



Politechnika Krakowska
im. Tadeusza Kościuszki

Nauki inżynieryjno-techniczne | Inżynieria lądowa i transport



ROZPRAWA DOKTORSKA

Modelowanie wpływu otoczenia trasy na parametry podróży rowerami miejskimi

Modelling the influence of the immediate vicinity of route on the parameters of travels by city bicycles

Autor: mgr inż. Krystian Adam Banet
Promotor: dr hab. inż. Vitalii Naumov, prof. PK
Katedra Systemów Transportowych

Kraków, czerwiec 2021



Politechnika Krakowska
Wydział Inżynierii Lądowej

Droga nie wybrana

Dwie drogi w żółtym lesie szły w dwie różne strony:

Żalując, że się nie da jechać dwiema naraz

I być jednym podróżnym, stałem, zapatrzony

W głąb pierwszej z dróg, aż po jej zakręt oddalony,

Gdzie widok nikał w gęstych krzakach i konarach;

Potem ruszyłem drugą z nich, nie mniej ciekawą,

Może wartą wyboru z tej jednej przyczyny,

Że, rzadziej używana, zarastała trawą;

A jednak mogłem skrócić tak w lewo, jak w prawo:

Tu i tam takie same były koleiny,

Pełne liści, na których w tej porannej porze

Nie znaczyły się jeszcze śladów czarne smugi.

Och, wiedziałem: choć pierwszą na później odłożę,

Drogi nas w inne drogi prowadzą - i może

Nie zjawię się w tym samym miejscu po raz drugi.

Po wielu latach, z twarzą przez zmarszczki zoraną,

Opowiem to, z westchnieniem i mglistym morałem:

Zdarzyło mi się niegdyś ujrzeć w lesie rano

Dwie drogi; pojechałem tą mniej uczęszczaną -

Reszta wzięła się z tego, że to ją wybrałem.

Robert Frost

Dziękuję firmie BikeU, Operatorowi systemu rowerów miejskich Wavelo, za udostępnienie danych, bez których powstanie niniejszej pracy doktorskiej nie byłoby możliwe.

Autor

Spis treści

Streszczenie	9
Summary	11
1. Wprowadzenie	14
1.1. Zrównoważony rozwój w zakresie mobilności	14
1.2. Cel pracy	16
1.3. Struktura pracy	17
2. Stan aktualnych badań nad ruchem rowerowym	20
2.1. Rower jako środek transportu	20
2.2. Korzyści ruchu rowerowego	22
2.3. Czynniki i bariery rozwoju ruchu rowerowego	24
2.4. Ruch rowerowy a rozwój zrównoważony. Promocja ruchu rowerowego	29
2.5. Udział podróży rowerowych we wszystkich podróżach	39
2.6. Parametry podróży rowerowych	46
2.7. Pomiary i prognozowanie ruchu rowerowego	51
2.8. Modele ruchu rowerowego	56
2.9. Systemy <i>bike-sharing</i> i możliwości pozyskiwania z nich danych	62
2.10. Podsumowanie stanu badań nad ruchem rowerowym	70
3. Wykorzystanie dużych zbiorów danych do modelowania ruchu rowerowego	72
3.1. Weryfikacja analizowanego zbioru danych	78
3.1.1. Metodyka weryfikacji analizowanego zbioru danych	80
3.1.2. Wyniki weryfikacji analizowanego zbioru danych	82
3.2. Weryfikacja danych o liczbie i czasie postojów użytkowników rowerów miejskich	84
3.2.1. Metodyka weryfikacji danych o liczbie i czasie postojów użytkowników rowerów miejskich	85
3.2.2. Wyniki weryfikacji danych o liczbie i czasie postojów użytkowników rowerów miejskich	87
3.2.3. Agregacja danych o liczbie i czasie postojów użytkowników rowerów miejskich	89
3.2.4. Dychotomizacja danych o liczbie i czasie postojów użytkowników rowerów miejskich	94

4.	Waloryzacja otoczenia trasy.....	98
4.1.	Analiza walorów kulturowych na potrzeby opracowania waloryzacji otoczenia trasy.	102
4.2.	Analiza walorów przyrodniczych na potrzeby opracowania waloryzacji otoczenia trasy	106
4.3.	Metodyka i wyniki opracowania waloryzacji otoczenia trasy.....	107
4.3.1.	Metodyka opracowania waloryzacji otoczenia trasy	109
4.3.2.	Walidacja opracowanej metodyki waloryzacji otoczenia trasy	111
5.	Modelowanie dla potrzeb określenia wpływu otoczenia trasy na parametry podróży rowerami miejskimi.....	114
5.1.	Model wpływu otoczenia trasy na czas podróży rowerami miejskimi.....	118
5.2.	Model wpływu otoczenia trasy na długość podróży rowerami miejskimi.....	121
5.3.	Model wpływu otoczenia trasy na współczynnik wydłużenia trasy w podróżach rowerami miejskimi	122
5.4.	Modele wpływu otoczenia trasy na liczbę i czas postojów użytkowników rowerów miejskich	124
5.4.1.	Modele regresji liniowej wpływu otoczenia trasy na liczbę i czas postojów użytkowników rowerów miejskich.....	125
5.4.2.	Modele regresji logistycznej wpływu otoczenia trasy na liczbę i czas postojów użytkowników rowerów miejskich	129
6.	Podsumowanie	134
6.1.	Wnioski generalne	136
6.2.	Kierunki dalszych badań	137
	Spis rysunków.....	139
	Spis fotografii.....	141
	Spis tabel	142
	Bibliografia.....	143
	Spis załączników	159

Streszczenie

Pojęcie zrównoważonej mobilności jest obecnie jednym z częściej poruszanych zagadnień w transporcie. Z pojęciem tym wiąże się m.in. rozwój ruchu pieszego i proekologicznych środków transportu, w które zaliczają się rowery, w tym rowery publiczne. Na wybór tego środka transportu wpływ ma szereg czynników indywidualnych i środowiskowych, spośród których do najważniejszych należą: płeć, wiek, warunki pogodowe czy topografia i zagospodarowanie terenu. Jedynym z aspektów jest także atrakcyjność otoczenia trasy, co czyni badania jego wpływu na parametry podróży rowerami miejskimi zagadnieniem interdyscyplinarnym z pogranicza urbanistyki i planowania systemów transportowych.

W niniejszej pracy analizie poddane zostały dane z systemu rowerów publicznych Wavelo, który funkcjonował w latach 2017-2020 w Krakowie. Dane zawierały informacje o wybranych przez użytkowników trasach i czasie podróży, dzięki czemu możliwa była ocena rozkładu czasowo-przestrzennego podróży rowerami miejskimi. Po przeprowadzonej procedurze czyszczenia danych o podróżach rowerowych w ramach systemu Wavelo i filtrowania danych o postojach, opracowano metodykę oceny atrakcyjności otoczenia trasy. Metodyka ta opiera się na wskazaniu poziomu atrakcyjności otoczenia trasy na bazie występujących w przestrzeni walorów kulturowo-przyrodniczych.

Przygotowane w ten sposób zestawy danych pozwoliły na określenie modeli regresji liniowej opisujących wpływ atrakcyjności otoczenia trasy na takie parametry podróży rowerowych jak: czas trwania podróży, długość podróży i współczynnik wydłużenia trasy. Ponadto opracowano model regresji logistycznej służący do przewidywania, w których miejscach nastąpi duża liczba lub duży sumaryczny czas postojów. Dzięki temu uzyskano narzędzie dla decydentów i urbanistów służące do identyfikacji miejsc atrakcyjnych dla rowerzystów, co będzie pomocne w kształtowaniu przestrzeni publicznej pod kątem wymagań tej grupy użytkowników.

Summary

The concept of sustainable mobility is now one of the more talked about issues in transport. This concept is linked to, among other things, the development of pedestrian traffic and environmentally friendly modes of transport, which include cycling, including public bicycles. The choice of this mode of transport is influenced by a number of individual and environmental factors, among which the most important are gender, age, weather conditions or topography and land development. One of the aspects is also the attractiveness of the immediate vicinity of the route, which makes the study of its influence on the parameters of urban cycling an interdisciplinary issue from the borderland of urban planning and transport system planning.

This study analyses data from the Wavelo bike sharing system that operated between 2017 and 2020 in Kraków. The data contained information on user-selected routes and trip times, allowing an assessment of the time-space distribution of urban cycling trips. Following a procedure for cleaning cycling trip data within the Wavelo system and filtering data about stops, a methodology was developed to assess the attractiveness of the immediate vicinity of the route. The methodology is based on an indication of the level of attractiveness of the immediate vicinity of the route on the basis of the cultural and natural values present in the space.

The data sets prepared in this way allowed to define linear regression models describing the influence of the attractiveness of the immediate vicinity of the route on such parameters of cycling trips as: duration of the trip, length of the trip and the coefficient of route extension. In addition, a logistic regression model was developed to predict where a high number or high total stopping time would occur. This has provided a tool for decision makers and urban planners to identify places attractive for cyclists, which will be helpful in shaping public space according to the requirements of this group of users.

1

||||| Wprowadzenie

1. Wprowadzenie

Ruch rowerowy jako problem badawczy analizowany jest przez różne dziedziny nauki, począwszy od inżynierii lądowej i transportu, poprzez urbanistykę, nauki społeczne i ekonomiczne do medycyny. Problematyka ruchu rowerowego jest także zagadnieniem podejmowanym przez geografów transportu, którzy zajmują się analizą miejskiego i turystycznego ruchu rowerowego. Oprócz tego wykazuje się procesy rządzące ruchem rowerowym, wpływ warunków klimatycznych, ukształtowania terenu, zagospodarowania przestrzennego na preferencje transportowe czy subiektywne postrzeganie przestrzeni miast lub obszarów turystycznych [1]–[4]. W literaturze widoczna jest luka badawcza dotycząca metod szacowania popytu na podróże rowerowe. Powodem jest m.in. brak dobrej jakości danych o ruchu rowerowym. Wielu badaczy mimo to podjęło się próby określenia wpływu takich czynników jak: rodzaj trasy, nawierzchnia czy warunki pogodowe na liczbę podróży rowerowych [3], [5]–[9]. Niewielu z nich skupiło się natomiast na parametrach tych podróży, takich jak współczynnik wydłużenia trasy czy czas i lokalizacja postojów. W pracy postanowiono sprawdzić jak parametry podróży rowerowych zależą od poziomu atrakcyjności otoczenia trasy, opisanego liczbą towarzyszących jej walorów kulturowo-przyrodniczych. Badanie wszystkich podróży rowerowych nie było możliwe ze względu na brak danych, które pokazywałyby jak kształtują się wszystkie podróże rowerowe w mieście, biorąc pod uwagę ich rozkład przestrzenny i czasowy. Dzięki możliwości pozyskania danych od operatora rowerów publicznych Wavelo, które funkcjonowały w Krakowie w latach 2017-2020, w pracy skupiono się na analizie wpływu otoczenia trasy na parametry podróży rowerami miejskimi, co dzięki modelom regresji liniowej i regresji logistycznej udało się potwierdzić. Skupienie się w pracy jedynie na rowerach miejskich stanowi jej największe ograniczenie ze względu na nieudowodnioną możliwość ekstrapolacji wyników na całą populację rowerzystów.

1.1. Zrównoważony rozwój w zakresie mobilności

Główna idea „smart city” opiera się na założeniu, by inwestycje w kapitał społeczny, technologie czy infrastrukturę przyczyniały się do rozwoju miasta i stałego podwyższania jakości życia mieszkańców. Jednym z filarów filozofii „smart” jest nowoczesny i zintegrowany transport, a jego nieodzowną częścią, która na przestrzeni ostatnich lat bardzo zyskała na znaczeniu, nie tylko w największych metropoliach, ale także w średniej wielkości i najmniejszych samorządach, są właśnie samoobsługowe systemy krótkoterminowego wynajmu rowerów (ang. *bike-sharing system*) [10]. Z istotą zrównoważonego transportu związane

jest pojęcie „miękkiej mobilności”, które charakteryzuje zachowania komunikacyjne redukujące pracę przewozową i preferuje środki lokomocji przyjazne środowisku [11]. Do tej grupy zaliczają się rowery, w tym rowery publiczne, które są przykładem systemów pojazdów współdzielonych obejmujących sieć strategicznie rozmieszczonych stacji, które dysponują określoną flotą pojazdów. Bez względu na wskazane powyżej ograniczenia, przygotowana dysertacja wpisuje się w szerszy kontekst działań związanych z opracowywaniem modeli rozwoju „smart” transportu, które będą w stanie zapewnić mobilność odpowiadającą zapotrzebowaniu społecznemu przy możliwie najniższym obciążeniu środowiska. To z kolei wpisuje się w ideę wdrażania zasad zrównoważonego rozwoju w zakresie mobilności [12] i było jedną z motywacji zajęcia się tematem rowerów miejskich. Dodatkowo w pracy udało się powiązać ze sobą „miękką” tematykę związaną z urbanistyką i waloryzacją otoczenia trasy oraz konkretne dane liczbowe o podróżach rowerów miejskich, które to związane są z pojęciem dużych zbiorów danych (ang. *big data*) [13]. Pierwsze udokumentowane użycie terminu *big data* pojawiło się w artykule z 1997 roku, autorstwa naukowców z NASA, opisującym problem, jaki mieli z wizualizacją dużej ilości danych [14]. Obecnie według definicji Słownika Cambridge *big data* to bardzo duże zbiory danych, które są tworzone przez osoby korzystające z Internetu i które mogą być przechowywane, rozumiane i wykorzystywane wyłącznie za pomocą specjalnych narzędzi i metod [15]. Zgodnie z definicją Gartnera *big data* to dane, które zawierają większą różnorodność (ang. *variety*), przybywającą w coraz większej ilości (ang. *volume*) i z coraz większą prędkością (ang. *velocity*). Definicja ta znana jest jako „trzy V” (ang. *the three Vs*). Zestawy danych określane mianem *big data* są tak obszerne, że tradycyjne oprogramowanie do przetwarzania danych nie może nimi zarządzać, ale te olbrzymie ilości danych można wykorzystać do rozwiązania problemów, które wcześniej nie były możliwe do rozwiązania [13]. Przykładem takiego problemu jest kwestia prognozowania i modelowania ruchu rowerowego dzięki wykorzystaniu danych z systemu miejskich wypożyczalni rowerów, mówiących o źródłach i celach podróży, porze, w której się odbyła, czasie jej trwania, a niekiedy także dając informację o trasie przejazdu. Duże zbiory danych stanowią ciekawe źródło wiedzy i pozwalają na przeprowadzenie analiz, których wykonanie nie było dotąd możliwe przy użyciu tradycyjnych metod i pozwala na odkrycie często niedostrzeganych dotychczas zależności.

1.2. Cel pracy

Podjęte w pracy badania poszerzają wiedzę na temat parametrów podróży realizowanych w obrębie systemu rowerów miejskich w Krakowie, a celem naukowym pracy jest **opracowanie modelu wpływu otoczenia trasy na parametry podróży w obrębie systemu rowerów miejskich**. Wśród działań służących osiągnięciu powyższego celu wymienić można **analizę danych o podróżach rowerami miejskimi**, w tym **opracowanie metodyki weryfikacji dużych zbiorów danych o podróżach realizowanych z użyciem tego środka transportu** oraz **opracowanie zaawansowanych modeli uczenia maszynowego**. Przeprowadzone analizy pozwoliły na uzupełnienie luki badawczej w zakresie analizy liczby i czasu postojów użytkowników systemu rowerów publicznych.

Praktycznym celem pracy jest **opracowanie narzędzia dla decydentów i urbanistów do identyfikacji miejsc, które są atrakcyjne dla użytkowników rowerów miejskich**. W praktyce pozwala to na określenie tych obszarów, w których powinno się zwrócić szczególną uwagę na kształtowanie przestrzeni publicznej pod kątem urządzeń małej architektury i lokalizowania mebli miejskich umożliwiających odpoczynek, a także lokalizowania rowerowej infrastruktury punktowej. Spełnia to warunki kreowania dobrej przestrzeni publicznej, która jest otwarta i dostosowana do potrzeb wielu grup użytkowników. Wpisuje się to także w szerszy kontekst promocji zrównoważonego transportu i zmniejszenia zatłoczenia komunikacyjnego. Jednym ze sposobów redukcji takiego zatłoczenia jest **odpowiednie kształtowanie przestrzeni transportowej z uwzględnieniem potrzeb percepcyjnych i ruchowych wszystkich uczestników ruchu drogowego, również pieszych i rowerzystów, co dotyczy nie tylko kształtowania infrastruktury liniowej**. Takie podejście do rozwiązania tych problemów może być czynnikiem zachęcającym te grupy uczestników ruchu drogowego do wyboru właśnie takiego sposobu realizacji codziennych przemieszczeń [16]. To z kolei przynosi szereg korzyści dla miasta, m.in. kreowanie pozytywnego wizerunku miasta otwartego na promowanie ekologicznych form transportu, zmiana podziału zadań przewozowych, pozytywne zmiany przestrzenne ulic i placów, poprawa zdrowia publicznego czy poprawa warunków środowiska miejskiego. Należy pamiętać, że ruch rowerowy stanowi podstawowy składnik systemów transportowych w obszarach śródmiejskich. Dynamiczny wzrost liczby rowerzystów w ostatnich latach narzuca obowiązek podejmowania działań przystosowujących ulice i place do rosnących potrzeb. Wieloletnie zaniedbania powinny zachęcać do poszukiwania rozwiązań, które szybko i bez angażowania nadmiernych środków będą przynosić zauważalną poprawę sytuacji ruchu rowerowego, w połączeniu z działaniami porządkującymi przestrzeń ulic i placów [17].

1.3. Struktura pracy

Niniejsza praca składa się z następujących części:

- W **rozdziale 1** zawarto wprowadzenie do tematu, w którym zarysowano jego szerszy kontekst, genezy podjęcia tematu oraz cele pracy;
- W **rozdziale 2** zawarto opis aktualnego stanu badań związanych z ruchem rowerowym, w tym z systemami rowerów publicznych. Rozdział podzielony został na dziewięć części odpowiadających konkretnym zagadnieniom literaturowym i zakończony krótkim podsumowaniem stanu badań. Podrozdziały rozdziału 2 odnoszą się do stanu badań w zakresie: korzyści ruchu rowerowego, czynników i barier w rozwoju ruchu rowerowego, promocji ruchu rowerowego w kontekście zrównoważonego rozwoju, udziału podróży rowerowych, parametrów podróży rowerowych, pomiarów i prognozowania ruchu rowerowego, modelowania ruchu rowerowego oraz systemów rowerów publicznych;
- W **rozdziale 3** zaprezentowano informacje na temat pozyskanej próbki danych wraz z opisem zaproponowanej metodyki weryfikacji (czyszczenia) surowych danych i filtrowania danych o postojach użytkowników rowerów miejskich. Zaproponowana metodyka weryfikacji danych opiera się o trzy etapy, w których z próbki eliminowane są uszkodzone dane oraz rekordy z zerowym dystansem lub czasem trwania podróży. Metoda filtrowania danych o postojach skupia się na eliminacji tych postojów, które nastąpiły w związku z czynnościami związanymi z wypożyczeniem roweru lub utrudnieniami w ruchu. W ramach rozdziału zaprezentowano także podstawowe statystyki oczyszczonego zbioru danych oraz wstępne wyniki analiz związane z przygotowaniem map ciepła liczby i sumarycznego czasu postojów rowerzystów;
- W **rozdziale 4** opisano metodykę waloryzacji otoczenia trasy, bazującej na ocenie walorów kulturowych i przyrodniczych występujących na danym obszarze. Dzięki temu przygotowano dla Krakowa siatkę waloryzacyjną z przypisanym do każdego z pól siatki poziomem atrakcyjności otoczenia trasy. W jednym z podrozdziałów dokonano także walidacji opracowanej metodyki w oparciu o miejski dokument, stanowiący o walorach przestrzeni turystycznej miasta Krakowa;
- W **rozdziale 5** znajduje się opis założeń przygotowanych modeli liniowych wpływu atrakcyjności otoczenia trasy na długość podróży, jej czas oraz współczynnik wydłużenia trasy. Ponadto dla postojów użytkowników rowerów miejskich przygotowano modele regresji liniowej i logistycznej, dzięki którym możliwe jest

z dużym prawdopodobieństwem określenie, w których obszarach nastąpi duża liczba lub duży sumaryczny czas postojów;

- W **rozdziale 6** zawarto podsumowanie podjętych w niniejszej pracy rozważań wraz z kluczowymi wnioskami oraz koncepcją kierunków dalszych badań.

Na końcu pracy znajduje się **spis rysunków, fotografii i tabel** oraz licząca 224 pozycje **bibliografia**. Do pracy w wersji elektronicznej dołączone zostały **skrypty z kodem**, który został napisany w celu analizy danych o podróżach rowerami miejskimi Wavelo.

2

||||| Aktualny stan badań nad
ruchem rowerowym

2. Stan aktualnych badań nad ruchem rowerowym

Rozwój różnych środków transportu bardziej niż inne czynniki wpłynął na to, w jaki sposób przebiegał rozwój miast. Przed nadejściem ery motoryzacji miasta były mniejsze i bardziej zwarte pod względem powierzchni i liczby ludności. Podróżowanie między miastami było żmudne, a transport towarów był zasadniczo ograniczony do krótkich odległości. Podobnie z podróżami do pracy, szkoły, podróżami biznesowymi czy w celu spotkań towarzyskich – były one limitowane dla większości ludzi odległością dojazdu pieszo. Pojawienie się roweru zmieniło sposób podróżowania i dało większą swobodę. Zahamowanie rozwoju ruchu rowerowego spowodowane było rozwojem motoryzacji, jednak obecnie ruch rowerowy w codziennych dojazdach ze względu na szereg korzyści staje się coraz bardziej popularny. Rozwijający się ruch rowerowy stał się obiektem zainteresowania wielu badaczy. W literaturze pojawia się mnogość opracowań, w których poruszane są różnorakie aspekty ruchu rowerowego, takie jak: kwestie ekologiczne, ekonomiczne, społeczne czy te związane z jego prognozowaniem i modelowaniem oraz z projektowaniem infrastruktury rowerowej. Dodatkowo można wydzielić w literaturze pozycje dotyczące badania wpływu czynników zewnętrznych na rozwój ruchu rowerowego oraz ukazujące ruch rowerowy jako element zrównoważonego rozwoju transportu.

2.1. Rower jako środek transportu

Pojawienie się roweru było istotną innowacją, która znacznie rozszerzyła zakres możliwości odbywania podróży [18]. Po raz pierwszy rower zaprezentowany został na Wystawie Światowej w Paryżu w 1867 roku i był ważnym wynalazkiem, który zmienił sposób podróżowania mieszkańców miast u schyłku XIX wieku. Pierwotny rower określany jest mianem welocypedu (z fr. *vélocipède*) – był to rower nieposiadający łańcucha ani hamulców, często z bardzo dużym kołem przednim oraz z małym kołem tylnym (bicykl), niekiedy z dwoma kołami tylnymi (tricykl), czasem z dwoma kołami przednimi (kwadrycykl). Przykład jednego z pierwszych welocypedów ukazano na Fot. 2.1.



