczestników czy bezpieczeństwa danych oraz zgody i transparentności.

## BIBLIOGRAFIA

- Ash J., Kitchin R., Leszczynski A. (2018). Introducing Digital Geographies. W: J. Ash, R. Kitchin, S. Leszczynski (Eds.), *Digital Geographies* (s. 1–10). London: Sage. DOI: <https://doi.org/10.4135/9781529793536.n1>
- Ashworth G.J., Page S.J. (2011). Urban Tourism Research: Recent Progress and Current Paradoxes. *Tourism Management*, 32(1), 1–15. DOI: <https://doi.org/10.1016/j.tourman.2010.02.002>
- Awati R. (2023). *What Is a Heat Map (Heatmap)?* Online: <https://www.techtarget.com/searchbusinessanalytics/definition/heat-map> (dostęp: 20.11.2023).
- Bank Danych Lokalnych Głównego Urzędu Statystycznego (BDL GUS). Online: <https://bdl.stat.gov.pl/BDL> (dostęp: 20.11.2023).
- Beiqi S., Zhao J., Chen P.-J. (2016). Exploring Urban Tourism Crowding in Shanghai via Crowdsourcing Geospatial Data. *Current Issues in Tourism*, 20(11), 1–24. DOI: <https://doi.org/10.1080/013683500.2016.1224820>
- Domènech A., Mohino I., Moya-Gómez B. (2020). Using Flickr Geotagged Photos to Estimate Visitor Trajectories in World Heritage Cities. *International Journal of Geo-Information*, 9(11). DOI: <https://doi.org/10.3390/ijgi9110646>
- Elwood S., Goodchild M.F., Sui D.Z. (2012). Researching Volunteered Geographic Information: Spatial Data, Geographic Research, and New Social Practice. *Annals of the Association of American Geographers*, 102(3), 571–590. DOI: <https://doi.org/10.1080/00045608.2011.595657>
- García-Palomares J.C., Gutiérrez J., Mínguez C. (2015). Identification of Tourist Hot Spots Based on Social Networks: A Comparative Analysis of European Metropolises Using Photo-Sha-