Fot. 2.1. Welocypedy z 1886 roku

(źródło: [19])

Początkowo rower używany był przez wyższe klasy jako forma spędzania wolnego czasu i rekreacji jednak z czasem został zaadoptowany przez klasę robotniczą jako środek transportu wykorzystywany przy dojazdach do pracy [8]. Rower jako środek transportu jest funkcjonalny poprzez zapewnianie możliwości podróżowania od drzwi do drzwi przy średniej prędkości komunikacyjnej 10-12 km/h, umożliwiając pokonanie odległości kilku kilometrów w społecznie akceptowalnym czasie podróży około 30 minut [20]. Obecnie, poza celami rekreacyjnymi, rower jest znacznie mniej używany jako środek transportu w krajach lepiej rozwiniętych, stanowiąc tym samym ważny środek transportu w krajach rozwijających się, zwłaszcza w Chinach [8]. Podobnie jest w innych krajach rozwijających się, gdzie koszty posiadania samochodu są zbyt duże dla przeciętnego obywatela, czego powodem jest niski dochód *per capita*, a do tego wysokie koszty utrzymania samochodu. Turner i in. (2006) wykazują, że wraz ze wzrostem dochodu *per capita* mieszkańcy zmieniają środek transportu na pojazd zmotoryzowany, a udział ruchu pieszego i rowerowego w ogóle podróży maleje [18]. Przykładem kraju, gdzie widoczny jest silny wpływ samochodu jako dominującego środka transportu są Stany Zjednoczone XX wieku. Modernistyczne przestrzenie usługowo-handlowe i mieszkaniowe, zaprojektowane tam po II wojnie światowej, nie zachęcają do

odbywania podróży pieszo. Typowe dla tych obszarów są braki w infrastrukturze dla ruchu pieszego i rowerowego oraz szerokie i trudne do pokonania ulice [18]. Przykład Stanów Zjednoczonych pokazuje jak w ciągu ostatnich 70 lat kraj może odwrócić się od tradycyjnego, kompaktowego miasta i przejść w kierunku miasta rozporozszonego, skoncentrowanego na samochodzie osobowym, który sprawia, że podróżowanie w inny sposób aniżeli prywatnym samochodem staje się niepraktyczne i niewygodne [21]. Jest to potęgowane częstym brakiem odważnych decyzji decydentów na redystrybucję przestrzeni i środków pomiędzy infrastrukturę drogową i rowerową, co skutkuje brakiem wystarczających funduszy na inwestycje w udogodnienia dla rowerzystów [22]. W takich warunkach mieszkańcy miast, którzy zwykle wybierają prywatne samochody w codziennych podróżach, rower postrzegają nie jako środek transportu, a jako formę rozrywki i rekreacji [18].

2.2. Korzyści ruchu rowerowego

Ruch rowerowy, podobnie jak pieszy, od lat doceniany jest ze względu na swoje walory zdrowotne, jednak niesie za sobą nie tylko korzyści w zakresie zdrowia i sprawności fizycznej, ale także dla środowiska. Badania wykazały, że nawet średni wysiłek związany z regularną jazdą na rowerze poprawia jakość życia i redukuje ryzyko wystąpienia choroby wieńcowej serca, cukrzycy, udaru, a także pomaga redukować koszty leczenia i zwiększyć poziom niezależności funkcjonalnej w późniejszych latach życia. Użytkowanie roweru poprawia ogólną sprawność i prowadzi do pozytywnych zmian fizjologicznych i psychologicznych. Usprawnia organizm szczególnie w zakresie funkcjonowania: płuc, układu oddechowego, serca i krążenia. Poza korzyściami zdrowotnymi ruch pieszy i rowerowy posiada także walory społeczne, dając pieszym i rowerzystom więcej możliwości do socjalizacji aniżeli mają ich kierujący samochodami osobowymi [18], [23], [24]. Ruch rowerowy wpływa też na lepszą koncentrację u dzieci, które dojeżdżają rowerem do szkoły w porównaniu do ich rówieśników, którzy są podwożeni samochodem [25]. Ostatnimi laty zaczyna być także dostrzegana rola ruchu rowerowego jako proekologicznego środka transportu, którego udział w wielu obszarach zurbanizowanych rośnie [26]. Gonzalo-Ordena i in. (2014) wskazują, że rower w mieście łączy w sobie zalety transportu indywidualnego i transportu publicznego. Jazda na rowerze podobnie jak jazda samochodem osobowym zapewnia wysoką średnią prędkość podróży od drzwi do drzwi oraz elastyczność wyboru trasy przejazdu. Pod kątem przystępności kosztów i przyjazności dla środowiska rower jest jak transport publiczny [27]. Pod kątem środowiska dostrzegana jest zaleta roweru jaką jest niezuzywanie energii elektrycznej oraz paliw płynnych.

W dodatku rower, prócz energooszczędności, cechuje się oszczędnością terenu, tak w ruchu jak i w spoczynku, a do tego ma wysoką zdolność przewozową na odległościach osiągalnych dla roweru [20]. Więcej podróży rowerowych w miastach przyczynia się do niższego poziomu zanieczyszczenia, oszczędności przestrzeni, a co za tym idzie możliwości lepszego jej wykorzystania, zwłaszcza w centrach miast. Dla miast zwiększony udział podróży rowerowych to także synonim poprawy ogólnej jakości życia, mniejszy hałas, mniejsze pogorszenie stanu zabytków i mniejsze koszty sprzątanania [11], [22], [28]. Zalewski (1996) zwraca też uwagę na to, że rower jest skuteczny jak chodzi o wzrost atrakcyjności miasta jako ośrodka turystyczno-krajoznawczego [29]. Kopta i Rudnicki (1996) uwypuklają również wpływ ruchu rowerowego na powstrzymanie procesów dekoncentracji osadnictwa poprzez mniejsze zatłoczenie ulic samochodami czy łagodzenie deficytu miejsc parkingowych w strefach intensywnie zabudowanych. To z kolei hamuje proces wyludniania obszarów miasta w poszukiwaniu dogodniejszych warunków bytowania na peryferiach i w obszarach podmiejskich [11].

W przypadku inwestycji w transport publiczny widoczny jest ich wpływ na wartość nieruchomości. Wyniki prowadzonych przez Debrezion i in. (2006) analiz statystycznych i ekonometrycznych dowiodły, że – wykluczając wpływ innych czynników – mieszkania w pobliżu stacji kolejowych są średnio o jedną czwartą droższe niż mieszkania leżące z dala od stacji. Równocześnie podwojenie częstotliwości kursowania pociągów prowadzi do wzrostu cen mieszkań o około 2,5% [30]. Okazuje się jednak, że również ruch rowerowy, a dokładniej drogi rowerowe, są również czynnikiem atrakcyjności i wpływają pozytywnie na wartości nieruchomości, co w swoich badaniach w miastach amerykańskich dowiódł Krizek (2007), zauważając jednak, że nie wszyscy właściciele nieruchomości na sprzedaż uznają udogodnienia rowerowe za ważne [31]. Pozytywny wpływ ruchu rowerowego na lokalną ekonomię został dowiedziony z kolei przez Garrett-Peltier (2011), która zauważyła, że co prawda skala oddziaływania infrastruktury rowerowej jest mniejsza niż transportu szynowego, jednak za obecność dróg rowerowych nabywcy nieruchomości w miastach Ameryki Północnej chcą płacić więcej [32].

Zmiana zachowań transportowych i rezygnacja z samochodów osobowych na rzecz ruchu pieszego i rowerowego przynosi, prócz korzyści zdrowotnych i ekologicznych, także społeczne oszczędności. Meschik (2012) w swoich badaniach w Wiedniu wykazał, że ruch rowerowy ma lepszy wpływ na ekonomię niż ruch samochodowy. W związku z tym zwraca on uwagę, że wydatki na infrastrukturę rowerową nie są aktem dobroczynności podatników wobec mającej mniejsze prawa grupy użytkowników dróg. Doszedł on także do wniosku, że wzrost natężenia samochodów osobowych w połączeniu z obecnymi wzorcami użytkowania

terenu przywiązani do samochodu osobowego i siedzącym trybem życia powodują niezliczone problemy i koszty dla całego społeczeństwa [33]. Badania przeprowadzone w Minnesocie pokazały, że poprzez zmianę zachowań komunikacyjnych w podróżach do jednej mili, amerykańska gospodarka jest w stanie zaoszczędzić od 3 do 14 centów na jednym pojazdokilometrze, dzięki zredukowaniu zanieczyszczenia powietrza, zmniejszeniu kosztów importu paliwa czy kosztów związanych z kongestią i czasem w niej traconym [34]. Na podstawie danych z 2016 roku w przypadku Unii Europejskiej dzięki przejechanym na rowerze w ciągu roku 134 mld km we Wspólnocie zaoszczędzono: niemal 15,5 mld euro w zakresie środowiska i klimatu (oszczędności wynikające m.in. z redukcji emisji dwutlenku węgla, zanieczyszczeń powietrza), 2,8 mld euro jak chodzi o energię (m.in. obniżenie zużycia paliw), a oszczędność na poziomie 191,3 mld euro przyniosły korzyści zdrowotne (obniżenie ciężkości wypadków czy wydłużenie życia). Ponadto korzyści mikroekonomiczne, takie jak rozwój przemysłu rowerowego i turystyki rowerowej, pomogły zaoszczędzić Unii 63,1 mld euro. Kolejne 20,0 mld euro oszczędności związane jest z technologią i projektowaniem, w tym korzyściami związanymi z integracją planowania przestrzennego i infrastruktury. Oszczędności dla UE związane są także z czasem oraz przestrzenią (131,0 mld euro), kwestiami społecznymi (50,0 mld euro), mobilnością i kongestią (29,6 mld euro), a także z dywersyfikacją kultury rowerowej (10,0 mld euro) [35].

2.3. Czynniki i bariery rozwoju ruchu rowerowego

Na wybór roweru jako środka transportu wpływ mają różne czynniki, takie jak czynniki indywidualne czy środowiskowe. Wśród czynników indywidualnych najważniejsze znaczenie ma wiek [28], [36]. Większość badań pokazuje, że z wiekiem jazda na rowerze staje się coraz mniej popularna, w szczególności gdy mowa o podróżach rowerowych w dojazdach do pracy czy szkoły [26], [28], [37]. Wpływ na ruch rowerowy ma także płeć. Badania Parkina i in. (2007) wskazują, że częściej na rowerze podróżują mężczyźni [28], [38]. Do czynników indywidualnych zaliczyć można także: dochody, przyzwyczajenia, przekonania i wyznawane wartości czy okoliczności i potrzeby rodzinne, jak np. konieczność odwiezienia dzieci do szkoły [36]. Ortúzar i in. (2000) wskazali również, że wielkość gospodarstwa domowego oraz poziom wykształcenia i zatrudnienia mają wpływ na wybór roweru jako środka transportu [39]. Dodatkowo samochód osobowy dla wielu jest symbolem siły, prestiżu, niezależności, wolności i statusu społecznego [23].

Odnosnie czynników środowiskowych jedne z amerykańskich badań pokazały, że obecność uniwersytetu w mieście korzystnie wpływa na zwiększenie liczby podróży rowerowych. W rzeczywistości żaden inny czynnik nie koreluje tak konsekwentnie z wysokim poziomem dojazdów do pracy rowerem [36]. Miasta z wyższym odsetkiem ludności dojeżdżającej do 5,0 mil lub mniej zwykle mają więcej rowerzystów, ale gdy miasta uniwersyteckie są usuwane z tej grupy, relacja jest nieco słabsza. Znacznie ważniejszy jest stosunek długości tras rowerowych do długości sieci drogowej w mieście. Nawet jeśli miasta uniwersyteckie nie są brane pod uwagę to miasta o wyższym poziomie dojazdów rowerowych mają średnio o 70% więcej tras rowerowych na milę drogi i sześć razy więcej ścieżek rowerowych na milę głównych arterii.

Wśród czynników środowiskowych mających wpływ na wybór roweru jako środka transportu należy wymienić także topografię. Intuicyjnie wydaje się, że tereny faliste i górzyste są potencjalnym czynnikiem odstrasającym od podróży rowerowych ze względu na konieczność pokonywania wzniesień oraz zmęczenie [36]. Badania w tym zakresie są ograniczone, jednak te wykonane w Anglii nad podmiejskimi dojazdami do pracy i szkoły na rowerach wykazały silną negatywną korelację między pagórkowatością obszaru, a poziomem dojazdów do pracy rowerem [40]. Pod względem topografii Parkin i in. (2007) [38], Stinson i Bhat (2003) [41], Cervero i Duncan (2003) [42] oraz Sener i in. (2009) [43] stwierdzili, że obecność stromych wzgórz stanowi główny czynnik zniechęcający do jazdy rowerem, zwłaszcza dla kobiet. Okoliczność ta jest dużo mniej istotna w przypadku rowerów elektrycznych, które w przeciwieństwie do tradycyjnych rowerów, zapewniają dodatkowe doładowanie za pomocą elektrycznego silnika wspomagania pedalów, dzięki czemu znacznie ułatwiają poruszanie się po pagórkowatym terenie [44]. Oprócz ukształtowania terenu wpływ na liczbę podróży rowerowych ma także otoczenie, tj. zagospodarowanie terenu. Fegan (1992) oraz Kuzmyak i Dill (2012) zwracają uwagę, że zwarta zabudowa może zmniejszyć dystans podróży i tym samym uczynić jazdę na rowerze realną opcją podróży [21], [36]. Według Fegan większa gęstość zabudowy może jednak oznaczać również większe zatłoczenie ulic, co powoduje, że przestrzeń dla rowerzystów staje się ograniczona, tak więc wysoka gęstość ruchu bez sieci bezpiecznej infrastruktury rowerowej może nie stymulować podróży rowerowych [36]. Uwagę na to zwraca też Zalewski (1987), który zauważył, że zwarta i gęsta zabudowa (przede wszystkim w śródmieściach i centrach miast) nie sprzyja wydzielaniu liniowych urządzeń ułatwiających korzystanie z roweru [20]. Poza zwartością zabudowy inni badacze, tj. Cervero i Duncan (2003), zbadali efekty wpływu struktury funkcjonalnej na podróże rowerowe i zasugerowali wzrost podróży rowerowych przy polifunkcyjności obszaru [42]. Axhausen i Smith (1986) także zasugerowali w swoich badaniach wpływ funkcji otoczenia na wybór

środka transportu [45]. Beim (2003) przeanalizował dodatkowo wpływ rodzaju zabudowy mieszkaniowej na preferencje transportowe mieszkańców. Ujawnia się tu m.in. problem przechowywania rowerów jako jeden z bardziej istotnych czynników utrudniających korzystanie z niego, na co zwrócił uwagę także Kopta (1985) [46], [47], który również przywołał badania Knoflachera i Klossa (1979). Wynika z nich, że liczba podróży rowerowych jest powiązana z wielkością miasta, tj. wraz ze wzrostem wielkości miasta maleje liczba podróży rowerowych przypadających na jednego mieszkańca [48]. Duży wpływ na wybór innych niż samochód osobowy środków transportu ma także czynnik związany z polityką parkingową i ograniczeniami w parkowaniu, w centrum [36]. Ortúzar i in. (2000) zwrócili uwagę, że również dostęp do transportu zbiorowego ma wpływ na wybór roweru jako środka transportu [39].

Fegan (1992) zwraca uwagę, iż klimat nie ma wpływu na liczbę podróży rowerowych, z wyjątkiem sezonowej i dziennej zmienności w podejmowaniu decyzji o wyborze roweru jako środka transportu [36], co znajduje także potwierdzenie u Kuzmyaka i Dill (2012) [21]. Duża rola w wyborze roweru jest jednak przypisywana warunkom pogodowym. Ohrn (1974) i Hanson (1974) doszli do wniosku, że pogoda jest większym czynnikiem odstrasającym od podróży obligatoryjnych związanych z pracą czy szkołą niż od podróży fakultatywnych [49], [50]. Badania sugerują, że najważniejszym czynnikiem pogodowym brany pod uwagę przy podejmowaniu decyzji o podróży rowerem są opady. Buckley (1982) zauważył znacznie więcej rowerzystów w dniach gdy pogoda była częściowo słoneczna, aniżeli w dni z mgłą i deszczem. Podobnie pomiary rowerzystów na West Seattle Bridge w latach 1990-1991 wykazały gwałtowne spadki liczby rowerzystów podczas dni deszczowych [36]. Również Dill i Carr (2003) w swoim artykule wskazały, że opady mają negatywny efekt na wybór roweru w dojazdach do pracy czy szkoły [51]. Do podobnych wniosków doszli Parkin i in. (2007) [38], w przeciwieństwie do Duncana i Cervero (2003), którzy nie zaobserwowali żadnego wpływu opadów na podróże rowerem [42]. Nankervis (1999) oraz Winter i in. (2007) zauważyli natomiast redukcję liczby podróży rowerowych podczas chłodniejszej pogody [52], [53]. Beim (2003) zauważył, że największą barierą dla podjęcia decyzji o wyruszeniu rowerem jest silniejszy deszcz i śnieg [46]. Hunt i Abraham (2007) zwracają uwagę na fakt, że wśród czynników zachęcających do odbywania podróży do pracy rowerem jest także obecność prysznicza w miejscu pracy i możliwość bezpiecznego pozostawienia roweru [1].

Wśród aspektów mających wpływ na udział podróży rowerowych nie bez znaczenia jest również infrastruktura rowerowa, jej gęstość i dostępność do niej [8], [27]. Zalewski (1993) zauważył zależność udziału podróży rowerowych w dzień roboczy w okresie wiosenno-letnim

od gęstości demograficznej sieci dróg rowerowych [54]. Pucher i Buehler (2008), którzy porównali doświadczenia związane z ruchem pieszym i rowerowym w Stanach Zjednoczonych i Europie podkreślili, że zapewnienie wysokiej jakości sieci infrastruktury dla pieszych i rowerzystów jest kluczowym czynnikiem wpływającym na wysoki udział podróży pieszych i rowerowych [37]. Aultman-Hall i in. (1997) zwracają uwagę, że większy stopień integracji sieci chodników i dróg rowerowych zachęca do odbywania podróży niezmotoryzowanych [55]. W krajach, w których ruch rowerowy przyjmuje formę niezorganizowaną, rowerzyści dzielą przestrzeń z przestrzenią przeznaczoną dla pieszych i samochodów, jednakże podjętych zostało wiele prób w celu wytworzenia w obrębie miast przestrzeni specjalnych dla rowerów (ang. *cycling areas*) z wydzielonymi pasami oraz obiektami służącymi do ich parkowania. Krajem, który przoduje w tej kwestii jest Holandia, w której drogi dla rowerów uczynione zostały częścią miejskiego systemu transportowego [8]. Okazuje się jednak, że nie zawsze w Holandii ruch rowerowy rozwijał się jak obecnie. W latach 1966-1971 nastąpił tam spadek ruchu rowerowego, a przyczyną tego były luki w układzie rowerowym, przy jednoczesnym gwałtownym rozwoju motoryzacji i przenoszeniu się mieszkańców miast na suburbia. Rozwój infrastruktury rowerowej oraz realizacja idei *woonerfu* ustabilizowała sytuację, dzięki czemu w Holandii nadal obowiązuje zasada powszechnego użytkowania roweru [56]. Doświadczenia np. z Amsterdamu i Kopenhagi, czyli miast stawianych za wzorzec rozwiniętego systemu rowerowego, pokazują, że impulsem do jego rozwoju musi być stworzenie systemu dróg i parkingów rowerowych [57]. Shafizadeh i Niemeier (1997) [58], Howard i Burns (2001) [59], Stinson i Bhat (2003) [41] oraz Tilahun i in. (2007) [60], pokazali, że rowerzyści preferują drogi dla rowerów aniżeli wspólne poruszanie się z samochodami po drogach.

Rozwój ruchu rowerowego w miastach hamowany jest w dużej mierze poprzez bariery infrastrukturalne. Sieć istniejących dróg dla rowerów jest często fragmentaryczna, a istniejące drogi dla rowerów mają określony przebieg, ich nawierzchnia jest złej jakości. Często budowa dróg rowerowych jest nieuzasadniona potrzebami, tj. drogi dla rowerów budowane są w miejscach gdzie łatwo je wyznaczyć, a nie tam, gdzie są potrzebne. Dodatkowo ograniczeniem są: brak możliwości bezpośredniego przejazdu przez przejścia dla pieszych, limitowana liczba parkingów, problemy z oznakowaniem czy niska kultura uczestników ruchu drogowego. Zwiększenie atrakcyjności roweru jako środka transportu jest ściśle powiązane z likwidacją wymienionych barier, co pojawia się bardzo często w literaturze ([8], [29], [46], [47], [57], [61]). Prócz tego Kopta i Rudnicki (1996) podkreślają, że poprzez relatywnie niskie koszty budowy dróg rowerowych i wysoką ich przepustowość są one bardziej efektywne niż jezdnie wykorzystywane przez samochody i autobusy [11]. Mimo to z danych Głównego

Urzędu Statystycznego wynika, że w skali kraju sieć dróg dla rowerów nie jest dobrze rozwinięta. Łączna długość dróg dla rowerów będących pod zarządem jednostek samorządu terytorialnego w 2017 roku w Polsce wyniosła 12,1 tys. km, z czego 67,1% stanowiły ścieżki będące pod zarządem gmin, a 18,6% ścieżki pozostające pod zarządem powiatów. Najnowsze dane udostępniane przez GUS mówią, że w 2019 roku łączna długość dróg dla rowerów będących pod zarządem jednostek samorządu terytorialnego wynosiła 15,5 tys. km. Pomiędzy 2017 a 2019 rokiem nastąpił wzrost długości ścieżek rowerowych będących pod zarządem jednostek samorządu terytorialnego o 28,0%. Najdłuższe ścieżki rowerowe pozostające pod zarządem jednostek samorządu terytorialnego, przypadające na 10 tys. ludności, znajdowały się w 2019 roku w województwie lubuskim – 6,36 km, najkrótsze w województwie małopolskim – 1,87 km [62], [63]. Kopta (1983) zwraca uwagę, że brak rozwiniętej infrastruktury rowerowej powoduje, iż posiadane przez mieszkańców rowery nie pełnią żadnej roli komunikacyjnej [64]. Jeśli chodzi o liczbę rowerów w Polsce to GUS nie podaje jej wprost [65], wiadomo natomiast, że w 2017 roku 60,7% polskich gospodarstw domowych posiadało minimum jeden rower (inny niż dziecięcy) – wartość ta zmalała w stosunku do 2016 roku o 2,9% [66]. Dla 2019 roku GUS nie podaje konkretnych informacji o liczbie rowerów w gospodarstwach, informując jedynie, że w 2019 roku zdecydowanie większy odsetek gospodarstw domowych na wsi niż w mieście posiadał samochód osobowy, motocykl, skuter, motorower lub rower oraz, że w porównaniu z 2018 rokiem różnice w stopniu wyposażenia zmniejszyły się nieznacznie na korzyść wsi [67]. Problem z rozwojem ruchu rowerowego pojawia się zwłaszcza w miastach zależnych od samochodu (ang. *automobile-dependent cities*), w których współdzielenie dróg przez samochody ciężarowe, osobowe i rowery nie jest łatwe [8], a obawa o bezpieczeństwo osobiste w ruchu drogowym jest jedną z najczęściej wymienianych przyczyn rezygnacji z wyboru roweru jako środka transportu [18], [36]. Beim (2003) zwraca uwagę, że większość ludzi woli przy jeździe rowerem korzystać z dłuższej, ale wygodnej i bezpiecznej drogi. Większy udział osób pragnących się poruszać krótszą i mniej bezpieczną drogą w badaniach Beima był wśród wykorzystujących rower w dojazdach codziennych [46]. Kopta (1985) zwraca uwagę na fakt, że przyrost długości dróg rowerowych przekłada się na spadek liczby rannych i zabitych w wypadkach rowerzystów [47].

Wśród czynników, które zniechęcają do korzystania z rowerów jest także wygoda użytkowania, która pojawia się w wielu badaniach podróży jako główny czynnik, mający wpływ na podział zadań przewozowych, np. w Palo Alto czy Seattle (USA) [36], [68], [69]. Jednym z podstawowych pytań jest to jak zachęcić osoby wykorzystujące rowery jedynie do celów rekreacyjnych, by wykorzystywały rower także w codziennych dojazdach do pracy czy szkoły

[36]. Wysiłek fizyczny, który w sposób oczywisty jest wpisany w podróż o charakterze rekreacyjnym, rzadko jest akceptowany w sytuacji, gdy rower staje się normalnym środkiem transportu. Oczekiwania podróżujących są wówczas zbliżone do tych, które są stawiane systemowi drogowemu czy też systemowi transportu zbiorowego [57]. Ankieta Harris Poll z 1991 roku sugeruje, że część odpowiedzi na postawione pytanie jak zachęcić osoby wykorzystujące rower w celach rekreacyjnych do wykorzystywania go w codziennych podróżach, leży w ulepszeniu infrastruktury rowerowej [36]. Nie ma jednak pewności, w jakim stopniu deklarowany przez użytkownika zamiar wykorzystywania roweru w codziennych podróżach będzie odpowiadać rzeczywistej zmianie w zachowaniach komunikacyjnych jeśli ulepszenia w infrastrukturze zostaną zrealizowane [18], [36]. Można natomiast stwierdzić, że skuteczny rozwój komunikacji rowerowej w miastach i usuwanie ograniczających ją barier wymagają budowy narzędzi, pozwalających na prognozowanie ruchu rowerowego [61].

2.4. Ruch rowerowy a rozwój zrównoważony. Promocja ruchu rowerowego

Nie ulega wątpliwości, że rozwój infrastruktury transportowej winien preferować te formy transportu, które są przyjazne środowisku naturalnemu i jednocześnie służą lepszemu wykorzystaniu posiadanych zasobów [70], jak np. ruch rowerowy. Jego rozwój, prócz rozbudowy infrastruktury, musi odbywać się także poprzez działania promocyjne, które wskazują mieszkańcom miast korzyści płynące z ruchu rowerowego w myśl idei „zrównoważonego rozwoju”. Pojęcie to pojawiło się w 1972 roku na Konferencji Sztokholmskiej, a dokładniej zostało sformułowane podczas III Sesji Zarządzającej Programem Ochrony Środowiska Organizacji Narodów Zjednoczonych 3 lata później. Była to odpowiedź na dostrzeżenie potrzeby zmian w zakresie ochrony środowiska. Przyczynił się do tego kryzys energetyczny z 1973 roku i dokonana przez OPEC (ang. *Organization of the Petroleum Exporting Countries*) podwyżka cen ropy naftowej, które uświadomiły decydującym i społeczeństwu państw zachodnich, że surowce, nie tylko energetyczne, nie są darmowym ubikwitem [46]. Do tego jednocześnie ujemne działanie masowej motoryzacji na środowisko naturalne, które wymuszało większy umiar w użytkowaniu samochodów [64]. Wdrażane w tamtych czasach rozwiązania z zakresu ochrony środowiska i podejście, że ochrona środowiska jest osobną i najważniejszą dziedziną życia nie sprawdziły się. Dostrzeżono konieczność integracji celów ochrony środowiska z celami pozostałych dziedzin życia, co przyczyniło się do powstania koncepcji zrównoważonego rozwoju. Oficjalne przyjęcie

koncepcji zrównoważonego rozwoju to 1992 rok i Szczyt Ziemi w Rio de Janeiro. Przyjęty wówczas globalny program działań „Agenda 21” stał się inspiracją dla innych dokumentów, w tym m.in. Unii Europejskiej [46]. Wprowadzone w Rio de Janeiro pojęcie znalazło się również w polskich dokumentach, w tym w najważniejszym, tj. w Konstytucji. Artykuł 5. Konstytucji RP mówi, że *Rzeczpospolita Polska [...] zapewnia ochronę środowiska, kierując się zasadą zrównoważonego rozwoju* [71]. Rozwój zrównoważony jako odzwierciedlenie postanowień z Rio de Janeiro zdefiniowany jest także w polskiej Ustawie z dnia 27 kwietnia 2001 roku – Prawo ochrony środowiska. Definicja mówi, że jest to *rozwój społeczno-gospodarczy, w którym następuje proces integrowania działań politycznych, gospodarczych i społecznych, z zachowaniem równowagi przyrodniczej oraz trwałości podstawowych procesów przyrodniczych, w celu zagwarantowania możliwości zaspokajania podstawowych potrzeb poszczególnych społeczności lub obywateli zarówno współczesnego pokolenia, jak i przyszłych pokoleń* [72]. Zapisy o zrównoważonym rozwoju znalazły swoje odbicie także w dokumentach strategicznych Polski związanych z polityką: przestrzenną, środowiskową i transportową [73].

W czasach wzrastającego zatłoczenia motoryzacyjnego, które prowadzi do społecznych konfliktów, a także do zanieczyszczenia środowiska i przyczynia się do większości problemów komunikacyjnych ważne jest, aby przyjęto model rozwoju transportu, który będzie w stanie zapewnić mobilność odpowiadającą zapotrzebowaniu społecznemu przy możliwie najniższym obciążeniu środowiska. Rozwiązaniem jest wdrażanie idei zrównoważonego rozwoju w zakresie mobilności [46] oraz uchwalanie polityki komunikacyjnej przyjaznej ruchowi rowerowemu [11]. Z istotą zrównoważonego transportu związane jest pojęcie „miękkiej mobilności”, które charakteryzuje zachowania komunikacyjne redukujące pracę przewozową i preferuje środki lokomocji przyjazne środowisku [11]. W wielu dokumentach i opracowaniach, w tym w „Agendzie 21”, to ruch rowerowy wymieniany jest jako istotny element modelu zrównoważonego transportu [46]. Według definicji Ala (1991) *tylko taki system transportowy jest zrównoważony, który z pokolenia na pokolenie może w pełni funkcjonować przy przemieszczaniu osób i ładunków bez zanieczyszczenia: materiałów, energii, środowiska należnych każdemu pokoleniu* [74]. Aby te warunki zostały spełnione konieczna jest według niego zmiana w zachowaniach komunikacyjnych mieszkańców tak, by rola samochodu sprowadzała się głównie do realizacji rzadkich podróży lub podróży do miejsc rozproszonych, lecz komunikacja zbiorowa (także kolej) ma pełnić kluczową rolę na dłuższych dystansach i w codziennych podróżach. Podstawowymi formami do odbywania krótkich podróży zgodnie z tą definicją stać ma się ruch pieszy i rowerowy [11], [73]. Wbrew pozorom okazuje się, że pomimo wielkiego postępu w transporcie, rower nadal jest najszybszym i najtańszym środkiem

do odbywania krótkich podróży, a w dodatku można nim dotrzeć w rejony nieobsługiwane komunikacją zbiorową ani samochodem [64].

W 1994 roku w Ålborg, w Danii, podczas Europejskiej Konferencji na rzecz Zrównoważonego Rozwoju Miast i Gmin przyjęta została tzw. Karta Aalborska. Uczestnicy Konferencji przyjęli zobowiązanie do realizacji zadań określonych w „Agendzie 21” przez władze i społeczność lokalną [75]. Do momentu powstania Karty Aalborskiej uważano, zgodnie z zapisami przygotowanej pod przewodnictwem Le Corbusiera Karty Ateńskiej, że komunikacja w mieście może być zapewniona przede wszystkim za pomocą samochodów [76], [77]. Po raz pierwszy od lat Karta Aalborska w tak wyraźny sposób zaakcentowała potrzebę rozwoju alternatywnych dla indywidualnej motoryzacji środków transportu [46]. Dodatkowo wiele dokumentów, publikacji i konferencji poświęconych problematyce zrównoważonego transportu postawiło wobec władz wymagania, by integrować zagospodarowanie przestrzenne i planowanie transportu w taki sposób, aby zmniejszyć zapotrzebowanie na transport i umożliwić rozwój alternatywnych wobec samochodu form transportu, m.in. poprzez tworzenie sieci dróg rowerowych i dla pieszych, rozwój transportu zbiorowego i promocję ekologicznych środków transportu. Ponadto podkreślana jest istotność kreowania dogodnych warunków środowiskowych, sposobów osadnictwa i infrastruktury transportu zbiorowego, które dopuszczają i będą stymulować istotny wzrost liczby krótkich podróży realizowanych pieszo lub rowerem [11], [73], który jest doceniany nie tylko z uwagi na swoje walory funkcjonalno-techniczne, a szczególnie tereno- i energooszczędność. Poprzez to oraz powszechną potrzebę przeciwdziałania uciążliwościom komunikacyjnym i swoje walory społeczno-zdrowotne winien stać się dużo bardziej wykorzystywanym środkiem transportu [29], o czym mowa także w Karcie Brukselskiej, która została sygnowana w 2009 roku w trakcie Światowego Kongresu Rowerowego Velo-city [78], [79].

Doświadczenia zagraniczne pokazują, że promocja ruchu rowerowego może być rozpatrywana w czterech aspektach:

- prawnym, który warunkuje korzystanie z rowerów,
- technicznym, dotyczącym infrastruktury, w tym także parkingów rowerowych,
- organizacyjno-finansowym, który związany jest z realizacją programów rozwoju ruchu rowerowego,
- psychosocjologicznym i propagandowym, kształtującym wyobrażenia użytkowników i poglądy odnośnie możliwości wykorzystywania rowerów [29].

W USA zalety ruchu rowerowego wskazane zostały przez Departament Transportu Stanów Zjednoczonych (ang. *United States Department of Transportation*), który wyznaczył na początku lat 90. XX wieku także konkretny cel podwojenia odsetka podróży rowerowych, a sam rower jak i chodzenie pieszo nazwane zostały przez FHWA – Federalną Agencję Drogową (ang. *Federal Highway Administration*) – „zapomnianymi środkami transportu”. W 1991 roku ISTEA (ang. *The Intermodal Surface Transportation Efficiency Act*) zatwierdziła miliardy dolarów amerykańskich na fundusze transportowe wykorzystywane do poprawy ciągów pieszych i rowerowych oraz na promocję ruchu pieszego i rowerowego. W celu zapewnienia tego finansowania utworzono w USA kilka programów, w tym: program przeciwdziałania kongestii i poprawy jakości powietrza (ang. *Congestion Mitigation and Air Quality Improvement Program*), krajowy system funduszy drogowych (ang. *National Highway System funds*), fundusze federalne oraz program STP (ang. *Surface Transportation Program*). W wyniku tych regulacji wydatki federalne na rzecz pieszych i rowerzystów wzrosły z 6 mln dolarów amerykańskich w 1990 roku do ponad 238 mln dolarów amerykańskich w 1997 roku. W następnych latach uruchamiano kolejne fundusze na rzecz rozwoju ruchu rowerowego i pieszego, dzięki czemu w 2009 roku wysokość dotacji wyniosła 1,2 mld dolarów amerykańskich, stanowiąc ok. 2,2% wszystkich federalnych funduszy transportowych, podczas gdy w roku 1992 było to około 0,05% [80]. Innym przykładem amerykańskiego programu promującego ruch pieszy i rowerowy jest podjęty w 2005 roku i finansowany przez FHWA *the Nonmotorized Transportation Pilot Program*. Uczestniczące w nim cztery jednostki miejskie i gminne zobowiązane były do opracowania, wdrożenia i oceny programu, aby zwiększyć korzystanie z roweru i chodzenia na pieszo jako codziennych środków transportu. Każda jednostka otrzymała fundusze na sfinansowanie wszystkich działań, od programów marketingu społecznego po zwiększenie egzekwowania prawa i budowę infrastruktury dla pieszych i rowerzystów. Kolejnym programem wdrożonym w Stanach Zjednoczonych był program promujący bezpieczną drogę do szkoły, który zachęcał do chodzenia do szkoły pieszo lub do dojeżdżania rowerem. Jednym z największych wysiłków na rzecz promowania jazdy na rowerze i chodzenia w USA było przyjęcie polityki kompletnej ulicy (ang. *Complete Streets*). Ogólnym celem *Complete Streets* jest projektowanie ulic bezpiecznych i dostępnych dla wszystkich środków transportu, zamiast koncentrowania się wyłącznie na samochodach. W latach 1971-2009 przyjęto 121 kompletnych projektów ulic, zgodnych z wymogami *Complete Streets* [80].

W przypadku Unii Europejskiej polityka promująca zrównoważoną mobilność jest dość rozpowszechniona, a wiele postanowień dotyczących zrównoważonej mobilności zawartych jest w dokumentach i programach na szczeblu unijnym. To transport był jednym z pierwszych

obszarów wspólnej polityki europejskiej, a polityka transportowa jest jednym z pierwszych obszarów politycznych ujętych już w Traktacie Rzymskim, w którym państwa członkowskie podkreśliły wagę wspólnej polityki transportowej [12]. W 1990 roku w ramach programu ADONIS powstał pierwszy w Europie katalog rozwiązań dla ruchu pieszego i rowerowego [57]. W odpowiedzi na „Agendę 21” UE przyjęła tzw. Piąty Program ochrony środowiska naturalnego zatytułowany „W stronę zrównoważonego rozwoju”. Obejmował on początkowo lata 1993-1997, ale ostatecznie przedłużono go do 2000 roku. Jednym z sektorów, ujętym w programie jako mającym zasadnicze znaczenie dla rozwoju gospodarczego, a jednocześnie w sposób istotny wpływającym na środowisko, jest transport, obok energetyki, przemysłu, rolnictwa i turystyki [12]. Przez kolejne lata Unia Europejska kontynuuje politykę zrównoważonej mobilności i promocji ruchu rowerowego. W 2004 roku Wspólnota podczas konferencji ministrów transportu w Paryżu oficjalnie zaznaczyła wagę ruchu rowerowego jako praktycznego środka transportu w miastach, który cechuje się korzyściami środowiskowymi, ekonomicznymi i zdrowotnymi [81]. W 2007 roku komitet programu CIVITAS CARAVEL podjął inicjatywę opracowania Zielonej Księgi dla transportu publicznego, która opatrzona została podtytułem „W kierunku nowej kultury mobilności w mieście”, i w której wyrażone jest wsparcie konieczności redukcji liczby prywatnych samochodów w miastach, zwiększenia korzystania z transportu publicznego, poruszania się pieszo i jeżdżenia na rowerze [82]. Zielona Księga podaje kilka przykładów w jaki sposób ruch rowerowy może być promowany przez miasta, firmy czy szkoły, tj. m.in. poprzez gry związane z ruchem ulicznym, ocenę bezpieczeństwa drogowego lub pakiety edukacyjne [83]. Zrównoważona mobilność pojawia się też w kolejnych latach w dokumentach przygotowywanych przez Komisję Europejską. W 2011 roku zaaprobowala ona do wdrożenia strategię konkurencyjnego systemu transportu, który zwiększy mobilność, usunie główne bariery w kluczowych obszarach i spowoduje wzrost zatrudnienia. Strategiczne cele dotyczące rozwoju transportu w UE zostały zebrane wówczas w Białej Księdze Transportu, która nawiązuje do znowelizowanej strategii „Europa 2020” [12], [84]. Znajdują się w niej zapisy dotyczące tworzenia lepszych warunków do chodzenia na piechotę i jazdy na rowerze, które winny stanowić integralną część projektowania miejskiej mobilności i infrastruktury. W Księdze mówi się też o konieczności promowania informacji o dostępności alternatyw dla konwencjonalnego transportu indywidualnego i zachęcaniu do lepszego planowania mobilności, aby upowszechnić zachowania zgodne z zasadą zrównoważonego rozwoju [85].

Kilkanaście lat po deklaracji paryskiej, podczas nieformalnego spotkania ministrów transportu z krajów Wspólnoty w 2015 roku, w Luksemburgu przyjęto *Deklarację w sprawie transportu*

rowerowego jako transportu przyjaznego dla klimatu. Ministrowie wezwali Komisję Europejską, kraje członkowskie oraz władze lokalne i regionalne do rozważenia szeregu działań w zakresie zwiększania udziału podróży rowerowych [86]. W Deklaracji czytamy, że biorąc pod uwagę, że połowa wszystkich podróży samochodami osobowymi wykonanymi w większości europejskich miast jest krótsza niż 5 km, istnieje znaczny potencjał zwiększenia udziału podróży rowerowych, a tym samym poprawy jakości życia. Deklaracja mówi też, że wykorzystanie potencjału tkwiącego w podróżach rowerowych jest możliwe tylko przy wsparciu na wszystkich poziomach. Poprzez promowanie ruchu rowerowego w istniejących instrumentach polityki UE (takich jak: plany zrównoważonej mobilności miejskiej (ang. *Sustainable Urban Mobility Plans*), CIVITAS 2020, ELTIS, URBACT czy Europejski Tydzień Mobilności) oraz odpowiednie instrumenty finansowe (w tym: fundusze strukturalne i inwestycyjne, COSME oraz Horyzont 2020) transport rowerowy może przyczynić się do realizacji celów Komisji Europejskiej takich jak: nakłonienie do prywatnych inwestycji w setki tysięcy zrównoważonych miejsc pracy w krajach członkowskich czy zmniejszenie emisji i zwiększenie efektywności energetycznej [25]. Dokumenty Komisji Europejskiej podkreślają jednak, że w celu ograniczenia samochodów osobowych w miastach muszą być podejmowane nie tylko zabiegi zwiększające atrakcyjność transportu rowerowego i transportu publicznego, ale dodatkowo należy zadbać o komplementarność tych dwóch środków transportu [22]. Kopta (2007) wymienia cztery podstawowe formy integracji transportu zbiorowego z rowerowym, tj.:

- dojazd rowerem na przystanek komunikacji zbiorowej i kontynuacja podróży transportem zbiorowym (ang. *Bike and Ride*) – Fot. 2.2,
- dojazd transportem zbiorowym do miejsca zaparkowania roweru i kontynuacja podróży rowerem (ang. *Ride and Bike*),
- dojazd rowerem do przystanku, przewóz roweru i dojazd rowerem do celu podróży,
- dojazd rowerem do przystanku, kontynuacja podróży transportem zbiorowym do miejsca zaparkowania roweru i dojazd rowerem do celu podróży (ang. *Bike and Ride and Bike*).

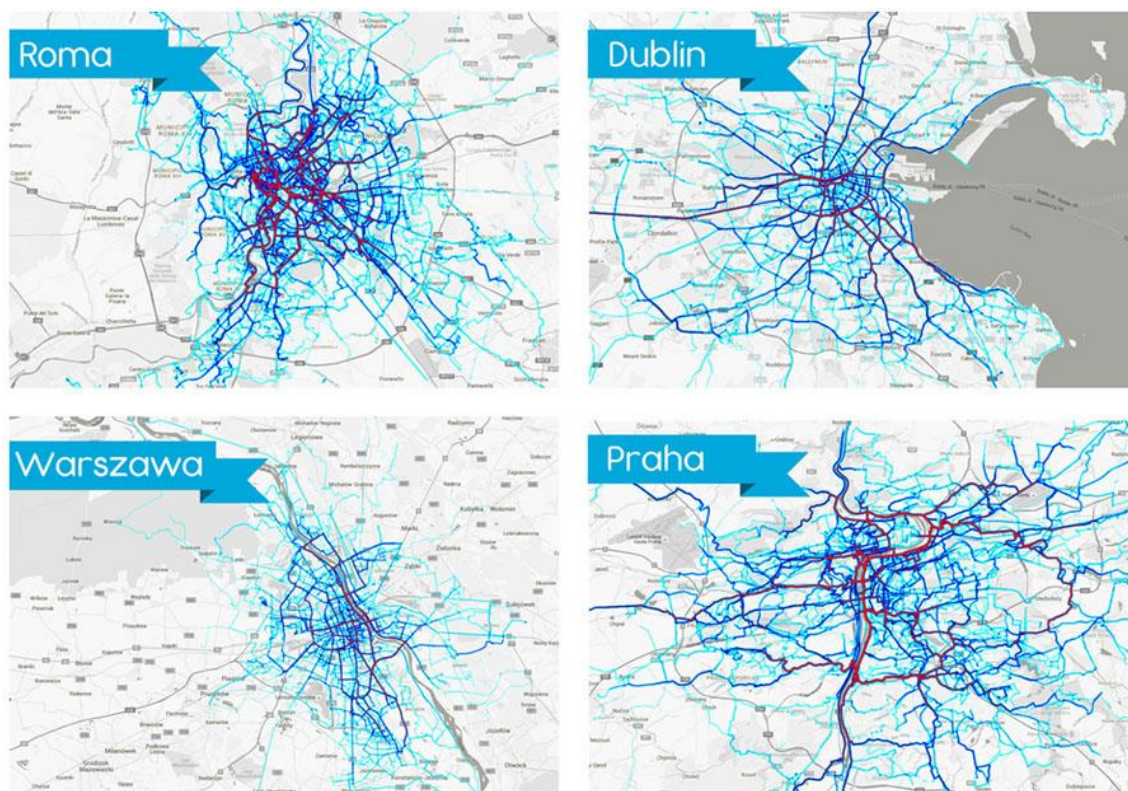


Fot. 2.2. Parkingi Bike and Ride w Monachium (po lewej) i w Krakowie przy pętli tramwajowej Kurdwanów P+R (po prawej)
(źródło:[87], [88])

Według Kopty trzecia z wymienionych opcji integracji transportu rowerowego i zbiorowego powinna najlepiej zaspokajać potrzeby społeczne i powinna być przedmiotem szczególnej troski przewoźników, zwłaszcza kolejowych, którzy powinni także zadbać o udogodnienia taryfowe dla rowerzystów [73]. Integracja transportu zbiorowego i rowerowego oznacza zatem przede wszystkim możliwość bezpiecznego pozostawienia roweru na przystankach transportu publicznego i możliwość zabrania go na pokład tramwaju czy autobusu [11], [22].

Przykładem innego programu jest BYPAD (ang. *Bicycle Policy Audit*). Jest to właściwie proces certyfikacji polityki rowerowej i narzędzie oceny polityki rowerowej oraz wypracowywania rozwiązań podnoszących jej jakość. BYPAD został opracowany przez międzynarodowe konsorcjum ekspertów rowerowych w ramach projektów finansowanych przez Komisję Europejską. Na zespół ten składają się praktycy dysponujący wiedzą na temat procedur zarządzania jakością i zasad funkcjonowania ruchu rowerowego w swoich krajach. Z programu BYPAD skorzystały także polskie samorzady, m.in. Poznań i Gdynia [89]. W Europie problematyka rozwoju i promocji ruchu rowerowego podejmowana jest nie tylko na szczeblu unijnym, np. Holandia, Dania i Niemcy posiadają swoje własne, oficjalne krajowe plany rowerowe. Każdy z tych planów określa ogólny cel, jakim jest podniesienie udziału podróży rowerowych w codziennych podróżach, przy jednoczesnym zwiększeniu bezpieczeństwa jazdy na rowerze. Proponują również różne strategie, aby osiągnąć wymienione cele: lepsze projektowanie dróg, dróg rowerowych i skrzyżowań, więcej miejsc parkingowych dla rowerów, koordynacja z transportem publicznym, kampanie bezpieczeństwa rowerowego i kampanie promujące ruch rowerowy [37]. Zalewski (1996) zwraca uwagę na fakt, że to szczebel działań lokalnych w warunkach samorządności terytorialnej spełnia najważniejszą rolę w tworzeniu optymalnych warunków dla ruchu rowerowego w konkretnym mieście czy dzielnicy, z uwagi na to, że gwarantuje on największe powodzenie podejmowanych działań [29]. Przykładem

Europejskiego projektu prowadzonego na szczeblu lokalnym jest projekt STARS (ang. *Sustainable Travel Accreditation and Recognition for Schools*), czyli zrównoważona akredytacja i identyfikacja szkół w zakresie podróżowania. Projekt ten zrzesza dziewięciu partnerów wdrażających działania wokół wspólnego celu: zwiększenia liczby uczniów podróżujących do i ze szkoły rowerem, którzy wcześniej byli dowożeni samochodem [90]. Wśród działań miękkich na szczeblu europejskim wymienić można także inicjatywę Bolonii, która w ramach unijnego programu CIVITAS w 2012 roku zorganizowała pierwszą edycję Europejskiej Rywalizacji Rowerowej (ang. *European Cycling Challenge*). Zasada rywalizacji jest prosta – wygrywa to miasto, którego mieszkańcy wyjeżdżają w maju najczęściej kilometrów na rowerach, jednak do rywalizacji nie zaliczają się aktywności o charakterze rekreacyjnym czy sportowym, gdyż rywalizacja ma na celu promocję jazdy na rowerze do pracy, szkoły czy na zakupy. Na Rys. 2.1 ukazano wyniki rywalizacji z 2017 roku dla czterech wybranych miast, w tym Warszawy, która zajęła wówczas 4. miejsce. W pierwszych dwóch edycjach zwycięstwo odniósł Tallin [92].