- ring Services and GIS. *Applied Geography*, 63, 408–417. DOI: <https://doi.org/10.1016/j.apgeog.2015.08.002>
- Gardzińska A., Mańkowski T., Milewski D., Tokarz A. (2010). Region jako obszar badań systemu informacji turystycznej. W: A. Panasiuk (red.), *Informacja turystyczna* (s. 79–108). Warszawa: C.H. Beck.
- Gągolewski M., Bartoszek M., Cena A. (2016). *Przetwarzanie i analiza danych w języku Python*. Warszawa: Wydawnictwo Naukowe PWN.
- Girardin F., Calabrese F., Dal Fiore F., Ratti C., Blat J. (2009). Digital Footprinting: Uncovering Tourists with User-Generated Content. *Pervasive Computing, IEEE Pervasive Computing*, 7(4), 36–43. DOI: <https://doi.org/10.1109/MPRV.2008.71>
- Gołębski G. (red.). (2011). *Sposoby mierzenia i uwarunkowania rozwoju funkcji turystycznej miasta. Przykład Poznania*. Poznań: Wydawnictwo Uniwersytetu Ekonomicznego w Poznaniu.
- Goodchild M.F. (2007). Citizens as Sensors: The World of Volunteered Geography. *GeoJournal*, 69(4), 211–221. DOI: <https://doi.org/10.1007/s10708-007-9111-y>
- Grzyb M. (2019). *Grupowanie gęstościowe. Algorytm DBSCAN – teoria*. Online: <https://mateuszgrzyb.pl/grupowanie-gestosciowe-dbscan-teoria> (dostęp: 20.11.2023).
- Han S., Ren F., Wu C., Chen Y., Du Q., Ye X. (2018). Using the TensorFlow Deep Neural Network to Classify Mainland China Visitor Behaviours in Hong Kong from Check-in Data. *ISPRS International Journal of Geo-Information*, 7(4). DOI: <https://doi.org/10.3390/ijgi7040158>
- Hickey R.J. (1996). Noise Modelling and Evaluating Learning from Examples. *Artificial Intelligence*, 82(1–2), 157–179. DOI: [https://doi.org/10.1016/0004-3702\(94\)00094-8](https://doi.org/10.1016/0004-3702(94)00094-8)
- Jażdżewska I. (red.). (2008). *XXI Konwersatorium Wiedzy o Mieście. Funkcja turystyczna miast*. Łódź: Wydawnictwo Uniwersytetu Łódzkiego.
- Kowalczyk A. (2001). *Geografia turystyki*. Warszawa: Wydawnictwo Naukowe PWN.
- Kurek W. (red.). (2012). *Turystyka*. Warszawa: Wydawnictwo Naukowe PWN.
- Lijewski T., Mikułowski B., Wyrzykowski J. (1985). *Geografia turystyki Polski*. Warszawa: Państwowe Wydawnictwo Ekonomiczne.
- Liszewski S. (1999). Przestrzeń turystyczna miasta (przykład Łodzi). *Turyzm*, 9(1), 51–73. DOI: <https://doi.org/10.18778/0867-5856.9.1.04>
- Matczak A. (1989). Problemy badania funkcji turystycznej miast Polski. *Acta Universitatis Lodziensis. Turyzm*, (5), 25–37. DOI: <https://doi.org/10.18778/0860-1119.5.03>
- Otwarte Dane (2023). *Rejestr zabytków nieruchomości*. Online: <https://dane.gov.pl/pl/dataset/1130,rejestr-zabytkow-nieruchomych> (dostęp: 20.11.2023).
- Page S. (1995). *Urban Tourism*. London–New York: Routledge.
- Palaniappan S. (2023). *On Doing a Thorough Exploratory Data Analysis with Pandas in Python*. Online: <https://medium.com/@drsamypal/on-doing-a-thorough-exploratory-data-analysis-with-pandas-in-python-b210c8c69d88> (dostęp: 20.11.2023).
- Panourgias C. (2023). *Clustering with DBSCAN*. Online: <https://medium.com/@panourgiaschris/clustering-with-dbscan-b573a6056ad1> (dostęp: 20.11.2023).
- Rahmadian R., Feitosa D., Zwitter A. (2021). A Systematic Literature Review on the Use of Big Data for Sustainable Tourism. *Current Issues in Tourism*, 25(11), 1–20. DOI: <https://doi.org/10.1080/13683500.2021.1974358>
- Rath S.R. (2022). *Traffic Sign Recognition Using PyTorch and Deep Learning*. Online: <https://debuggercafe.com/traffic-sign-recognition-using-pytorch-and-deep-learning> (dostęp: 20.11.2023).
- Rodrigo J.A., Ortiz J.E. (2021). *Skforecast: Time Series Forecasting with Python and Scikit-Learn*. Online: <https://cienciadedatos.net/documentos/py27-time-series-forecasting-python-scikitlearn.html> (dostęp: 20.11.2023).
- Rogacewicz B. (2018). *Machine Learning – przydatne narzędzia i biblioteki*. Online: <https://no-fluffjobs.com/pl/log/wiedza-it/machine-learning-przydatne-narzedzia-i-biblioteki> (dostęp: 20.11.2023).

- Sinclair M., Ghermandi A., Sheela A.M. (2018). A Crowdsourced Valuation of Recreational Ecosystem Services Using Social Media Data: An Application to Tropical Wetland in India. *Science of the Total Environment*, 642, 356–365. DOI: <https://doi.org/10.1016/j.scitotenv.2018.06.056>
- Strzyż M. (2018). Wyżyna Kielecka (342.3). W: A. Richling, J. Solon, A. Macias, J. Balon, J. Bo-rzyszkowski, M. Kistowski (red.), *Regionalna geografia fizyczna Polski* (s. 421). Poznań: Bogucki Wydawnictwo Naukowe.
- Warszyńska J., Jackowski A. (1978). *Podstawy geografii turystyki*. Warszawa: PWN.
- Wilkins E.J., Wood S.A., Smith J.W. (2020). Uses and Limitations of Social Media to Inform Visitor Use Management in Parks and Protected Areas: A Systematic Review. *Environmental Management*, 67, 120–132. DOI: <https://doi.org/10.1007/s00267-020-01373-7>
- Wood S.A., Guerry A.D., Silver J.M., Lacayo M. (2013). Using Social Media to Quantify Nature-Based Tourism and Recreation. *Scientific Reports*, 3. DOI: <https://doi.org/10.1038/srep02976>
- Zhong L., Sun S., Law R. (2019). Movement Patterns of Tourists. *Tourism Management*, 75, 318–322. DOI: <https://doi.org/10.1016/j.tourman.2019.05.015>

PUBLICATION INFO		
SUBMITTED: 2023.12.13	ACCEPTED: 2024.04.09	PUBLISHED ONLINE: 2024.04.19