Rys. 2.1. Zagregowane wyniki ECC2017 dla Rzymu, Dublina, Warszawy i Pragi
(źródło: [91])

Generalna konkluzja wypływająca z prowadzonych m.in. w Europie działań na rzecz promocji ruchu rowerowego jest taka, że korzystanie z roweru jest istotnym czynnikiem kreowania nowej kultury mobilności w miastach [93].

Polska w przeciwieństwie do państw Europy Zachodniej nie posiada krajowej polityki rowerowej. Polskie prawo określa jedynie pewne minimalne wymagania dotyczące warunków technicznych i oznakowania dróg rowerowych czy też reguluje relacje pomiędzy uczestnikami ruchu [46]. Brak krajowych dokumentów dotyczących tego zagadnienia wymusił powstanie, np. Białej Księgi Mobilności, którą w 2015 roku przygotował Zespół Doradców Gospodarczych TOR we współpracy ze Stowarzyszeniem Transportu Publicznego i operatorem miejskich systemów rowerowych – firmą Nextbike. W założeniu Autorów ma ona stanowić punkt wyjścia do ogólnokrajowej dyskusji na temat zmian zachodzących w sferze mobilności i transportu publicznego [94]. Co się tyczy promocji ruchu rowerowego wśród samorządów to widoczne są powolne, lecz systematyczne zmiany świadomości, jakie następują wśród władz lokalnych. Pierwszym miastem, które w 1993 roku wprowadziło zapisy dotyczące ruchu rowerowego i rozwoju infrastruktury rowerowej do polityki transportowej, był Kraków. Władze miasta naklonione zostały do tego dzięki inicjatywom środowisk ekologicznych, które następnie zrzęsiły się pod szyldem „Kraków miastem rowerów” [95], [96]. Obecnie elementy polityki rowerowej wprowadzane są do strategii transportowych wielu miast Polski, jednak rzadko pojawiają się w nich dokumenty poświęcone bezpośrednio ruchowi rowerowemu, wyjątkiem jest m.in. Wrocław czy Łódź. Lepiej wygląda kwestia krótkoterminowych planów o charakterze operacyjnym – większość polskich dużych miast posiada dokumenty mówiące o planowanych inwestycjach rowerowych z informacją o docelowym kształcie głównych tras rowerowych oraz posiada zdefiniowane standardy wykonawcze infrastruktury rowerowej. Raport o rozwoju ruchu rowerowego w polskich miastach z 2016 roku, w którym porównano: Bydgoszcz, Kraków, Lublin, Łódź, Poznań, Radom, Szczecin, Toruń, Warszawę oraz Wrocław, zwraca uwagę, że dokumenty strategiczne związane z polityką transportową tych miast dają podstawę do rozwoju ruchu rowerowego. Mają one natomiast miękki charakter co prowadzi do rozbieżności między zapisami, a ich realizacją w praktyce. Słabością jest też fakt, że w żadnym z miast nie jest znany horyzont czasowy ukończenia systemu głównych tras, a na chwilę obecną żadne z miast nie zbliża się jeszcze do posiadania spójnego systemu głównych tras rowerowych [97].

Celem poprawy koordynacji i zwiększenia efektywności działań na rzecz rozwoju ruchu rowerowego, jak również celem lepszego uwzględnienia głosu opinii publicznej, miasta Polski przejęły rozwiązanie stosowane w miastach Europy Zachodniej, tj. powoływanie w strukturze administracyjnej specjalistów odpowiedzialnych za tematykę rowerową, którzy są potocznie nazywani „oficerami rowerowymi” (ang. *cycling officer*) [98]. Nie w każdym z większych polskich miast funkcjonuje takie stanowisko, a nawet jeśli osoba taka jest powołana to często jest to jej

zadanie dodatkowe. Są jednak takie miasta jak Kraków, Warszawa czy Wrocław, w których oficerowie rowerowi mają realną możliwość zarządzania polityką rowerową jako procesem i mają do dyspozycji zespół osób, które poświęcają się temu tematowi [97].

Problemy polskich miast, jak chodzi o rozwój infrastruktury rowerowej i tempo realizacji, potęgowane są brakiem wyraźnych i widocznych kampanii na rzecz zrównoważonego transportu, a w oficjalnych komunikatach władze miast unikają zasadniczo retoryki związanej z koniecznością ograniczania ruchu samochodowego. Działania miękkie wydają się być na pozór relatywnie mniej istotnym elementem polityki rowerowej, a ich znaczenie wobec działań inwestycyjnych zdaje się mieć znaczenie wtórne. W rzeczywistości mają one dużo większe znaczenie. Z jednej strony działania wizerunkowe są ważnym elementem całej polityki miasta, z drugiej strony aspektem nadającym wagę działaniom miękkim jest ogólnopolski problem ze społecznym poparciem dla idei zrównoważonego transportu. Jeżeli władzom miast zależy na zmianach w stronę zrównoważonej mobilności powinni oni inwestować w budowę poparcia społecznego dla tych zmian. W Polsce prym w kwestii promocji poruszania się rowerem po mieście i szerzenia idei zrównoważonego transportu wiodą w Polsce nie samorządy, a społeczne organizacje rowerowe. Miasta są na tym polu zdecydowanie bardziej powściągliwe i najczęściej ograniczają się do wspierania działań inicjowanych przez organizacje [97], w tym uczestniczą w projektach europejskich, jak np. Kraków, biorący udział w projekcie STARS, popularyzującym dojazdy na rowerze do szkoły [99]. Za miasta będące liderem w Polsce, jak chodzi o działania miękkie w zakresie ruchu rowerowego, uchodzą jednak Wrocław i Gdańsk [97]. Gdańsk to także miasto, które trzykrotnie zwyciężyło w Europejskiej Rywalizacji Rowerowej w latach: 2015, 2016 i 2017, za to w 2014 roku pierwsze miejsce zajęła Warszawa, tuż za nią Łódź [91]. Gołędziowska (2010) dostrzega, że biorąc pod uwagę sytuację polskich miast – ograniczone środki finansowe i zapóźnienia w zakresie różnych form infrastruktury transportowej – żądania środowisk promujących poruszanie się rowerem mogą wydawać się nazbyt rozbudowane. Zauważa też jednak, że gdyby nie aktywność i integracja tego środowiska, nie udałooby się osiągnąć w polskich miastach obecnego postępu w zakresie bezpieczeństwa i komfortu jazdy rowerzystów [98].

2.5. Udział podróży rowerowych we wszystkich podróżach

W podziale zadań przewozowych podróże wykonywane rowerami stanowią, w zależności od kraju, przeważnie od kilku do kilkunastu procent. Zarządzanie popytem na podróże powinno mieć na celu ograniczenie udziału samochodów osobowych w ogóle podróży i polegać na dużej liczbie małych interwencji, których kumulacja może przynieść pożądane efekty. W zestawie dobrych praktyk, które z sukcesem wpłynęły i nadal wpływają na zmniejszenie udziału samochodów osobowych w ogóle podróży w miastach, należy wymienić: parkingi *Park and Ride* oraz *Bike and Ride*, zabiegi uspokajania ruchu, priorytety dla komunikacji zbiorowej i samochodów z wyższym wskaźnikiem napelnienia, *carsharing*, wprowadzanie restrykcji parkingowych, ale także promocję ruchu rowerowego. W niektórych krajach, jak np. Holandia, już teraz rower stanowi ważny środek transportu. Efektem podjętych w Holandii zabiegów na rzecz rozwoju ruchu rowerowego jest to, że 27% wszystkich podróży związanych z dojazdami do pracy i szkoły realizowanych jest przy użyciu roweru [8], a w przypadku krótkich podróży do 5 km rower stanowi 39% w podziale zadań przewozowych [100]. Razem z podróżami pieszymi, które stanowią 22% podróży widać, że niemal połowa podróży w Holandii to podróże niezmotoryzowane. Nie wszystkie kraje zachodnie posiadają jednak takie wskaźniki jak Holandia [101]. Narodowe Badania Ruchu przeprowadzane w gospodarstwach domowych w Stanach Zjednoczonych w 2001 roku (ang. *National Household Travel Survey*) wykazało, że udział podróży rowerowych w zależności od regionu Stanów Zjednoczonych waha się od 0,4% (East South Central) do 1,1% (rejon Pacyfiku). Wyniki badań pokazały też, że ponad połowa podróży rowerowych i około jedna trzecia podróży pieszych ma charakter towarzyski lub rekreacyjny [18]. W tych samych badaniach w 2009 roku sytuacja nie uległa zmianie - średnio 1% podróży wykonywany był przy użyciu roweru, a około 11% pieszo [21]. Porównywanie Stanów Zjednoczonych z krajami azjatyckimi oraz krajami trzeciego świata pod kątem udziału podróży niezmotoryzowanych nie jest miarodajne ze względu na to, że znaczny udział podróży niezmotoryzowanych w tych krajach wynika z dużej gęstości zaludnienia oraz gorszych warunków ekonomicznych i ogólnej biedy. Potrzeba jednak innych powodów by wytłumaczyć różnice w małym udziale podróży niezmotoryzowanych w USA i innych krajach zachodnich, a wśród nich wymienić należy przede wszystkim wspomniane już podejście do projektowania nowoczesnych amerykańskich miast i dzielnic. Do tego dochodzi brak udogodnień dla rowerzystów połączony z szeregiem zachęt do korzystania z samochodu, tj. niskie ceny paliwa, bezpłatne parkingi, duża przepustowość ulic czy subsydiowane kredyty na mieszkania, na peryferiach miast [101]. Dodatkowo Kuzmyak i Dill (2012) zwracają uwagę, że w krajach europejskich częściej

wprowadzane są zabiegi uspokajania ruchu, pozwalające ruchowi niezmotoryzowanemu i zmotoryzowanemu na koegzystencję. Ponadto kraje europejskie cechuje dużo bardziej limitowana przestrzeń parkingowa połączona z wyższymi opłatami za parkowanie [21], [37].

W przypadku Europy w większości przypadków jazda na rowerze kojarzona jest z dwoma krajami i dwoma miastami: wspomnianą wyżej Holandią, a także Danią oraz ich stolicami: Amsterdamem i Kopenhagą [22]. Jest to zgodne z rzeczywistością, gdyż wśród europejskich stolic w 2015 roku to właśnie w Amsterdamie i Kopenhadze odnotowano największy odsetek osób używających rower jako środek transportu (ponad 50%) [102]. Ukształtowanie tych miast i krajów jest czynnikiem wpływającym na duży udział podróży rowerowych oraz pieszych [22], [37], [103]. Rozwój ruchu rowerowego w Kopenhadze przyspieszyła również pandemia COVID-19, dzięki której udział ruchu rowerowego w dojazdach do pracy i szkoły sięgnął poziomu 62% [104]. Okazuje się jednak, że także w tych miastach kilkadziesiąt lat temu ruch pieszy i rowerowy były wypierane przez samochody osobowe, a środowisko miejskie uległo przekształceniu, nie zachęcając do przemieszczania się pieszo czy na rowerze. W przypadku Kopenhagi osobą, która wywarła duży wpływ na zmiany w polityce transportowej jest architekt i urbanista Jan Gehl, który zapoczątkował proces odzyskiwania kopenhaskiego śródmieścia przez pieszych i rowerzystów. To on zainicjował powstanie w stolicy Danii stref pieszych. Zakończone sukcesem ich wprowadzanie, rosnąca kongestia, a także kryzys energetyczny zmieniły sposób patrzenia na politykę transportową Kopenhagi i spowodowały recesję samochodu osobowego i rozwój ruchu rowerowego. Zakrojone na dużą skalę inwestycje w infrastrukturę rowerową są kontynuowane do dnia dzisiejszego, dzięki czemu ruch rowerowy w Kopenhadze miał szansę na rozwój [103]. Rowery są jednak używane regularnie w dojazdach do pracy czy szkoły także w innych krajach europejskich. W Szwajcarii 40% podróży wykonywana jest piechotą, a 5% rowerem. W Niemczech, Finlandii, Hiszpanii i Szwecji podróże piesze to około 23% ogółu podróży, natomiast podróże rowerowe stanowią około 9% wszystkich podróży¹. W Wielkiej Brytanii wartości te wynoszą odpowiednio 24% i 2%², we Francji 19% i 3%³, w Belgii 16% i 8%⁴, w Norwegii 22% i 4%⁵. Duży udział podróży pieszych widoczny jest w Łotwie – stanowią one 30% podróży, ale podróże rowerowe stanowią tylko 5%⁶ [105]. Zestawienie powyższych danych zobrazowano na Rys. 2.2.

¹ Dane na podstawie Narodowych Badań Ruchu przeprowadzonych w latach: 2001/2002 w Niemczech, 2004/2005 w Finlandii, 2000 w Hiszpanii oraz 2005/2006 w Szwecji [105]

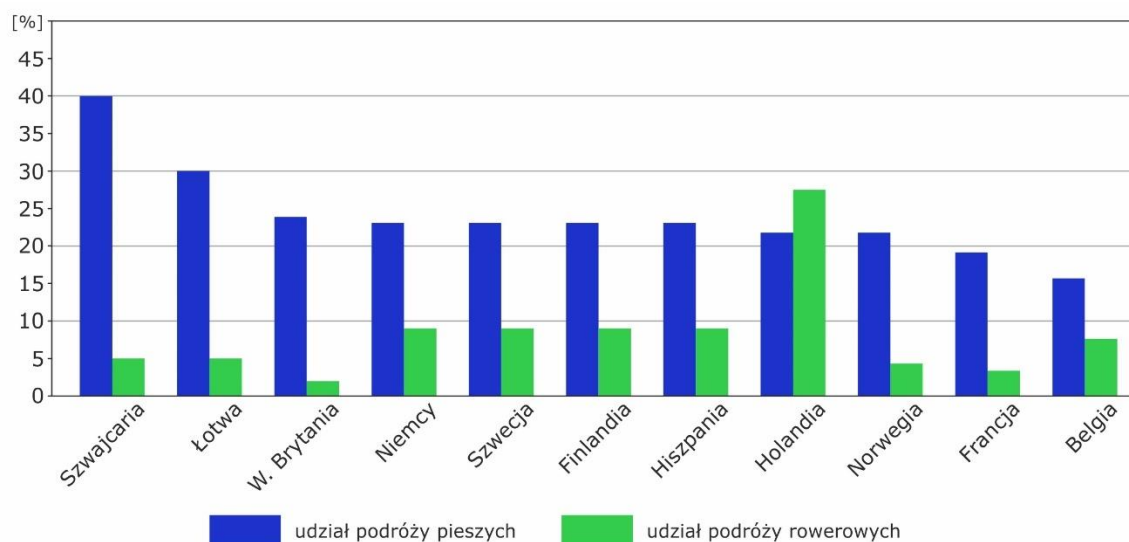
² Dane na podstawie Narodowego Badania Ruchu 2006 [105]

³ Dane na podstawie Narodowego Badania Ruchu 1993/1994 [105]

⁴ Dane na podstawie Narodowego Badania Ruchu 1998/1999 [105]

⁵ Dane na podstawie Narodowego Badania Ruchu 2001/2002 [105]


⁶ Dane na podstawie Narodowego Badania Ruchu 2003 [105]



Rys. 2.2. Udział podróży pieszych i rowerowych w krajach europejskich

(źródło: opracowanie własne na podstawie [105])

Wśród europejskich stolic, poza Amsterdamem i Kopenhagą, stosunkowo duży udział podróży rowerowych odnotowano w 2015 roku w Lublanie oraz Berlinie, gdzie co czwarty mieszkaniec wykorzystywał rower w codziennych podróżach. W pozostałych 27 zbadanych stolicach odsetek osób korzystających z roweru jako głównego środka transportu wynosi poniżej jednej piątej (w tym: Helsinki – ok. 19%, Sztokholm – ok. 18%, Dublin – ok. 18%, Oslo – ok. 16%), spadając poniżej 10% w 19 miastach i poniżej 5% w 13 miastach. W stolicy Turcji – Ankarze - udział ten wynosił mniej niż 1% [102]. Mimo to widoczna jest zależność, że kraje europejskie cechuje większy udział podróży rowerowych niż Stany Zjednoczone. Porównywalny do USA wzorzec podróżowania obecny jest w Kanadzie, gdzie zgodnie ze spisem powszechnym z 2001 roku podróże piesze to około 7% wszystkich podróży, a rowerowe 1%. Podobnie wygląda to w Australii, gdzie udział podróży rowerowych, według spisu powszechnego z 2006 roku, jest taki sam jak w Kanadzie, a podróże piesze stanowią 5% [101]. Różnica we wzorcach podróżowania uwidacznia się także podczas analizy przejechanych kilometrów na rowerze w przeliczeniu na osobę. Przeciętny mieszkaniec Holandii rocznie przejeżdża rowerem 848,0 km, Duńczyk średnio 584,0 km, Niemiec 291,0 km, Australijczyk 136,0 km, Francuz 75,0 km, a mieszkaniec Stanów Zjednoczonych 40,0 km [101]. Taka sama zależność widoczna jest także w powiązaniu motywacji związanych z pracą i szkołą, z wyborem roweru jako środka transportu, co widać na Rys. 2.3.



Rys. 2.3. Udział podróży rowerowych w wybranych krajach, w zależności od motywacji podróży
(źródło: opracowanie własne na podstawie [37])

Rys. 2.3 pokazuje, że wśród wszystkich podróży rowerowych 11% z nich w USA związanych jest z dojazdem do pracy lub szkoły, podczas gdy współczynnik ten w Niemczech wynosi 22%, w Holandii 32%, a w Danii 38%. Podróże związane z zakupami w Stanach Zjednoczonych stanowią 5% podróży rowerowych, w Niemczech 20%, w Holandii 22%, a w Danii 25% [37]. Dane te potwierdzają, że w przypadku USA trzy czwarte podróży rowerowych związanych jest z rekreacją. Udział ten jest niższy z krajach Europy Zachodniej – Niemcy: 35%, Holandia: 27% czy Dania: 24%. Te duże różnice między Ameryką Północną i Europą Zachodnią sugerują większy udział podróży rowerowych, wynikający z wykorzystywania rowerów w szerszym zakresie, zwłaszcza jeśli chodzi o codzienne podróże związane z pracą i szkołą [37].

Badania dotyczące udziału podróży rowerowych w ogólne podróży wykonywane są także w Polsce, natomiast brak jest kompleksowych danych dotyczących ruchu rowerowego w skali kraju [65]. Badanie ruchu rowerowego nie ma w Polsce ani długiej tradycji, ani ugruntowanej metodyki [79]. Problemem jest także to, że wiele gmin nie prowadzi pomiarów ruchu, a ponadto w wielu przypadkach pomiary ruchu klasyfikują ruch rowerowy jako „pojazdy inne”, np. wraz z pojazdami zaprzęgowymi. Metodyka prowadzonych w Polsce pomiarów ruchu najczęściej pomija ruch rowerowy, który odbywa się na chodnikach, drogach dla rowerów poza jezdnią i po nieformalnych trasach poza pasem drogowym. Nie mniej jednak dostępne są

wycinkowe dane, które mogą dać pewien obraz stanu ruchu rowerowego w Polsce [65]. Mimo że ruch rowerowy na drogach krajowych jest mniejszy niż na drogach powiatowych czy gminnych, to jest on w Polsce najlepiej rozpoznany. Wynika to z przeprowadzanego co 5 lat Generalnego Pomiaru Ruchu (GPR), który prócz pojazdów silnikowych uwzględnia także rowery w strukturze rodzajowej pojazdów. GPR podaje natężenia ruchu rowerowego jako średni dobowy ruch roczny (ŚDRR) w rowerach na dobę [65]. W 2005 roku według danych z GPR udział rowerów w stosunku do pojazdów samochodowych na drogach krajowych wyniósł 0,76%, w 2010 roku 0,46%, a w 2015 roku 0,30%, co uwiadcza tendencję spadkową [65], [106]. Świadczy to, że działania na rzecz poprawy warunków ruchu rowerowego, przy równoczesnym wzroście ruchu samochodowego, były zbyt słabe aby zachęcić więcej osób do jazdy na rowerze [65]. Średni dobowy ruch rowerów, w odróżnieniu od ruchu pojazdów silnikowych, każdorazowo wykazuje tendencję malejącą wraz ze wzrostem znaczenia dróg w układzie funkcjonalnym. Tym samym większy ruch rowerowy zaobserwowano na drogach wojewódzkich – podczas GPR w 2010 roku udział rowerów w stosunku do pojazdów samochodowych na drogach wojewódzkich wyniósł 2,09%, w 2015 roku 2,16% [106]. Ze względu na pandemię COVID-19 i wprowadzenie stanu epidemicznego w kraju pomiary pierwotnie zaplanowane na marzec i maj 2020 roku nie zostały przeprowadzone, a termin ich wykonania na drogach krajowych przesunięto na analogiczny okres w roku 2021. W związku z tym, wydłużeniu uległ okres na opracowanie wyników GPR 2020 [107], które nie są dostępne w trakcie przygotowywania niniejszej pracy.

Niewiele polskich miast i gmin wykonuje Kompleksowe Badania Ruchu. W związku z tym nie ma wiarygodnych informacji o udziale podróży różnymi środkami transportu, w tym o udziale roweru w podróżach miejskich i gminnych. Brak merytorycznej bazy porównawczej utrudnia jasne określenie udziału oraz wskaźnika wzrostu ruchu rowerowego w miastach. W dużych miastach ruch rowerowy kształtuje się na poziomie 1-3% podróży [65]. Rudnicki (1998) wskazał pięć koncepcji rozwoju systemu transportowego, który może być wybrany przez polskie miasta:

- pro-samochodowej,
- nadążania za rosnącymi i zmieniającymi się potrzebami użytkowników dróg z preferencjami dla samochodów,
- zrównoważonego rozwoju opartej na transporcie publicznym,
- zrównoważonego rozwoju opartej na wysokim udziale ruchu niezmotoryzowanego,
- miasta uwolnionego od samochodu, tzw. „car free city”.

Zdaniem Rudnickiego w polskich warunkach powinno się rekomendować koncepcję opartą na rozwoju transportu publicznego z tendencją do koncepcji opartej na wysokim udziale ruchu niezmotoryzowanego [108]. Wiele miast dąży do rozwoju transportu publicznego i ruchu rowerowego jednak wyniki podziału zadań przewozowych w wielu miastach nie odpowiadają postawionym przez Rudnickiego rekomendacjom.

Określenie udziału podróży rowerowych w miastach i gminach Polski jest trudne ze względu na stosunkowo niedużą liczbę badań ruchu rowerowego w miastach i gminach. Mimo to największe polskie miasta prowadzą badania ruchu rowerowego od lat. Te wykonane podczas Warszawskiego Badania Ruchu w 2015 roku wykazały, że każdego dnia roboczego z wykorzystaniem rowerów odbywa się 3,1% wszystkich podróży, za to razem podróże niezmotoryzowane stanowiły jedną piątą wszystkich podróży. W podziale zadań przewozowych w poszczególnych grupach wiekowych rower najchętniej wybierany był przez osoby w wieku 16-19 lat (4,9%), a najrzadziej przez osoby powyżej 65 roku życia (1,5%) [109]. W przypadku badań w Krakowie w 2013 roku udział podróży rowerowych wyniósł 1,2% (w 2003 roku było to 1,5%) [79]. W Gdyni udział podróży realizowanych rowerem w 2013 roku wyniósł 0,8%. Przykład Gdyni pokazuje, że rower, także w Polsce, najczęściej wykorzystywany jest w celach rekreacyjnych. Wśród wszystkich podróży rowerowych w 75% przypadków rower wybierany jest do tego celu, a zaledwie 9% osób korzystających w Gdyni z roweru wybiera rower w dojeździe do pracy [93]. Beim (2003) otrzymał podobne wyniki dla Poznania, gdzie 76% badanych wybierało rower w celach rekreacyjnych i turystycznych, a przy dojeździe do pracy i szkoły rower wykorzystywało 6,8% respondentów [46]. Kopta i in. (2009) zwracają uwagę, że w największych polskich miastach, jak Warszawa, Kraków i Poznań, najwyższe natężenia ruchu rowerowego występują na trasach dojazdowych do centrum, a dobowy rozkład natężeń ruchu rowerowego jest zgodny z rozkładem natężeń ruchu innych środków transportu, co wskazuje na znaczący udział podróży rowerem o charakterze obligatoryjnym (dojazdy do pracy, szkoły) [65]. Jedne z nowszych badań ruchu rowerowego w polskich miastach wykonane zostały w 2020 roku w Warszawie i wykonywane były w nietypowych warunkach, tj. w trakcie pandemii COVID-19, która znacząco wpłynęła na zachowania transportowe ludzi. Okazuje się, że w przypadku szczytu porannego w 32 z 36 punktów pomiarowych natężenie było niższe niż w 2019 roku. Średnio ruch w szczycie porannym spadł o 24,7%. Inaczej ma się sytuacja w przypadku szczytu popołudniowego – ruch dla godziny szczytu popołudniowego wzrósł sumarycznie o 25,2%. Jedynie w 7 punktach pomiarowych odnotowano niewiele niższe natężenia szczytu niż w 2019 roku. Może to wynikać z faktu, że w czasie epidemii bardzo dużo osób zmieniło tryb pracy na zdalny, co

przekłada się na mniejszy udział porannych podróży do pracy. Z kolei motywacje podróży popołudniowych, które często są nieobligatoryjne i niezwiązane z domem, nie zmieniły się (a wręcz mogło ich przybyć w związku z izolacją i potrzebą aktywności fizycznej) – stąd nie zaobserwowano spadku ruchu rowerowego. Wśród zaobserwowanych użytkowników ruchu ponad 65% to rowerzyści korzystający z rowerów sportowych. Z prywatnych rowerów typu „rower miejski” korzystało prawie 25% rowerzystów, a z miejskich rowerów Veturilo niewiele ponad 6%. Kierujący hulajnogami stanowili 4% użytkowników ruchu [110]. Przytoczone pomiary nie uwzględniały jednak udziału ruchu rowerowego w ogóle środków transportu. Podobne wyniki związane ze wzrostem ruchu rowerowego dzięki pandemii COVID-19 zaobserwowano również w Gdańsku i Krakowie. W pierwszym z miast w miesiącach jesiennych 2020 roku ruch rowerowy wzrósł nawet o 40% w porównaniu do analogicznego okresu poprzedniego roku, a w ciągu całego roku gdańskie liczniki rowerzystów zarejestrowały 5% wzrost ruchu rowerowego w porównaniu z 2019 rokiem [111]. W przypadku Krakowa analiza danych udostępnianych przez Zarząd Transportu Publicznego z liczników rowerowych pokazała, że w marcu 2021 roku, w porównaniu do marca 2020 roku, ruch rowerowy wzrósł o 29% [112]. Należy jednak mieć na uwadze duże ograniczenia epidemiczne w marcu 2020 roku. Nie mniej jednak powyższe dane pokazują, że pandemia sprzyja rozwojowi ruchu rowerowego. Ma to miejsce nie tylko w Polsce. Jednym ze środków ostrożności, podejmowanym przez miasta europejskie w trakcie pandemii, jest popularyzowanie właśnie transportu rowerowego. Poszerzano w tym celu istniejące ścieżki rowerowe, aby zapewnić poruszającym się po nich większy dystans oraz wytyczano nowe, nawet tymczasowe szlaki. Jak wskazuje Europejska Federacja Cyklistów (*European Cyclists' Federation*), wiele miast pracuje już nad rozwijaniem tych projektów w rzeczywistości popandemicznej [113]. Potwierdzają to dane Federacji ECF, które ukazują, że miasta na terenie Europy w 2020 roku wydały blisko 1 mld euro na związane z pandemią COVID-19 inwestycje rowerowe, od rozbudowy sieci dróg dla rowerów (których powstało łącznie ok. 1 tys. km) po działania uspokajające ruch i odzyskiwanie ulic dla pieszych.

Porównanie powyższych danych uwidacznia dużą różnicę w udziale podróży rowerowych między Polską, a krajami takimi jak Dania czy Holandia, jednak ciekawym jest, że w latach 50. XX wieku polskie miasta mogły pochwalić się udziałem podróży rowerowych taki jak dziś notowany jest w Kopenhadze czy Amsterdamie. Mowa np. o Wrocławiu, w którym udział podróży rowerowych wynosił wówczas 50% czy w Piotrkowie Trybunalskim, gdzie wartość ta oscylowała wokół 40%. Zalewski (1987) upatruje przyczynę spadku tych wartości w rozwoju nie tylko motoryzacji indywidualnej, ale też transportu zbiorowego [20]. Biernat i in. (2018)

w swoich badaniach ankietowych na temat motywacji i barier rozwoju ruchu rowerowego w Polsce otrzymali, że dla Polaków jednym z powodów stosunkowo małego udziału rowerowych podróży codziennych jest stosunkowo małe przywiązanie do tego środka transportu, niezależnie od czasu i długości podróży [114].

2.6. Parametry podróży rowerowych

Jednym z aspektów wymienianych jako powód niewyberania roweru czy dojścia pieszo jest dystans (lub towarzyszący dystansowi czynnik – czas podróży) pomiędzy źródłem, a celem podróży. Przykład Stanów Zjednoczonych pokazuje jednak, że około połowa wszystkich podróży odbywanych w kraju jest krótsza niż 4,8 km, a 28% wszystkich podróży jest krótsza niż mila (1,609 km). Wyniki te otrzymano w ramach Narodowego Badania Ruchu w 2001 roku. Pokazuje ono duży potencjał w możliwości zastąpienia wszystkich podróży zmotoryzowanych na odległość mniejszą niż mila podróżami niezmotoryzowanymi, tj. pieszymi i rowerowymi, co może przynieść duże korzyści dla czystszej powietrza i pomóc w redukcji zatłoczenia komunikacyjnego, zważywszy na fakt, że krótkie podróże wykonywane samochodem osobowym emitują więcej zanieczyszczeń na milę niż podróże dłuższe [18]. Jak chodzi o długość podróży rowerowych to na przykładzie Stanów Zjednoczonych Ohrn (1976) argumentował, że najczęściej odbywa się ich na dystansie krótszym niż 2,0 mile [49]. W 1981 roku Robinson potwierdził to, stwierdzając, że 90% podróży służbowych rowerem wynosiło 2,0 mile lub mniej, podobnie jak 84% innych podróży obligatoryjnych [36]. Wyniki te poparte są także badaniami z Kolorado w 1990 roku, gdzie podróże rowerowe w Boulder średnio odbywały się na dystansie 2,1 mili [115]. Inne badania sugerują, że podróże do pracy mogą być dłuższe. Forester (1984) stwierdził, że średnia jednokierunkowa podróż do pracy rowerem wynosiła 4,7 mili [36]. Broach i in. (2012) dowiedli, że na przykładzie Portland podróże rowerem w celu rekreacji mają średnio długość 2,2 mili, a te w celu dojazdów do pracy czy szkoły 3,7 mili [116]. Deakin (1985), powołując się na wcześniejsze prace, stwierdziła, że przeciętny dojeżdżający rowerem podróżował pomiędzy 5,0 a 6,0 milami, ale średnia długość wszystkich podróży rowerowych wynosiła od 1,0 do 2,0 mil [117]. Narodowe Badania Ruchu w USA w 2001 roku pokazały, że średnia długość podróży pieszych wynosi 0,6 mili (0,97 km), natomiast podróży rowerowych 2,0 mile (3,2 km), co potwierdza wcześniejsze badania i podkreśla duże możliwości wykorzystania rowerów w podróżach na krótsze dystanse [18].

Zgodnie z danymi zawartymi w publikacji Komisji Europejskiej z 1999 roku [22] w Europie 30% tras pokonywanych samochodem jest krótsza niż 3 km, a 50% jest krótszych niż 5 km.

Według Puchera i Buehlera (2008) w przypadku Europy duża część wszystkich podróży jest krótsza niż 2,5 km (44% w Holandii, 37% w Danii, 41% w Niemczech) [37]. W badaniach długości podróży rowerowych w krajach Europy Zachodniej wyniki pokazały, że średnia długość podróży rowerowych wynosi, w zależności od źródła danych, od 2 do 3 km [23], [100], za wyjątkiem Holandii i Danii, w których podróże te są dłuższe ze względu na prorowerową politykę oraz płaskie ukształtowanie terenu, nie mniej jednak nie należy oczekiwać by ludzie wykorzystywali rower jako środek transportu na dystanse dłuższe niż 3-5 km. W przypadku rezygnacji z samochodu osobowego w podróżach na tym dystansie i zmiany środka transportu na rower bądź odbycia podróży pieszo, w większości miast europejskich udałoby się zredukować o połowę liczbę podróży wykonywanych samochodem osobowym [23]. Sammer i Röschel (2009) podają, że w większości badań mobilności w miastach jedna piąta podróży samochodem osobowym jest krótsza niż 2,9 km, a 53% jest krótsza niż 5,8 km [118].

Jak chodzi o powiązany z dystansem podróży czas jej trwania, to Everett (1983) argumentował, że dla większości pracujących osób postrzegana strata czasu związana z dojazdem rowerem przewyższa oszczędności wynikające z niskich kosztów eksploatacji roweru, które są około ośmiokrotnie niższe na milę niż w przypadku samochodów osobowych [119], [120]. Holenderskie badania C. R. O. W. wykazały, że czas podróży ma jeszcze większy wpływ na wybór trasy niż odległość i w 50% przypadków rowerzyści wybierają trasę, która różni się mniej niż 5% od najszybszej trasy w sieci. Badania te zwracają uwagę na fakt, że z czasem przejazdu związany jest nie tylko wybór trasy, ale również organizacja ruchu, tj. obecność skrzyżowań z sygnalizacją świetlną i związana z tym konieczność hamowania. Dodatkowo dochodzi kwestia nawierzchni oraz kwestia atrakcyjności trasy. Rowerzyści często kierują się wizerunkiem okolicy i atrakcyjnością otoczenia trasy (tak zwaną mapą mentalną) – łatwo rozróżnialne trasy główne przyciągają więcej rowerzystów, nawet jeżeli nie oferują najszybszych połączeń [121]. Badania nad czasem podróży rowerowych prowadzili Nair i in. (2013), analizując dane z systemu wypożyczalni rowerowych w Paryżu. Otrzymali oni informacje, że 92% podróży jest krótszych niż 30 minut, natomiast 98% podróży jest krótszych niż 45 minut [122]. Podczas Warszawskich Badań Ruchu 2015 otrzymano wynik, że 39,9% jest krótsza niż kwadrans, 67,8% jest krótsza niż pół godziny, a podróże trwające dłużej niż godzinę stanowią 2,9% wszystkich podróży rowerowych [61].


Prócz dystansu i czasu podróży innym parametrem opisującym podróż jest prędkość: chwilowa, średnia i komunikacyjna. W obecnych warunkach prowadzenia badań podróży ciężko jest uzyskać pełne i miarodajne informacje o prędkości średniej i komunikacyjnej podróży odbywanych rowerem i porównania jej z prędkością średnią podróży wykonywanych

innymi środkami transportu. Według Kopty i in. (2012) problem jest związany m.in. z użytkownikami samochodów, którzy mają tendencję do podawania krótszych czasów podróży niż w rzeczywistości, poprzez niedodawanie do czasu podróży innych jej etapów niż sama jazda. Podczas gdy kierowca samochodu musi dotrzeć do samochodu, przygotować go do jazdy, znaleźć miejsce parkingowe i dotrzeć z parkingu do celu podróży, rowerzysta podróżuje praktycznie od drzwi źródła do drzwi celu podróży [123]. W przypadku bardziej miarodajnych danych pozyskanych z urządzeń GPS Broach i in. (2012) wykazali, że średnia prędkość komunikacyjna rowerzystów podróżujących w celach rekreacyjnych w Portland (USA) wynosi 16,1 km/h, natomiast w przypadku podróży obligatoryjnych 19 km/h [116]. Yamamoto i in. (2012) podczas badań nad prędkością komunikacyjną podróży rowerowych w Japonii otrzymali, że w ruchu swobodnym (bez oddziaływania szerokości ulicy, natężenia ruchu, sygnalizacji i innych czynników) wynosi ona 16,7 km/h, a w przypadku podróży w ruchu ulicznym wynosi 9,6 km/h [124]. Zgodnie z [125] średnia prędkość rowerzystów w krajach Europy Zachodniej wynosi 10-25 km/h. Kopta i Rudnicki (1996) podają, że prędkość komunikacyjna roweru może osiągnąć wartość 10-15 km/h. Zaznaczają oni przy tym, że prędkość komunikacyjna w ruchu rowerowym przekracza prędkość podróżną w komunikacji zbiorowej, która uwzględnia czas dojścia na przystanek, czas oczekiwania i przesiadki, osiągając wartość rzędu 10 km/h [11]. Badania prędkości średniej różnych środków transportu przeprowadzono m.in. w Poznaniu, gdzie Rakower i in. (2011) otrzymali informacje, że średnia prędkość podróży rowerem wynosi 14,23 km/h (prędkość średnia samej jazdy bez postojów wyniosła 16,49 km/h), zauważając tym samym, że wbrew pozorom średnia prędkość podróży była niższa na odcinkach wyposażonych w infrastrukturę rowerową, m.in. przez obecność większej liczby sygnalizacji świetlnych [126].

Badania prędkości chwilowej w ruchu rowerowym wykonane zostały m.in. przez Virklera i Balasubramaniana (1998), którzy zbadali prędkość rowerzystów w ramach badań nad wspólną infrastrukturą dla pieszych i rowerzystów w Columbii (USA) i Brisbane (Australia). W przypadku Columbii wyniosła ona 21,4 km/h, w Brisbane 20,7 km/h [127]. W badaniach Bernardi i Rupiego (2015) wykonanych w Bolonii wyniki były zależne od miejsca pomiaru i tego czy ruch rowerowy był odseparowany czy odbywał się razem z innymi pojazdami. Otrzymane wyniki pokazują, że w przypadku ruchu rowerowego odbywającego się po drogach rowerowych średnia prędkość chwilowa waha się od 14,6 do 18,9 km/h. W każdym z punktów pomiarowych prędkość chwilowa rowerzystów podróżujących po jezdni była większa niż tych podróżujących po drodze dla rowerów i wynosiła od 17,0 do 22,0 km/h. Okazuje się, że ta zależność jest spowodowana obecnością pieszych, którzy mieli największy wpływ na redukcję

prędkości przez rowerzystów na drogach dla rowerów (redukcja prędkości od 10 do 27%). Innym powodem zwalniania na drogach dla rowerów były zakłócenia spowodowane obecnością innych rowerzystów, które powodowały redukcję prędkości średnio o 5%. W przypadku rowerzystów poruszających się po ulicach największy wpływ na zmniejszenie ich prędkości miała obecność samochodów ciężarowych, bo aż nawet o 63% [128]. El-Geneidy i in. (2007) przy pomocy GPS zbadali średnią prędkość rowerzystów również w zależności od typu infrastruktury, otrzymując dla każdego z nich średnią prędkość około 16 km/h [129]. Parkin i Rotheram (2010) badali średnią prędkość chwilową w zależności od ukształtowania terenu. Ocenili oni dwa modele regresji liniowej prędkości i przyspieszenia, które pokazują, że wpływ spadku terenu na prędkość jest mniej wyraźny niż wpływ wzniesienia [130]. W Polsce tematem prędkości chwilowej rowerzystów zajął się m.in. Wolek (2010). Porównał on prędkość chwilową rowerzystów na wydzielonych drogach dla rowerów w trzech wybranych punktach pomiarowych we Wrocławiu, Krakowie i Warszawie. Średnie wyniki to: 19,19 km/h w Krakowie, 19,87 km/h w Warszawie oraz 21,06 km/h we Wrocławiu [131].

Podsumowaniem analizy średniego dystansu i prędkości komunikacyjnej podróży rowerowych są badania Hudsona (1978), który określił, że rower jest najszybszym środkiem transportu do 6 km. Samochód osobowy nie jest od roweru dużo wolniejszy, należy mieć jednak na uwadze dużo większą wrażliwość samochodu na kongestię [132]. Publikacja Komisji Europejskiej z 1999 roku podaje nieco inne dane niż wyniki Hudsona, mówiąc, że rower jest najszybszym środkiem transportu do 4,5 km (Rys. 2.4) [22].



Rys. 2.4. Czas podróży od drzwi do drzwi różnymi środkami transportu

(źródło: [123] na podstawie [22])

Bez względu na pewne różnice w literaturze dotyczące długości podróży, dla których czas jej trwania od drzwi do drzwi jest krótszy w przypadku roweru można stwierdzić, że w większości przypadków w obszarach zurbanizowanych na krótkich dystansach rower jest szybszy od samochodu, który zdobywa przewagę na dłuższych dystansach i na terenach niezurbanizowanych. Mając informację, że na ogół około połowa podróży w miastach dokonywanych samochodem osobowym jest krótsza niż 5 km, i wiedząc, że na odległości tej udowodniona została przewaga roweru, miasta holenderskie i niemieckie wprowadzają w swoich politykach transportowych i przestrzennych instrumenty zniechęcające do używania samochodu, a zachęcające do ruchu rowerowego. Jednym z takich instrumentów jest kreowanie „miast krótkich odległości”, polegający m.in. na spójności źródeł i celów podróży objętych podsystemem rowerowym oraz na bezpośredniości mierzonej współczynnikiem wydłużenia i opóźnienia, które powinny być minimalizowane. Do tego sieć winna być atrakcyjna, bezpieczna i wygodna [123].

Wspomniany współczynnik wydłużenia to kolejny parametr podróży rowerowych – jest to stosunek najkrótszej trasy jazdy rowerem do odległości w linii prostej. Zgodnie z zaleceniami holenderskimi dla głównych tras rowerowych powinien on być na poziomie 1,2, dla zbiorczych 1,3, a dla tras dojazdowych 1,4. Badania rozkładów wyboru tras przeprowadzone w Holandii pokazały, że 50% rowerzystów wybiera trasy, które są dłuższe mniej niż 6% od najkrótszej trasy [121]. Przykładem badań prowadzonych w Polsce dotyczących współczynnika wydłużenia w przypadku podróży rowerowych były badania Rakowera i in. (2011). Zbadali oni, że w Poznaniu współczynnik wydłużenia wynosi 1,22, będąc zbliżonym do zaleceń holenderskich [126]. Kolejny wspomniany parametr, czyli współczynnik opóźnienia związany jest z możliwością prowadzenia ruchu rowerowego bez zatrzymań i nie powinien on przekraczać na głównych trasach 15 sekund na 1 km trasy, a w przypadku pozostałych tras wartość graniczna wskazana w holenderskim podręczniku projektowania infrastruktury rowerowej to 20 sekund na 1 km trasy [121]. W badaniach w Poznaniu wyniósł on 154 sekundy na trasie liczącej 4,28 km, tj. 2,4 raza więcej niż wartość zalecana. Wyniki te pokazują, że mimo niewielkiego współczynnika wydłużenia trasy pojawiające się na niej przeszkody powodują zbyt duże opóźnienia ruchu rowerowego [123], [126]. Z kwestiami opóźnienia i wydłużonego czasu podróży związana jest także możliwość analizy innego wskaźnika, czyli analiza czasu postojów w ramach podróży [133].

2.7. Pomiary i prognozowanie ruchu rowerowego

Rozwój ruchu rowerowego w miastach skłania planistów do uwzględniania rowerów w procesie planowania systemów transportowych tych obszarów [26]. Zalecenia holenderskie wskazują kolejne kroki w planowaniu rozwoju sieci rowerowej w mieście. Po wykonaniu inwentaryzacji stanu istniejącego i konsultacji z zainteresowanymi i ze stowarzyszeniami rowerowymi mówią one o konieczności wykonania badań źródeł i celów podróży oraz przepływów ruchu, na podstawie których powinien zostać wykonany i skalibrowany model ruchu, który winien służyć do przygotowania projektu sieci rowerowej [121]. Niestety ruch rowerowy ze względu na swoją sezonowość i losowość wyboru jako środka transportu, a także zależność popytu od warunków pogodowych nie jest łatwy do prognozowania i modelowania. Problemem jest także wykonanie rzetelnych badań ruchu rowerowego. Pomimo zaleceń do wykonywania badań ruchu rowerowego jedną z tendencji, wymienianą w literaturze krajowej i zagranicznej, jest tworzenie układów ruchu rowerowego, które stanowią integralną część systemu transportowego obszaru zurbanizowanego bez wykonywania prognoz ruchu [26], [134]. Ruch pieszy i rowerowy od dziesięcioleci jest zaniedbywany podczas przygotowywania prognoz popytu na podróże. Miasta rozpoczynające prace nad przebudową swoich systemów transportowych, chcąc wspierać ruch pieszy i rowerowy, napotykają na niewystarczające fundusze, które nie są w stanie pokryć kosztów potrzebnych ulepszeń infrastrukturalnych. Planiści zaczęli szukać sposobów ustalania priorytetów, a jednym z nich jest przewidywanie popytu czy bazowanie na aktualnych danych. Podczas planowania urządzeń rowerowych lub pieszych należy mieć na uwadze, że obecne natężenia zwykle nie odzwierciedlają popytu z dwóch powodów: istniejące warunki i luki w sieci skutkują mniejszą liczbą użytkowników - potencjalni użytkownicy są zniechęceni przez niebezpieczne warunki, a rozproszona zabudowa tworzy odległości podróży, które są postrzegane jako zbyt długie do pokonania ich pieszo lub rowerem. Turner i in. (2006) podają dwie metody określania popytu na infrastrukturę pieszą i rowerową: podejście intuicyjne oraz wykorzystanie modeli prognozowania popytu. Intuicyjne podejście jest mniej czasochłonne, nie zapewnia jednak dokładnych wyników i zazwyczaj koncentruje się jedynie na odległości między źródłami, a celami podróży, ponieważ to ona jest podstawowym czynnikiem w początkowej fazie podejmowania decyzji o wyborze pójścia pieszo lub rowerem jako środka transportu. Drugą wymienioną przez Turner i in. (2006) metodą szacowania ukrytego popytu na ruch pieszy i rowerowy jest dostosowanie konwencjonalnej teorii prognozowania popytu na podróże zmotoryzowane tak, aby dotyczyła ona podróży rowerowych i pieszych, np. wykorzystując model grawitacyjny, co jest bardziej precyzyjne niż podejście intuicyjne [18].

W przypadku braku badań na temat ruchu rowerowego wytyczne holenderskie mówią o możliwości prognozowania ruchu w oparciu o zmienne objaśniające rejonów komunikacyjnych dotyczących liczby mieszkańców, miejsc pracy czy miejsc w szkołach. Dzięki ich znajomości możliwe jest wykrycie lokalnych zmienności i pozyskanie informacji na temat ruchu rowerowego. Wytyczne te podają również, że częstą praktyką prognozowania wielkości popytu na podróże rowerowe jest tworzenie macierzy podróży rowerowych na podstawie ogólnego modelu podróży, w którym znane są wartości dotyczące liczby podróży między każdą parą rejonów komunikacyjnych. Poprzez szacowanie proporcji udziału ruchu rowerowego w całości strumienia podróży możliwe jest określenie liczby podróży rowerowych w każdej relacji [121]. Metodę taką wymienia także Zalewski (2009) [26]. Inny model szacowania popytu na podróże rowerowe pojawił się w studium wykonalności dla tras rowerowych w województwie świętokrzyskim w 2012 roku. W przygotowanym opracowaniu ruch rowerowy mieszkańców w obszarach zurbanizowanych oraz niezurbanizowanych jest funkcją liczby mieszkańców korygowaną wskaźnikiem ruchliwości rowerem oraz średniorocznym wykorzystaniem roweru. Zauważono, że ruchliwość rowerem zależy od stopnia rozwoju komunikacji publicznej, przy czym jest on większy dla miast bez dobrze rozwiniętej komunikacji publicznej oraz terenów niezurbanizowanych, a niższy dla miast z dobrze rozwiniętą komunikacją publiczną [135].

W ostatnich latach obserwowany jest wzrost zainteresowania wykorzystania roweru w codziennych podróżach, czego odzwierciedleniem jest uwzględnianie tego środka transportu w badaniach ruchu i planach transportowych. Kuzmyak i Dill (2012) zwracają uwagę, że brak danych na temat natężeń ruchu pieszego i rowerowego hamuje samorządy, jednostki badawcze i biura projektowe przed zaplanowaniem bardziej efektywnych udogodnień i poprawą bezpieczeństwa pieszych i rowerzystów. Luka w postaci braku miarodajnych informacji o ruchu pieszym i rowerowym uniemożliwia też zaprojektowanie infrastruktury, która odpowiadałaby oczekiwaniom pieszych i rowerzystów oraz stopuje możliwości poprawy metod przewidywania wypadków z ich udziałem [21]. Wyszomirski i Hebel (2015) zwracają uwagę także na fakt, że badania ruchu rowerowego powinny być wykonywane regularnie według tej samej metodyki, co pozwoli na ustalenie zmian w zakresie korzystania z roweru przez mieszkańców. Ważne jest również, by ustalić cele podróży, w których wykorzystywany jest rower. Na tej podstawie można bowiem zaplanować sposób kształtowania systemu transportowego miasta, a dodatkowo badania takie powinny też poprzedzać wdrożenie systemu roweru miejskiego, gdyż umożliwiają określenie potencjalnego popytu na taki system oraz pozwalają na wstępną weryfikację proponowanych zasad jego

funkcjonowania [93]. Inni badacze jak Aultman-Hall wraz z Dowdsem i Lee (2012) idą dalej, twierdząc, że nie tylko ruch pieszy i rowerowy powinien być brany pod uwagę w modelach podróży, ale powinno się dążyć do zwiększenia liczby uwzględnianych niezmotoryzowanych środków transportu (tj. skutery, rolki, deskorolki czy wózki dziecięce i wózki dla niepełnosprawnych) [136]. Pozyskanie informacji na ich temat napotyka te same problemy jakie są spotykane w pozyskiwaniu informacji na temat ruchu pieszego i rowerowego.

Nowe techniki wykorzystujące systemy informacji geograficznej (ang. *GIS – Geographic Information System*) i dane na poziomie działek (ang. *parcel-level data*) zaczynają wyodrębniać i określać ilościowo rolę charakterystyk zagospodarowania terenu, takich jak: gęstość zabudowy, jej polifunkcyjność, dostępność do różnych środków transportu i sposób zagospodarowania przestrzeni na zachowania komunikacyjne, w szczególności związane z podróżami pieszymi i rowerowymi. Wiele samorządów przekształca swoje modele podróży tak, by pracować z użyciem mniejszych rejonów komunikacyjnych i zawrzeć charakterystyki zabudowy z włączeniem ruchu pieszego i rowerowego jako środki transportu. Modele bazujące na aktywnościach oraz te bazujące na przemieszczeniach umożliwiają analizę na poziomie tzw. *parcel points*, jednakże mogą nie być dostępne na poziomie krajowym przez lata. Najbardziej obszerne dane o ruchu pieszym i rowerowym pochodzą zwykle z przeprowadzanych w gospodarstwach domowych Kompleksowych Badań Ruchu wykonywanych na poziomach lokalnych i regionalnych [21], [93]. Badania te pozwalają na uzyskanie pełnych danych socjodemograficznych i informacji z dziennika podróży ze stosunkowo dużej próby gospodarstw domowych, które są wybierane tak, by były reprezentatywne dla danego obszaru [21]. Zalecenia holenderskie także mówią, że idealnymi danymi dla modelu ruchu rowerowego są rezultaty badań domowych, poparte informacjami zebranymi z badań ulicznych. Dzięki nim może powstać dobrej jakości więźba ruchu rowerowego, oparta na obserwowanym rozkładzie podróży [121]. Dalej jednak najpopularniejszą metodą pozyskiwania informacji o ruchu pieszym i rowerowym jest liczenie pieszych i rowerzystów w terenie, jednakże ich wartość, jak chodzi o zrozumienie zachowań komunikacyjnych pieszych i rowerzystów, jest ograniczona. Badania te umożliwiają określenie danej aktywności w objętym badaniem miejscu, aczkolwiek nie dają żadnych informacji na temat tego kto odbywa podróż, w jakiej motywacji, z jakiego źródła i do jakiego celu oraz czy alternatywne trasy były dostępne. Brak tych informacji uniemożliwia uzyskanie realistycznych szacunków popytu na podróże piesze i rowerowe [21]. Tego typu metoda pozyskiwania danych pokazuje w niewielkim stopniu obraz podróży rowerowych w danym mieście, jako że pomiary wykonywane są np. tylko na głównych skrzyżowaniach i przy określonych obiektach

w określone dni przez określony czas. Rozpowszechnianie i wykorzystanie zebranych w ten sposób danych jest często ograniczone [136]. Założenia C. R. O. W. w przypadku badań natężenia ruchu w punktach pomiarowych sugerują, by podczas takich badań zatrzymywać rowerzystów i zadawać im pytania dotyczące źródeł i celów podróży [121].

Do niedawna osiągnięcie dokładnych szacunków popytu na ruch rowerowy było bardzo trudne ze względu na brak danych, ale obecnie obserwujemy gwałtowny wzrost dostępności danych o popycie na podróże rowerowe. Nowe wyczerpujące zbiory danych jako dodatek do klasycznych metod obejmują: zautomatyzowane liczniki (Fot. 2.3), ogólnodostępne ślady GPS (ang. *crowdsourc*e) i dane dotyczące użytkowania rowerów [112], [137].



Fot. 2.3. Licznik rowerowy w Warszawie

(źródło: [138])

Nowe, bardziej zaawansowane technologie zliczania pieszych i rowerzystów mają swoje określone możliwości i ograniczenia. Narzędzie te obejmują czujniki mikrofalowe i podczerwone, urządzenia pneumatyczne i wrażliwe na nacisk pętle indukcyjne, liczniki piezoelektryczne oraz sprzęt do przetwarzania obrazu wideo. Różnią się one pod kątem dokładności, ustawień i czasu, w którym efektywnie rozróżniają pieszych i rowerzystów od innych użytkowników. Urządzenia na podczerwień nie rozróżniają pieszych i rowerzystów od innych poruszających się obiektów i mogą być zalecane tylko w przypadku istnienia fizycznej separacji między użytkownikami systemu transportowego, np. wydzielone drogi dla rowerów.

W konsekwencji urządzenia te nie nadają się do pomiarów ruchu mieszanego. Innym przykładem są czujniki wrażliwe na nacisk, które mogą nie być odpowiednie w warunkach zimowych gdy śnieg i lód zmniejszają czułość sprzętu. Niektóre wady urządzeń do zliczania pieszych i rowerzystów mogą być niwelowane poprzez wdrażanie ich w sposób innowacyjny czy poprzez montowanie kilku z nich jednocześnie.

Poza wymienionymi narzędziami istnieją także inne metody i technologie w zakresie zliczania pieszych i rowerzystów, dające również możliwość pobierania danych z bieżących źródeł. Obejmują one: pasywne przetwarzanie sygnału z mobilnych urządzeń pieszych i rowerzystów (wyodrębnienie lokalizacji pieszych i rowerzystów poprzez śledzenie ich telefonów komórkowych lub innych sygnałów cyfrowych), aktywne aplikacje do rejestrowania tras i zachowań (np. śledzenie zarejestrowanych użytkowników za pomocą internetowych aplikacji społecznościowych) oraz pasywne przetwarzanie obrazu wideo (z wykorzystaniem oprogramowania do analizy nagrań wideo z istniejących kamer). Wykorzystanie istniejących kamer do pomiaru ruchu pieszego i rowerowego jest dość atrakcyjnym rozwiązaniem ze względu na coraz większą popularność systemów monitoringu miejskiego. Niestety ma to również swoje ograniczenia wynikające z rozmieszczenia kamer i ich kierunku, na który są zorientowane. Jeśli nie są one ustawione wyłącznie w celu monitorowania aktywności pieszych i rowerzystów kąt widzenia lub oświetlenie mogą być nieodpowiednie w celu uzyskania pełnych i dokładnych danych [136]. Kuzmyak i Dill (2012) punktują odczyty ścieżek GPS jako obiecującą technikę zbierania danych o ruchu rowerowym. Ponadto zwracają uwagę na istotny fakt o danych na temat podróży rowerowych, a mianowicie większość danych daje jedynie informacje o osobach już wykorzystujących rower jako środek transportu. W przypadku gdy celem jest zwiększenie udziału podróży rowerowych należy pozyskać jak najwięcej danych na temat osób, które nie wybierają roweru jako środka transportu, gdyż będą one prawdopodobnie różnić się od tych, którzy już teraz wybierają rower w codziennych podróżach i zachęcenie ich do zmiany środka transportu najprawdopodobniej wymagać będzie odmiennego podejścia [21].

Obecnie jedną z możliwości pozyskiwania dużej ilości informacji o ruchu rowerowym jest analiza danych z systemów miejskich wypożyczalni rowerowych [122]. To źródło danych wpisuje się w definicję dużych zbiorów danych (ang. *big data*). Potencjał systemów wypożyczalni rowerów jako źródła danych o dynamice miasta i zagregowanych zachowaniach ludzkich wskazał m.in. Froehlich i in. (2009), zwracając tym samym uwagę na konieczność „wyczyszczenia” pozyskanych danych [139].

2.8. Modele ruchu rowerowego

Zgodnie z definicją pojawiającą się u Barceló (2010) system jest złożoną jednością, utworzoną z wielu często różnych części, podlegających wspólnemu planowi lub służących wspólnemu celowi. System to inaczej agregacja lub zbiór obiektów połączonych w regularną interakcję lub współzależność. Należy podkreślić, że ta koncepcja systemu zakłada holistyczne podejście. Innymi słowy, kładzie nacisk na funkcjonalne związki pomiędzy częściami i całością, zakłada, że całości nie można sprowadzić do sumy ich części lub alternatywnie, że system jest czymś więcej niż zwykłą sumą jego części. Przykładem systemu, który cechują aspekty wspomniane w powyższych definicjach jest system transportowy. Z pojęciem systemu wiąże się definicja modelu systemu. Aby go zbudować, najpierw musimy zdobyć wiedzę na temat systemu, jego działania, założeń, które zwykle przyjmują formę zależności matematycznych lub logicznych. Te matematyczne i logiczne relacje stanowią formalną reprezentację, którą nazywamy modelem systemu, i która jest zaprojektowana w celu wspomaganie analityków danego systemu w odpowiadaniu na pytania dotyczące tego systemu. Dlatego też w zależności od problemu, przekonań analityka i rodzaju pytań, na które należy odpowiedzieć, ten sam system można modelować na różne sposoby. Systemy komunikacyjne są dobrym przykładem wielorakiej natury modelowania [140]. Dodatkowo mogą one być analizowane w różnej skali. Modele, które przewidują ruch w dużej sieci nazywa się modelami „makroskopowymi”. Druga grupa to „mikroskopowe” modele ruchu. Są one głównie stosowane do uszczegóławiania analiz wykonywanych w modelach makroskopowych [141]. Są często wykorzystywane do oceny proponowanych środków inżynierii ruchu i inteligentnych systemów transportowych (ITS, ang. *Intelligent Transport Systems*) przed ich wdrożeniem [142].

Cascetta (2009) definiuje system transportowy jako zbiór elementów i interakcje między nimi, które powodują zarówno zapotrzebowanie na podróże w obrębie danego obszaru, jak i świadczenie usług transportowych w celu zaspokojenia tego popytu [143]. Barceló (2010) uznaje, że dwoma głównymi komponentami systemu transportowego są: popyt na podróże oraz przepustowość sieci transportowej. Aby móc ukończyć proces budowania modelu zgodnie z proponowanym podejściem systemowym, musimy być w stanie sformalizować zależności między przepustowością a popytem. Aby modelować tę interakcję, podstawową hipotezą jest to, że użytkownicy systemu transportowego podróżują ze źródeł do celów podróży wzdłuż dostępnych łączących je tras, co wymaga zamodelowania tego jak podróżujący wybierają swoje trasy przejazdu przez sieć. Hipoteza modelowania, która wspiera główne modele transportu, opiera się na koncepcji równowagi, zakładającej, że podróżni starają się

zminimalizować ich indywidualne czasy podróży, to znaczy, że wybierają te trasy, które postrzegają jako najkrótsze w panujących warunkach drogowych [140].

W odniesieniu do podsystemu pieszego i rowerowego konwencjonalne źródła danych oraz modele podróży ograniczają planistów i decydentów, nie pozwalając na pełne włączenie do procesu planowania polityki pieszej i rowerowej. Znane makroskopowe modele podróży stosowane przez jednostki samorządowe (jak np. model czterostadiowy [144]) często nie uwzględniają chodzenia na pieszo i rowerem jako środków transportu w procesie planowania. Do tego rejonu komunikacyjne w modelach są zbyt duże aby odnosić się do charakterystyki zabudowy oraz do przemieszczeń na krótsze odległości, które są właśnie często podróżami rowerowymi bądź pieszymi [21]. Hottenstein i in. (1997) podkreśla ważność wykonywania modeli ruchu rowerowego z racji możliwości ich wykorzystania do oceny przyszłych potrzeb i zaplanowania infrastruktury rowerowej oraz zmierzania wpływu zwiększenia udziału podróży niezmotoryzowanych na wybór innych środków transportu [145]. Proulx i Pozdunkhov (2017) zwracają uwagę, że popyt na podróże rowerowe nie musi być modelowany, a można bazować jedynie na obserwacjach, jednak bezpośrednia obserwacja jest praktycznie ograniczona do małego podzbioru połączeń/skrzyżowań sieci ze względu na koszt pozyskania danych. Aby określić warunki dotyczące całej sieci wskazują oni jednak konieczność modelowania ruchu rowerowego [137]. Fenton i in. (2018) zwracają uwagę, że ze względu na swoją złożoność ruch pieszy i rowerowy są trudniejsze do modelowania. Zachowanie ruchu pojazdów zmotoryzowanych na drogach jest relatywnie jednorodne – samochody zazwyczaj pozostają w obrębie zdefiniowanej sieci ulicznej i poruszają się w tym samym kierunku i z podobną prędkością. Piesi i rowerzyści mają znacznie więcej swobody poruszania się i są stosunkowo heterogeniczni. Kolejny aspekt problematyki modelowania ruchu pieszego i rowerowego to ich koszty. Jednym z podstawowych założeń tradycyjnego modelowania transportu jest stwierdzenie, że ludzie zachowują się jak racjonalni ekonomiczni gracze, co oznacza, że wybierają trasę podróży o najmniejszym koszcie. Oblicza się je na podstawie kosztów finansowych (koszt na kilometr przejazdu samochodem, opłata za transport publiczny), kosztów zależnych od czasu podróży (obliczanych poprzez zastosowanie standardowego kosztu na godzinę do czasu podróży), czy dodatkowych „kar”, aby odzwierciedlić preferencje użytkowników (np. kary czasowe za podróż z przesiadką aniżeli podróż bezpośrednią). Ta metoda znajduje uzasadnienie przy porównaniu podróży samochodem z podróżą środkami transportu publicznego, ale nie sprawdza się w przypadku podróży pieszych i rowerowych. Piesi i rowerzyści przy wyborze środka transportu biorą pod uwagę m.in. ukształtowanie terenu, bezpieczeństwo czy scenerię, a prosty model oparty wyłącznie na czasie i koszcie

podróży nie uwzględnia tych czynników, a także nie jest wystarczająco wrażliwy na ulepszenia w ruchu pieszym i rowerowym. Brak możliwości przeprowadzenia dokładnej analizy korzystnego wpływu ruchu pieszego i rowerowego na transport spowodował, że wiele miejskich projektów z zakresu ruchu pieszego i rowerowego nie zostało wdrożonych, a w rezultacie liczba uczestników ruchu pieszego i rowerowego zmalała. Pozbawiło to miasta skutecznych środków ograniczania zatorów komunikacyjnych. Projekt FLOW⁷ pozwolił udoskonalić techniki oceny korzystnego wpływu ruchu pieszego i rowerowego na ograniczenie korków ulicznych rozwiązał ten problem poprzez opracowanie nowych podejść do planowania transportu miejskiego [146].

Landis (1996) wskazuje, że w przeciwieństwie do prognozowania popytu i modelowania podróży zmotoryzowanych, w których używa się klasycznego modelu czterostadiowego, prognozowanie popytu i modelowanie podróży rowerowych opiera się w dużej mierze na metodach liniowych z lat 30. XX wieku [147]. Przegląd literatury krajowej i zagranicznej dotyczącej modelowania ruchu rowerowego rzeczywiście pozwala stwierdzić, iż najczęściej ruch rowerowy analizowany jest przy użyciu klasycznych modeli prognostycznych: modeli liniowej i nieliniowej regresji jednokrotnej bądź wielokrotnej, modeli transformacji logitowej (binarne lub wielokrotne), modeli maksymalizacji entropii oraz rozwinięcia w szereg Taylora. Pierwsze dwie grupy służą do przewidywania ruchliwości rowerowej, tj. liczby podróży wykonywanych rowerem na mieszkańca w ciągu doby, bądź do określania udziału ruchu rowerowego w podziale zadań przewozowych. Model maksymalizacji entropii wykorzystuje się w dużej mierze do modelowania wyboru roweru jako środka transportu, a także do modelowania rozkładu przestrzennego ruchu rowerowego. Szereg Taylora pozwala na oszacowanie zmiany ruchliwości rowerowej osób w danym okresie czasu w zależności od motywacji podróży i konkurencyjnych środków lokomocji [46]. Xu i in. (2013) zauważają, że w związku z dużą złożonością, nieliniowością i niepewnością przepływu ruchu, model regresji pojedynczej nie jest w stanie zapewnić dokładności i wydajności. Aby przezwyciężyć braki tej metody, proponują oni użycie modelu hybrydowego, który łączy klasteryzację z maszyną wektorów nośnych, wykorzystując komplementarne zalety obu podejść [148]. Landis (1996) do wykorzystania w modelowaniu ruchu rowerowego wskazuje model LDS, tj. probabilistyczny model grawitacyjny. Różni się on od klasycznego modelu czterostadiowego tym, że podczas gdy model czterostadiowy wymaga obszernego kodowania sieci i algorytmów do symulacji podróży między generatorami, a atraktorami, model LDS szybko szacuje

⁷ projekt Komisji Europejskiej w zakresie badań i innowacji realizowany w latach 2015-2018

prawdopodobieństwo podróży rowerowych w oparciu o bliskość, częstotliwość i wielkość sąsiednich generatorów i atraktorów podróży rowerowych [147]. W przypadku badań nad modelem ruchu rowerowego dla Poznania w modelu regresji wielokrotnej liniowej i modelu regresji wielokrotnej kwadratowej istotne okazały się tylko: liczba podróży pieszych oraz liczba posiadanych rowerów. Statystycznie istotne w przygotowanych modelach nie były m.in.: współczynnik motoryzacji czy średnia długość jazdy samochodem. Beim (2003) określił, że dla Poznania ruch rowerowy opisywany jest najlepiej przez model logistyczny [46].

Powiązany z modelowaniem ruchu rowerowego model wyboru ścieżki był poruszany w literaturze pod kątem wpływu cech infrastruktury na wybór trasy przejazdu. Pojawiają się badania na poziomie agregacji i dezagregacji. Badania na poziomie zagregowanym koncentrują się na analizie zależności między charakterystyką trasy rowerowej i zagregowanymi miarami ruchu rowerowego na danych trasach. Badania na poziomie dezagregacji związane są z przeprowadzaniem analizy na poziomie poszczególnych rowerzystów, zamiast korzystać ze zagregowanych zmiennych zależnych. Oddają one według Sener i in. (2009) podstawową zależność behawioralną między preferencjami wyboru trasy i determinantami tego wyboru. W konsekwencji oznacza to, że przy analizie wyboru tras przez rowerzystów powinno się dokonywać identyfikacji atrybutów infrastruktury rowerowej, które są istotne dla rowerzystów, i szukać zależności między nimi. Dotychczasowe badania identyfikowały cechy infrastruktury rowerowej i oceniały bezwzględną i względną ważność tych atrybutów. Ich wpływ na wybór ścieżki przejazdu może być łagodzony wskaźnikami demograficznymi oraz cechami rowerzystów. Sener i in. (2009) wymieniają 6 grup wskaźników, które mogą być brane pod uwagę w rozpatrywaniu wyboru trasy przejazdu przez rowerzystów. Pierwsza grupa to charakterystyki opisujące rowerzystę, takie jak: wiek, płeć, zawód, doświadczenie w ruchu rowerowym. Drugą grupę stanowią kwestie związane z parkowaniem przyulicznym, tj.: rodzaj parkowania, wskaźnik rotacji, wskaźnik napelnienia parkingów czy długość parkingu. Kolejna grupa to czynniki związane z udogodnieniami dla rowerzystów, wśród których Sener i in. (2009) wymieniają ciągłość oraz typ trasy, tj. czy jest to wydzielona droga dla rowerów czy szeroki, zewnętrzny pas jezdni (ang. *wide-outside lane*) umożliwiający ruch dwójki rowerzystów i samochodu obok siebie lub rowerzysty i samochodu ciężarowego. Czwarta grupa to fizyczne charakterystyki drogi takie jak: klasa drogi, liczba znaków „stop”, sygnalizacji świetlnych i skrzyżowań. Piątą grupę stanowią funkcjonalne atrybuty drogi: natężenie ruchu oraz ograniczenie prędkości, a ostatnią eksploatacyjne charakterystyki drogi, np. czas podróży [43]. Zalewski (2009) zwraca uwagę, że należy mieć na uwadze fakt, iż rowerzyści silnie preferują poruszanie się po trasach jak najkrótszych, co stanowi przesłankę do modelowania rozkładu

ruchu rowerowego na sieć. W tym wypadku najodpowiedniejsza jest metoda „wszystko albo nic” obciążająca całym potokiem ruchu najkrótszą trasę między dwoma określonymi punktami ruchotwórczymi [26].

Powyższe atrybuty i ich wpływ na wybór trasy przez rowerzystów były poruszane w literaturze wielokrotnie. Lott i in. (1978) zajęli się ruchem rowerowym w Davis (USA) i wpływem rodzaju trasy rowerowej i jej bezpieczeństwa na wybór trasy przejazdu [149]. Bovy i Bradley (1984) analizowali trasy przejazdu pracowników do Uniwersytetu w Delft (Holandia), skupiając się na: rodzaju trasy, nawierzchni, natężeniu ruchu i czasie przejazdu [150]. Axhausen i Smith (1986) w swoich badaniach preferencji rowerzystów w Mumbaju (Indie) zajęli się wyborem trasy przejazdu przez rowerzystów wybierających rower w ruchu codziennym i rekreacyjnym. W swoich analizach uwzględnili: doświadczenie w ruchu rowerowym, rodzaj trasy, nawierzchnię, otoczenie trasy, zagospodarowanie terenu oraz natężenie ruchu [45]. W 1992 roku w Calgary (Kanada) przeprowadzono badania preferencji rowerzystów w ruchu codziennym, których celem było lepsze zrozumienie potrzeb rowerzystów dotyczących infrastruktury. Zbadano wpływ rodzaju trasy, udogodnień związanych z parkowaniem rowerów, natężenia ruchu oraz pogody [151]. Antonakos (1994) zajął się ruchem rekreacyjnym w Michigan (USA) i zbadał preferencje rowerzystów, czego efektem była analiza opisowa. Dane do badań zebrane zostały w ramach ankiety. Atrybuty, które wziął pod uwagę to: wiek, płeć, dostępność do samochodu i roweru, doświadczenie w ruchu rowerowym, ciągłość i typ trasy rowerowej, jej nawierzchnię, ukształtowanie terenu, scenerię, liczbę zatrzymań, znaków drogowych, natężenie i prędkość ruchu, dystans oraz czas podróży [152]. Davis (1995) badał ruch rowerowy w Atlancie (USA), a dokładnie wpływ warunków drogowych na ruch rowerowy, biorąc pod uwagę: obecność parkowania przy ulicy, rodzaj trasy rowerowej, nawierzchnię, obecność skrzyżowań, odległość między nimi i ich konfigurację, otoczenie drogi, zagospodarowanie terenu oraz prędkość ruchu [153]. Guttenplan i Patten (1995) na Florydzie (USA) zbadali wskaźniki wpływające na wybór szlaków rowerów, rozpatrując typ trasy rowerowej, obecność udogodnień związanych z parkowaniem roweru, obecność przysznica oraz czas jazdy [154]. Hopkinson i Wardman (1996) dzięki pozyskaniu danych z badań preferencji oraz badań w gospodarstwach domowych w Bradford (Wielka Brytania) przeprowadzili analizę ruchu rowerowego pod kątem szacowania popytu i wyboru ścieżki. Jako wskaźniki przyjęli: wiek, płeć, dostęp do samochodu i roweru, doświadczenie w ruchu rowerowym, podawane powody wyboru roweru, typ trasy drogowej oraz koszt i czas podróży [155]. Aultman-Hall (1996) w ramach rozprawy doktorskiej zajęła się dojazdami do pracy i szkoły na rowerze w Ontario (Kanada), bazując na danych GIS z 397 tras rowerowych, które

zostały uzupełnione o badania preferencji. Autorka badań skupiła się na charakterystykach tras, które wpływają na ich wybór przez rowerzystów. Wzięła pod uwagę rodzaj trasy, obecność skrzyżowań, ich odległość oraz konfigurację. Dodatkowo zbadala także wpływ wieku i płci [156]. Landis i in. (1997) w Tampie (USA), w swoich badaniach wzięła pod uwagę: typ trasy, jej nawierzchnię, otoczenie, zagospodarowanie terenu oraz prędkość i natężenie ruchu [157]. Stinson i Bhat (2003) zbadali wybór tras przejazdu przez rowerzystów w zależności od wieku, płci, dochodu, obecności równoległego parkowania, typu trasy, jej ciągłości, klasy drogi, nawierzchni trasy, ukształtowania terenu oraz organizacji ruchu [41]. Hunt i Abraham (2006) zajęli się ruchem rowerowym w Edmonton (Kanada) związanym z nierekreacyjnymi motywacjami podróży. Czynniki wyboru trasy zbadane przez nich to: wiek rowerzysty i jego doświadczenie w ruchu rowerowym, typ trasy rowerowej, obecność parkingu, prysznic oraz natężenie ruchu i czas podróży [1]. Tilahun i in. (2007) skupili się na wpływie wieku, płci, pory roku, wielkości gospodarstwa, wielkości dochodów, obecności parkowania przy trasie rowerowej, jej rodzaju i czasu podróży na wybór ścieżki przejazdu. Sprawdzili czy podróżni byłoby w stanie wybrać dłuższą trasę, gdyby mieli do wyboru trasę, którą cechuje lepsza infrastruktura rowerowa [60]. Broach i in. (2012) przedstawili wyniki modelu wyboru trasy rowerzysty, który pokazuje względną atrakcyjność różnych typów infrastruktury, jak również wpływ urządzeń sterujących ruchem (np. sygnalizacja czy znaki „stop”) i topografii na wybór trasy. Model został opracowany na podstawie danych GPS zebranych od 164 rowerzystów w ciągu kilku dni w Portland (USA), którzy wykorzystywali rower w podróży nierekreacyjnych [116]. Proulx i Pozdunkhov (2017) na przykładzie San Francisco przedstawili metodę szacowania popytu na podróże rowerowe w całej sieci, w określonej jednostce czasu w oparciu o różne źródła danych o popycie, w tym o dane z systemu rowerów miejskich. Wykorzystuje ona geograficznie ważone połączenie danych (ang. *Geographically Weighted Data Fusion*) [137]. W Polsce model ruchu rowerowego opracowany został dla Warszawy w ramach wykonywania kompleksowych badań ruchu w 2015 roku. Został on wykonany w programie PTV VISUM według zasad klasycznego modelu czterostadiowego z pominięciem trzeciego etapu, tj. podziału zadań przewozowych, jako, że ruch rowerowy odwzorowany był za pomocą odrębnego modelu [61], [158].

Analiza powyższych badań pokazuje, że najczęściej analizowanym aspektem, mającym wpływ na wybór trasy przejazdu, jest rodzaj trasy. Żadne z powyższych badań nie brały natomiast pod uwagę jednocześnie wszystkich 6 kategorii wskaźników, które mogą być brane pod uwagę w rozpatrywaniu wyboru trasy przejazdu przez rowerzystów. Wszystkie ze wskaźników zostały rozpatrzone przez Senera i in. (2009), którzy zwrócili także uwagę na fakt, że w większości

wcześniejszych badań wykorzystano techniki analizy opisowej do analizy zebranych danych, a w niewielkiej liczbie badań zastosowano modele regresji i wielomianów logitowych do oceny wpływu cech trasy i rowerzystów na wybór trasy przejazdu [43]. Metoda regresji liniowej została wykorzystana przez Axhausena i Smitha (1986) oraz Landisa i in. (1997) [45], [157]. Bovy i Bradley (1984) wykorzystali metodę najmniejszych kwadratów oraz wielomianowy model logitowy [150], z którego skorzystali również Hunt i Abraham (2006), Stinson i Bhat (2003) oraz Sener i in. (2009) [1], [41], [43]. Model logitowy pojawił się jako metoda wykorzystana przez Hopkinsona i Wardmana (1996) oraz Ortúzara i in. (2000) [39], [155]. Dwumianowy model logitowy i liniowy model użyteczności zostały wykorzystane przez Tilahuna i in. (2007) [60]. W modelach użyteczności (zaliczanych do behawioralnych modeli popytu) zakłada się, że użytkownik, działając racjonalnie podczas realizacji podróży, stara się zmaksymalizować swoje postrzegane korzyści (lub zminimalizować uciążliwość), które wyrażone są w postaci funkcji użyteczności [159]. Sener i in. (2009) zwracają również uwagę na fakt iż niewielka liczba badań skupiała się na parkowaniu samochodów jako czynnika mającym wpływ na wybór trasy przejazdu przez rowerzystów, a nawet jeśli aspekt ten był rozważany to jedynie pod kątem tego czy parking istnieje czy nie. Nie były rozważane inne charakterystyki parkingowe, jak chociażby wskaźnik napelnienia czy rotacji. W niewielu badaniach pojawia się też wpływ bezpośrednio i czasu podróży, a jedynie Sener i in. (2009) zastosowali podczas swoich badań w Teksasie wielowymiarową analizę wyboru trasy uwzględniającą zmiany wrażliwości u rowerzystów ze względu na obserwowane i nieobserwowane cechy indywidualne [43].

2.9. Systemy *bike-sharing* i możliwości pozyskiwania z nich danych

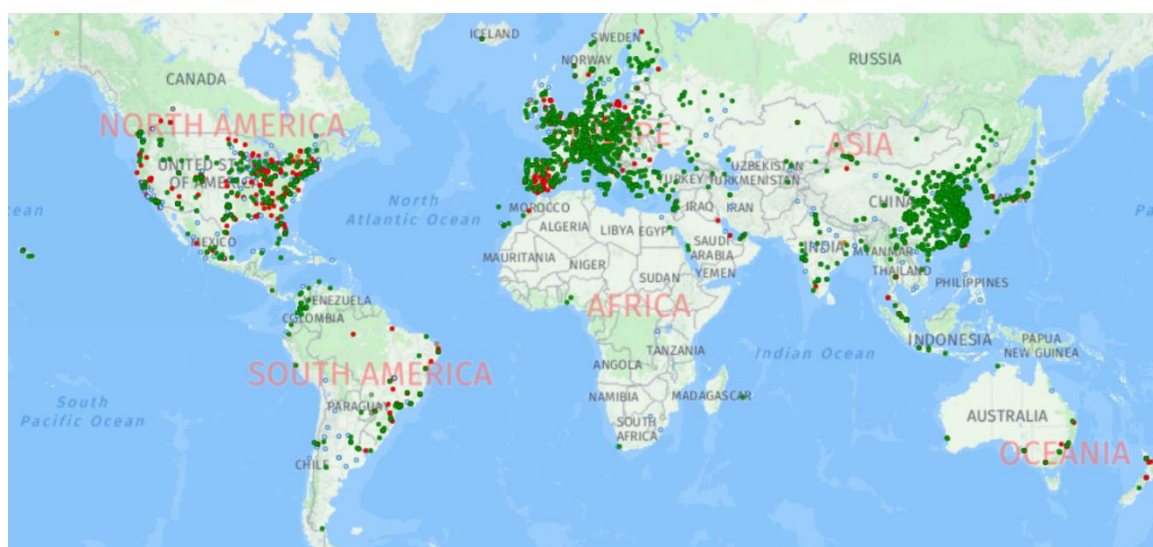
Wpisujące się w ideę „smart city” samoobsługowe systemy krótkoterminowego wynajmu rowerów (ang. *bike-sharing system*) [10] są przykładem systemów pojazdów współdzielonych obejmujących sieć strategicznie rozmieszczonych stacji, które dysponują określoną flotą pojazdów. W najbardziej elastycznej formie użytkownicy, którzy wybrali się w podróż, mogą wypożyczyć rower znajdujący się w pobliżu źródła podróży i zwrócić go blisko miejsca docelowego. W ogólnym ujęciu system pojazdów współdzielonych można interpretować jako indywidualny środek transportu (w przypadku krótkich podróży) lub jako istotny odcinek podróży intermodalnej (w przypadku dłuższych podróży). W podróżach intermodalnych tego typu system zwiększa dostępność transportową, rozwiązując „problem pierwszej i ostatniej mili” [9], [122], [160], z czym nie do końca zgadza się Campbell i in. (2016) [161]. Shaheen i in.

(2009) zwracają uwagę, że rower publiczny to indywidualny środek transportu, ale klasyfikują go jako formę transportu publicznego [162]. W aspekcie korzyści rowerów publicznych Nair i in. (2013) zwracają uwagę, że dla użytkowników system wypożyczania rowerów oferuje zwiększone możliwości podróżowania dzięki elastyczności i niskim kosztom. Użytkownicy mają swobodę wyboru czasu wyjazdu, tras i celów podróży [122]. Shaheen i in. (2009) wśród zalet systemu rowerów publicznych wymieniają również: zwiększone korzyści zdrowotne, większą świadomość ekologiczną, mniejszy poziom kongestii, zmniejszone zużycie paliwa i mniejsze koszty związane z przesunięciami modalnymi [162]. Rosnąca popularność roweru jako środka transportu objawia się rozwojem systemów krótkoterminowego wynajmu rowerów, a opcja ta jest coraz częściej rozważana i stosowana w miastach [8]. Shaheen i in. (2009) zwracają uwagę na prostą zasadę systemu rowerów publicznych: użytkownicy korzystają z roweru w razie potrzeby bez ponoszenia kosztów i obowiązków związanych z posiadaniem roweru [162].

Początki rowerów publicznych datuje się na lata 60. XX wieku. Pierwsze rowery publiczne pojawiły się w Amsterdamie i wprowadzone zostały dzięki staraniom organizacji Provos, która była mocno zaangażowana w sprawy związane ze środowiskiem. To ona opublikowała swój plan białych rowerów (ang. *white bike*), który był postrzegany jako rozwiązanie problemów komunikacyjnych w centrum Amsterdamu. Pięćdziesiąt rowerów pomalowano na białą, pozostawiono na stałe i umieszczono w całym mieście, aby mieszkańcy mogli z nich swobodnie korzystać. Niestety rowery te często były kradzione lub uszkodzone, co przyczyniło się do tego, że plan białych rowerów zawiódł wkrótce po jego uruchomieniu. Pomimo negatywnych doświadczeń związanych z wprowadzeniem białych rowerów w stolicy Holandii idea *bike-sharing* przykuła uwagę i doprowadziła do powstania pierwszej generacji rowerów publicznych określanych mianem białych bądź darmowych rowerów. Systemy te bazowały na bezkosztowej możliwości używania niezablokowanych rowerów, które były rozmieszczone w mieście przypadkowo i z reguły malowane na jeden jasny kolor. Systemy takie pojawiły się w La Rochelle (Francja) w 1974 roku oraz w Cambridge (Wielka Brytania) w 1993 roku. Problemy związane z darmowymi rowerami doprowadziły do wprowadzenia w Kopenhadze w 1995 roku systemu, który był oparty o depozyt pieniędzy, które były zwracane po przejeździe, a zablokowane rowery były zlokalizowane w specjalnych stojakach. To przyczyniło się do powstania drugiej generacji rowerów publicznych, a niedociągnięcia tej generacji doprowadziły później do powstania trzeciej generacji [162]. *Bike-sharing* stał się popularny z jej wprowadzeniem, a może być ona opisana za pomocą automatycznego urządzenia transakcyjnego na każdej stacji i zidentyfikowanych użytkowników rowerów

publicznych. Systemy te odniosły względny sukces na całym świecie. W Kopenhadze i Madrycie istnieją systemy rowerów publicznych czwartej generacji z ulepszonymi stacjami dokującymi, redystrybucją rowerów, integracją z innymi środkami transportu i rowerami elektrycznymi [160], [162].

Według stanu na maj 2021 roku na świecie funkcjonuje 2008 systemów rowerów miejskich, 24 systemy są zawieszono, planuje się utworzenie 284 nowych systemów, a w 56 przypadkach zdecydowano o anulowaniu wprowadzania systemu rowerów miejskich. Dotychczas zamknięto na świecie 790 systemów [163]. Na Rys. 2.5 zaznaczono systemy obecnie funkcjonujące (kolor zielony) oraz systemy zamknięte (kolor czerwony).



Rys. 2.5. Systemy rowerów miejskich na świecie

(źródło: [163])

Istniejące systemy funkcjonują według różnych modeli biznesowych, a ich operatorami są firmy reklamowe, zarządy transportu w miastach, organizacje non-profit czy prywatne firmy [162]. Przykładem dobrze funkcjonującego systemu roweru miejskiego jest funkcjonujący w Paryżu Vélib', gdzie rowery są oferowane na wynajem przez mniej niż 24 godziny, a najbardziej opłacalny dla użytkownika jest wynajem poniżej 2 godzin. System składa się z 1450 wypożyczalni rowerów o średniej odległości 300 metrów i puli 20 tys. rowerów. System *bike-sharing* w Paryżu okazał się bardzo popularny, ale miał również pewne problemy, w szczególności wysoki poziom wandalizmu i konieczność zmiany położenia rowerów co noc z powodu wzorców dojazdów do pracy (ang. *commuting patterns*) [8]. W 2009 roku w okresie od marca do lipca średnia dzienna liczba podróży w paryskim systemie wyniosła niemal 80 tys. [122]. Przykład systemu rowerów miejskich w Barcelonie pokazuje, że sprawnie działający system jest w stanie zaowocować wzrostem podróży rowerowych, który wyniósł

w omawianym przypadku wzrost rzędu 30%. W przypadku Londynu wprowadzany w 2001 roku plan „Cycling Revolution” oparto na założeniu, że do 2026 roku liczba podróży rowerowych w mieście wzrośnie o 400%. Jednym z elementów mającym przyczynić się do tego wzrostu było wprowadzenie systemu rowerów miejskich. Najlepsze europejskie praktyki pokazują, że aby system rowerów miejskich miał szansę na powodzenie i stanowił realną alternatywę to oprócz rozwiniętej infrastruktury musi on być zintegrowany ze środkami transportu publicznego [164]. Wzorem Paryża, Brukseli czy Kopenhagi w Polsce także wdrażane są projekty miejskich wypożyczalni rowerów. Pierwszy taki system powstał w Krakowie w 2008 roku i po różnych metamorfozach działał w latach 2017-2020 pod nazwą Wavelo obok 19 innych systemów w kraju [165]. Co ważne krakowski system oferował rowery miejskie czwartej generacji (Fot. 2.4) [166].



Fot. 2.4. Rowery Wavelo na stacji wypożyczeń przy Placu Wszystkich Świętych
(źródło: [167])

System Wavelo to nie jedyny system, który zakończył funkcjonowanie w Polsce, otóż trójmiejski system Mevo zaprzestał funkcjonowania w 2019 roku. Zarówno Wavelo, jak i Mevo, to systemy rowerowe działające na nietypowych, w porównaniu do innych miast, zasadach. Z niewielkim finansowaniem ze strony miasta, za to z dużą samodzielnością operatora, który jednocześnie miał czerpać gros zysków. W Trójmieście problemem była relokacja rowerów i ładowanie rozległego systemu rowerów elektrycznych. W Krakowie

okazało się, że system nie jest w stanie się sam sfinansować, co naraziło operatora na straty. Wavelo polegało bowiem na tym, że zyski z systemu, zarówno z wypożyczeń, jak i reklamowe, czerpał operator. Jednocześnie jednak musiał na własną rękę utrzymywać system, a z miasta otrzymywał 1 zł za każdy działający rower, czyli 1,5 tys. zł miesięcznie. W miesiącach zimowych system także funkcjonował, ale tylko w wymiarze 500 rowerów [168]. Aktualnie najbardziej rozwinięty system rowerów publicznych w Polsce to warszawskie Veturilo, powstałe w 2012 roku, w którym dokonano do 2018 roku 17 milionów wypożyczeń, a obecnie system ma w swojej flocie prócz tradycyjnych rowerów także rowery elektryczne, dziecięce i tandemy [169].

Kwestia modelowania ruchu rowerowego wiąże się także z systemami miejskich wypożyczalni rowerów. W ciągu ostatnich kilku lat przeprowadzono szereg badań poświęconych analizie czynników wpływających na podróże rowerowe w ramach systemów rowerów miejskich. Badania te zazwyczaj próbują rozpoznać potencjalne lokalizacje stacji nowotworzonych systemów i oszacować przepływy rowerowe i wykorzystanie rowerów miejskich, biorąc pod uwagę zmienne społeczno-demograficzne i dane dotyczące zagospodarowania (takie jak gęstość zaludnienia i miejsc pracy), a także parametry topologiczne i meteorologiczne dla proponowanych lokalizacji [170]–[172]. Dane z systemów rowerów miejskich znajdują zastosowanie także w badaniach systemów już funkcjonujących, jednak ilość danych zebranych w takich systemach jest często bardzo duża. Etienne i Latifa (2014) zwracają uwagę, że powoduje to trudność uzyskania wiedzy z tych danych, korzystając z nich bez pomocy automatycznych algorytmów, które wyodrębniają wzorce mobilności i dają syntetyczny obraz informacji o ruchu rowerowym w obrębie systemu rowerów publicznych [173]. Tran i in. (2015) zwracają uwagę, że dane te, które są zbierane w sposób automatyczny, stanowią cenne źródło informacji aby lepiej zrozumieć korzystanie z rowerów miejskich i są lepszym źródłem danych aniżeli wcześniej wykorzystywane tradycyjne badania, wykonywane celem określenia czynników, które mogą zachęcać do korzystania z rowerów publicznych [9]. Zhao i in. (2020) zauważa, że dzięki lokalizatory GPS w rowerach miejskich pozwalają na bardzo dokładne analizy wpływu rowerów miejskich na przestrzeń miejską, mobilność, zachowania podróżne, zrównoważony rozwój i dostępność. W porównaniu z innymi środkami transportu, dane dotyczące udostępniania rowerów zwykle zawierają dokładne punkty początkowe i końcowe oryginalnych podróży, co jest przydatne do analizy wpływu użytkowania terenu [174]. Informacje o podróżach z ich czasem trwania, źródłem i celem, które są często publicznie dostępne, są nieocenionym źródłem pozwalającym lepsze zrozumienie wzorców mobilności [175].

Podejścia do badań danych z systemów rowerów miejskich różnią się w zależności od rodzaju wykorzystywanych danych i celu, do którego służą. Zebrane dane dotyczące istniejących systemów mogą odpowiadać statystykom zajętości stacji, takim jak obłożenie stacji w ciągu dnia lub w kilku przedziałach czasowych, ale dostępne mogą być również dane dotyczące podróży (tj. dla każdej podróży wykonanej przy użyciu systemu), w którym to przypadku stacja początkowa i czas rozpoczęcia, oraz stacja docelowa i czas zakończenia podróży są rejestrowane. Ta ostatnia forma zbioru danych jest interesująca, ponieważ dostarcza informacji o miejscu początkowym i docelowym użytkownika, umożliwiając w ten sposób budowę więzby ruchu. Korzystając z tego typu danych, naukowcy zbadali dwa główne nurty, a mianowicie: klasteryzację i prognozowanie. Podczas gdy celem klasteryzacji jest identyfikacja wzorców mobilności w wykorzystaniu rowerów publicznych poprzez podział stacji na różne klastry o podobnym zastosowaniu, prognozy koncentrują się na opracowaniu modeli zdolnych do przewidywania zajętości stacji lub bardziej globalnie stanu sieci w określonym czasie [173]. W przypadku istniejących systemów jednym z problemów, z którym borykają się ich operatorzy, jest niesymetryczność popytu. Ponieważ liczba podróży z jednej stacji do drugiej rzadko jest równa liczbie podróży w przeciwnym kierunku, flota rowerowa może z czasem stać się niezbalansowana przestrzennie. Aby zaspokoić popyt w najbliższej przyszłości, operatorzy muszą redystrybuować pojazdy między stacjami, aby skorygować tę asymetrię [122]. W literaturze zagranicznej można znaleźć badania związane z zarządzaniem flotą w systemach pojazdów współdzielonych (m.in.: Barth i Todd (1999), Nair i in. (2013), Etienne i Latifa (2014), Chen i in. (2016), Liu i in. (2016), Lin i in. (2018)) przy czym część odnosi się do systemów *car-sharing* [122], [173], [176]–[179]. Okazuje się, że dane z systemów rowerowych mogą być też wykorzystywane do określania ogólnego popytu na podróże rowerowe. Wiadomym jest, że podróże w systemie rowerów publicznych odbywają się pomiędzy stacjami, ale rozwój nowych generacji pozwala na rezygnację z pozostawiania rowerów w stacjach dokujących. Oznacza to, że sposoby wykorzystania roweru publicznego w większym stopniu będą przypominać sposoby korzystania z rowerów prywatnych. Informacja na temat trasy przebytej rowerem publicznym nie będzie ograniczać się do rejestracji pomiędzy stacjami bazowymi, ale obejmie również drogę do docelowego miejsca podróży, dając pełen obraz informacji o źródłach i celach podróży rowerowych [79].

Dzięki danym pozyskanym z systemów rowerów miejskich możliwe jest określenie jak kształtuje się długość podróży z użyciem rowerów danego systemu. Wyniki Kou i Cai (2019) pokazują, że zarówno odległość, jak i czas trwania podróży są zgodne z log-normalnym rozkładem w większych systemach rowerów publicznych (np. w Bostonie, Waszyngtonie,

Chicago i Nowym Jorku), podczas gdy dystrybucja dla mniejszych systemów jest różna: rozkład Weibulla, gamma i lognormalny, co wynika z faktu, iż geograficzna granica systemów ogranicza przemieszczanie się użytkowników [180]. Froehlich i in. (2009) przeanalizowali dane z systemu rowerów miejskich w Barcelonie i metodą hierarchicznej klasteryzacji zbadali wzorce użytkowania poszczególnych stacji i geograficzną dystrybucję rowerów na terenie miasta. Dodatkowo opracowany został model przewidywania liczby dostępnych rowerów na każdej stacji w danym momencie w przyszłości [139]. Klasteryzacją posłużyli się także Etienne i Latifa (2014), którzy opracowali automatyczny algorytm oparty na nowym modelu statystycznym, który samoistnie grupuje stacje rowerów publicznych zgodnie z ich profilem użytkowania [173]. Buck i Buehler (2012) badali wpływ różnych czynników, w tym obecności ścieżek rowerowych, liczby ludności, liczby gospodarstw domowych bez samochodów i miejsc sprzedaży detalicznej w pobliżu stacji wypożyczeń na podróże rowerowe w systemie rowerów miejskich w Waszyngtonie [181]. Daddio (2012) również przeprowadził badania nad systemem rowerów miejskich w stolicy Stanów Zjednoczonych, otrzymując, że znaczący wpływ na liczbę użytkowników systemu ma odległość od środka ciężkości systemu – im dalej od niego, tym liczba rowerzystów, korzystających z rowerów miejskich, mniejsza [182]. Wang i in. (2012) w swojej analizie uwzględnili roczne wskaźniki dla każdej stacji w Minneapolis i zbadali wpływ pobliskich obszarów biznesowych, gęstości miejsc pracy, cech społeczno-demograficznych, cech zabudowy i zmiennych opisujących infrastrukturę transportową na roczne potoki podróży w obrębie systemu [183]. Rixey (2013) zbadał, z wykorzystaniem analizy regresji, wpływ charakterystyk demograficznych i cech zabudowy na średnie miesięczne wykorzystanie rowerów na poziomie stacji w trzech różnych miastach w USA: Waszyngtonie, Minneapolis i Denver [184]. Wpływ użytkowania terenu, formy urbanistycznej i czynników meteorologicznych na zmianę profili popytu na podróże rowerowe w obrębie systemu rowerów miejskich w Montrealu (Kanada) zbadali Eluru i in. (2014), skupiając się bardziej na wpływie zmiennych, mających wpływ w krótszym okresie, np. na poziomie godziny, niż na danych zagregowanych do roku czy miesiąca. W przywołanych badaniach przeprowadzonych w Montrealu wykorzystany został model regresji liniowej oraz model liniowy mieszany [170]. Rudloff i Lackner (2014) zamodelowali popyt na podróże rowerowe w obrębie systemu rowerów publicznych w Wiedniu. W szczególności wzięli pod uwagę wpływ pogody i zapelnienia sąsiednich stacji, stosując rozkład Poissona oraz ujemny rozkład dwumianowy [3]. Tran i in. (2015) poddali analizie uwarunkowania wpływające na popyt na podróże rowerowe w obrębie systemu rowerów miejskich w Lyonie (Francja), a szczególnie atrybuty zabudowy wokół stacji. Dokonali tego dzięki danym pozyskanym od operatora systemu, które

zawierały minutowe wskazania dostępnych rowerów na wszystkich ówczesnych stacjach [9]. Zeng i in. (2017) podczas prognozowania przepływów w obrębie systemu rowerów publicznych zastosowali model autoregresji i średniej ruchomej [185]. W 2018 roku Pogodzińska poddała analizie dane z rowerów miejskich w Krakowie celem opracowania metody szacowania natężenia ruchu rowerowego, wykorzystując przy tym także dane z pięciu pętli pomiaru automatycznego. Na podstawie analizy wariancji i testu post-hoc Tukey'a określiła wpływ lokalizacji i dnia tygodnia na udział rowerów systemu miejskiego w całym potoku rowerzystów [5]. W 2020 roku wyniki swoich badań dotyczących wpływu liczby sklepów detalicznych i biur biznesowych w pobliżu wypożyczalni rowerów miejskich na liczbę wypożyczeń opublikowali Lin i in. [186]. Dane z rowerów miejskich zostały wykorzystane przez Brinkmanna (2020) do opisanía różnic w sposobie wykorzystania rowerów miejskich przez turystów i zwykłych użytkowników posiadających abonament na przykładzie Rio de Janeiro i Miami Beach [187]. Inni badacze – Ni i Chen (2020) – w oparciu o dane z tygodniowych podróży roweru miejskiego i taksówek w równoległym okresie w Pekinie, porównali czasowo-przestrzenny rozkład tych dwóch środków transportu, jako łączników tzw. „pierwszej i ostatniej mili”, by poznać społeczno-demograficzne i środowiskowe czynniki, które wpływają na wybór tych środków transportu w dojeździe do stacji metra [188]. W 2021 roku ukazały się badania nad systemem roweru publicznego w Lizbonie. W artykule zidentyfikowano wzorce w systemie GIRA, analizując przestrzenno-czasowy rozkład odległości, prędkości i czasu trwania podróży oraz korelację z czynnikami środowiskowymi, takimi jak warunki pogodowe [189].

Środkiem transportu, który zdobył olbrzymią popularność na świecie w ostatnich latach jest hulajnoga elektryczna. Systemy współdzielonych hulajnóg bez dokowania w stacji szybko rozwijają się na całym świecie, stanowiąc silną alternatywę dla systemu rowerów publicznych. Ograniczone badania w tym zakresie rzuciły światło na charakterystykę użytkowania tej powstającej usługi i stosunkowo niewiele wiadomo na temat jej podobieństw i różnic w stosunku do systemów rowerów publicznych. Badania pokazują, że wspólne korzystanie z obu systemów jednocześnie jest bardziej popularne na obszarach o większej gęstości zaludnienia, wyższych dochodach, większej liczbie młodych ludzi i terenach bardziej komercyjnych [190]. Jednym z głównych pytań podczas analizy systemów hulajnóg elektrycznych jest to, czy są one substytutami istniejących opcji mobilności lub czy wypełniają pozostawione przez nie luki w świadczeniu usług. Yan i in. (2021) dokonali analizy czasoprzestrzennych wzorców dostępności i korzystania z usług e-hulajnóg w Waszyngtonie, koncentrując się na ich przestrzennych związkach z transportem publicznym i rowerami

miejskimi. Wyniki analizy trzech otwartych dużych zbiorów danych sugerują, że hulajnogi elektryczne mają zarówno konkurencyjne, jak i uzupełniające się skutki dla usług transportu publicznego i rowerów publicznych. Zasięg używania elektrycznych hulajnóg w znacznym stopniu pokrywa się z obszarami usług transportu i roweru publicznego, a większość podróży na hulajnogach elektrycznych autorzy badania zaklasyfikowali jako substytut transportu publicznego i rowerów publicznych [191].

2.10. Podsumowanie stanu badań nad ruchem rowerowym

Dokonana kwerenda źródeł bibliograficznych ukazuje jak rozległe prowadzone są badania związane z ruchem rowerowym, w tym także z systemami rowerów publicznych. Począwszy od poszukiwania wpływu cech takich jak wiek czy płeć na wybór roweru jako środka transportu, poprzez analizę długości, czasu czy prędkości podróży rowerowych, a skończywszy na analizach dużych zbiorów danych, pochodzących z rowerów miejskich i wykorzystywanych w celu predykcji zajętości stacji czy wzorców mobilności użytkowników systemu. Ponadto, jako, że lata 2020-2021 w każdej z dziedzin upływają pod znakiem pandemii COVID-19, w literaturze znaleźć można także opracowania dotyczące wpływu epidemii koronawirusa na funkcjonowania systemów rowerów miejskich [192].

Okazuje się, że wiele miejsca w literaturze poświęcono wpływowi zagospodarowania przestrzennego na zajętość stacji rowerów miejskich i liczbę podróży związanych z miejscami obudowanymi klastrami biurowymi czy sprzedażą detaliczną. Przeprowadzono także badania związane z atrakcyjnością otoczenia trasy w kontekście wyboru trasy, jednakże żadne ze znalezionych badań nie odnosiło się do analizy postojów rowerzystów i identyfikacji atrakcyjnych miejsc dla użytkowników systemów rowerów miejskich. Większość z badań w podobnym zakresie odnosi się do poszukiwania lokalizacji wypożyczalni, biorąc pod uwagę preferencje użytkowników, ale także, a może przede wszystkim, opłacalność danej lokalizacji pod kątem biznesowym dla operatora systemu. Dokonany przegląd stanu badań pozwolił utwierdzić się, że w zakresie poruszonym w niniejszej dysertacji istnieje luka badawcza, którą dzięki tej pracy postarano się w pewnym stopniu wypełnić i zapoczątkować badania w analizowanej płaszczyźnie.

3

||||| Wykorzystanie dużych zbiorów
danych do modelowania
ruchu rowerowego

3. Wykorzystanie dużych zbiorów danych do modelowania ruchu rowerowego

Dane, które posłużyły do wykonania analiz w ramach niniejszej dysertacji pozyskane zostały dzięki uprzejmości operatora krakowskiego systemu rowerów miejskich Wavelo – firmy BikeU. Dane te obejmują 8 dni 2017 roku – od 31 maja do 7 czerwca. Okres analizy przypada na szczyt turystyczny, a ponadto podróżom rowerowym w analizowanym okresie sprzyjały warunki pogodowe – średnia temperatura powietrza wahała się od 16,7°C do 21,3°C, opady deszczu miały charakter przelotny, a ciśnienie powietrza oscylowało wokół 1015 hPa (Tab. 3.1).

Tab. 3.1. Warunki pogodowe na stacji pomiarowej Kraków-Balice w dniach 31.05-7.06.2017 roku

Data	Dzień tygodnia	Średnia temperatura powietrza [°C]	Maksymalna temperatura powietrza [°C]	Całkowite opady deszczu [mm]	Średnie ciśnienie powietrza [hPa]
31.05.2017	środa	19,5	24,5	0,1	1016,0
1.06.2017	czwartek	17,1	22,2	0,0	1019,0
2.06.2017	piątek	16,7	24,4	0,0	1018,1
3.06.2017	sobota	17,3	24,4	0,0	1016,6
4.06.2017	niedziela	19,6	28,9	3,6	1010,8
5.06.2017	poniedziałek	18,0	22,7	0,0	1015,3
6.06.2017	wtorek	21,3	28,4	0,0	1008,1
7.06.2017	środa	16,9	26,0	0,0	1014,2

źródło: opracowanie własne na podstawie [193]

Analizowany zestaw danych zawiera informacje o 34969 podróżach. Dane przechowywane są w formacie GPX. Format ten nazywany jest także GPS eXchange Format i jest formatem pliku XML [194], którego nazwa pochodzi od słów *Extensible Markup Language*. Pliki w formacie .xml są plikami tekstowymi, a XML to język znaczników, którego celem jest definiowanie składni kodowania dokumentów. Cały proces przebiega poprzez użycie znaczników definiujących strukturę dokumentu, ale także poprzez sposób jego przechowywania i przesyłania [195]. Format GPX stworzony jest po to, by ułatwić wymianę danych pomiędzy aplikacjami używającymi danych GPS, takich jak POI (użyteczne miejsca, ang. *points of interest*), punkty nawigacyjne (ang. *waypoint*), ścieżki (ang. *track*) czy trasy (ang. *route*). Dane te charakteryzuje łatwość przetwarzania i konwersji na inne formy [194]. Rys. 3.1 przedstawia na fragmencie pliku przykład, w jaki sposób pojedynczy punkt nawigacyjny (zwany „LAGORETICO”) i seria punktów trasy są reprezentowane w pliku GPX.

```

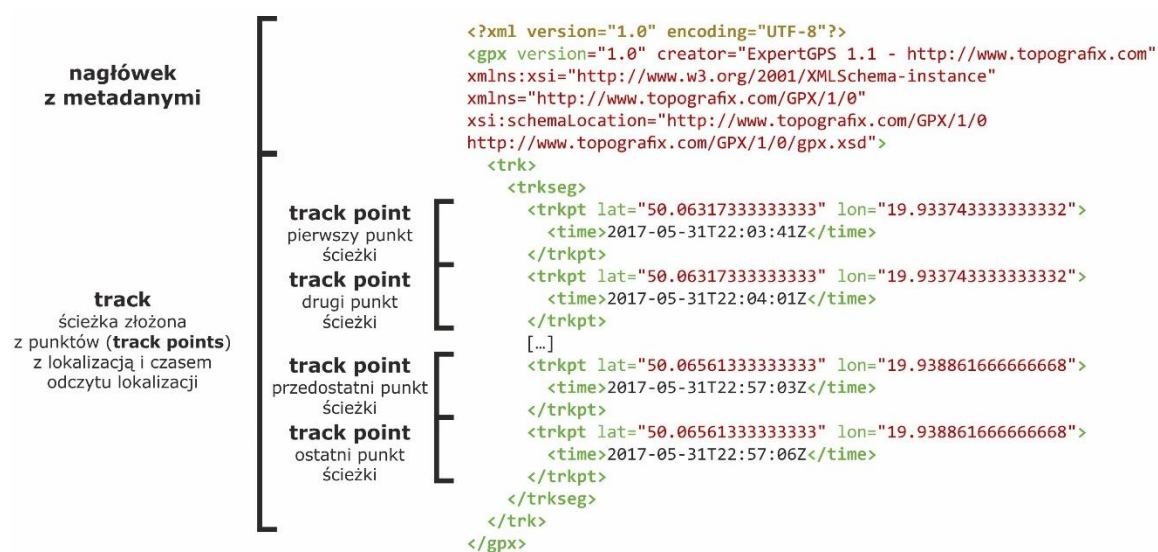
<?xml version="1.0" encoding="UTF-8"?>
<gpx version="1.0">
  <name>Example gpx</name>
  <wpt lat="46.57638889" lon="8.89263889">
    <ele>2372</ele>
    <name>LAGORETICO</name>
  </wpt>
  <trk><name>Example gpx</name><number>1</number><trkseg>
    <trkpt lat="46.57608333" lon="8.89241667"><ele>2376</ele><time>2007-10-14T10:09:57Z</time></trkpt>
    <trkpt lat="46.57619444" lon="8.89252778"><ele>2375</ele><time>2007-10-14T10:10:52Z</time></trkpt>
    <trkpt lat="46.57641667" lon="8.89266667"><ele>2372</ele><time>2007-10-14T10:12:39Z</time></trkpt>
    <trkpt lat="46.57650000" lon="8.89280556"><ele>2373</ele><time>2007-10-14T10:13:12Z</time></trkpt>
    <trkpt lat="46.57638889" lon="8.89302778"><ele>2374</ele><time>2007-10-14T10:13:20Z</time></trkpt>
    <trkpt lat="46.57652778" lon="8.89322222"><ele>2375</ele><time>2007-10-14T10:13:48Z</time></trkpt>
    <trkpt lat="46.57661111" lon="8.89344444"><ele>2376</ele><time>2007-10-14T10:14:08Z</time></trkpt>
  </trkseg></trk>
</gpx>

```

Rys. 3.1. Fragment pliku w formacie GPX

(źródło: [196])

Powyższy przykład pokazuje strukturę pliku GPX z danymi o pierwszym punkcie w nagłówku z metadanymi. Dalsze punkty (*track points*) ścieżki (*track*: początek ścieżki oznaczony jako `<trk>` a koniec jako `</trk>`) oznaczone symbolami `<trkpt>` (początek informacji o punkcie) oraz `</trkpt>` (koniec informacji o punkcie) zawierają dane o współrzędnych geograficznych punktu (`lat` oraz `lon`), czasie ich odczytu `<time>`, a także o wysokości punktu `<ele>`. Plik GPX używany w analizie danych o zachowaniach użytkowników systemu Wavelo zbudowany jest nieco inaczej, tj. nie zawiera informacji o pierwszym punkcie ścieżki w nagłówku oraz nie posiada informacji o wysokości każdego punktu. Niestety dane nie zawierają informacji o użytkowniku, takich jak płeć czy rodzaj wykupionego abonamentu, co mogłoby pomóc w analizie tego, którzy użytkownicy są stałymi użytkownikami. Strukturę analizowanego pliku GPX na podstawie fragmentu jednej ścieżki pokazano na Rys. 3.2.



Rys. 3.2. Struktura analizowanego pliku GPX

(źródło: opracowanie własne na podstawie [197])

Analizowane dane uzyskano z komputerów pokładowych z GPS, w które wyposażony był każdy rower miejski Wavelo, a prócz informacji o miejscu źródłowym i docelowym podróży dane dostarczają informacji o trasie przejazdu. Jest to możliwe dzięki temu, że lokalizatory GPS w rowerach Wavelo pozyskiwały informację o położeniu roweru co 5-15 sekund. Informacja o położeniu jest dość dokładna – według informacji pozyskanych od operatora rowerów Wavelo wynosiła ona 5-10 m. Dzięki takiej strukturze danych możliwe jest przedstawienie każdej z podróży w formie wykresu zależności dystansu od czasu i prędkości od czasu (Rys. 3.3). Na rysunku widać niejednorodność zachowań i przebiegu podróży – część podróży przebiegała bez zatrzymań na trasie (a), część charakteryzuje długi postój związany z wypożyczeniem roweru bądź jego zwróceniem na stacji (b), kolejną grupę stanowią podróże z dłuższymi postojami (c), dla innych podróży charakterystyczne są natomiast krótsze postoje w trakcie podróży (d).

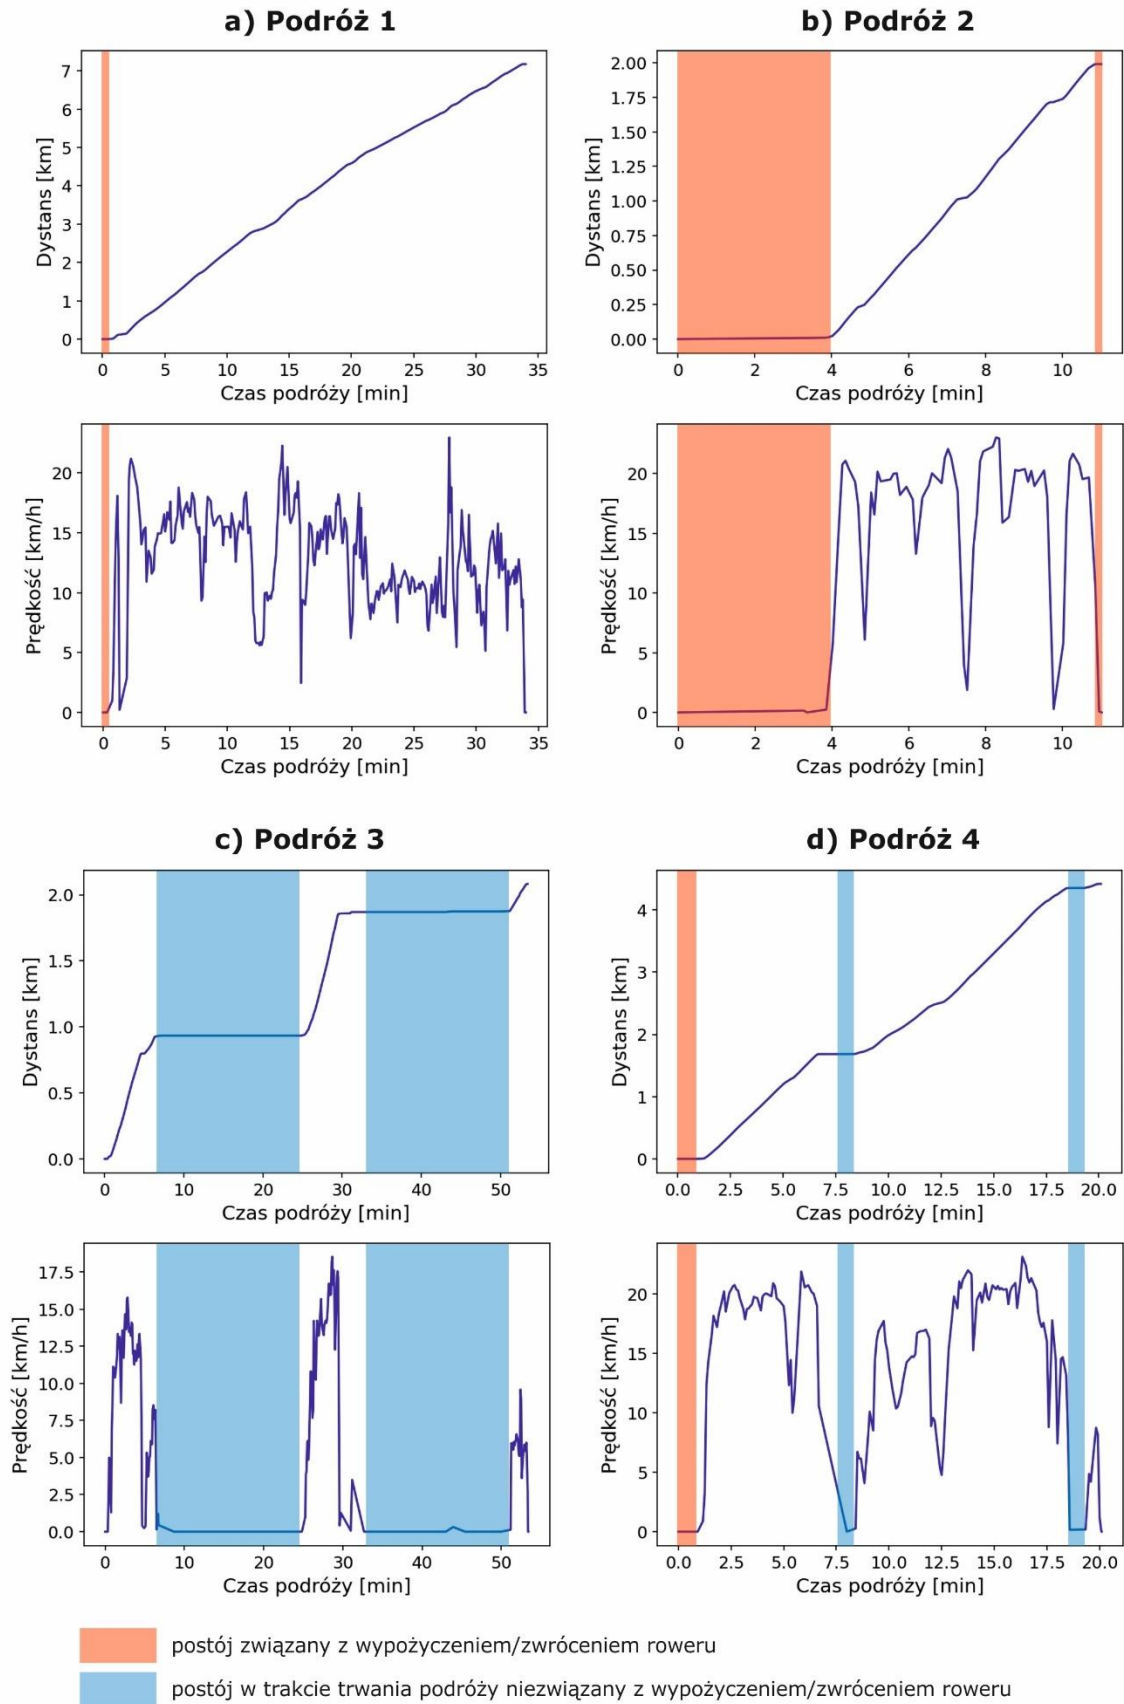
Aby odczytać dane z plików GPX, opracowano kod w języku Python. Język ten to wieloplatformowy język programowania i może być używany na komputerze z systemem Windows, Linux Box lub Apple Mac itp. W niniejszej dysertacji wykorzystywana jest wersja Python 3, która została wydana w grudniu 2008 roku i jest główną wersją języka, który nie jest wstecznie kompatybilny [198]. Do pisania kodu wykorzystywany był Jupyter Notebook – jest to aplikacja internetowa typu *open source*, która umożliwia tworzenie i udostępnianie dokumentów zawierających aktywny kod, równania, wizualizacje i tekst narracyjny. Jego zastosowania obejmują: czyszczenie i transformację danych, symulację numeryczną, modelowanie statystyczne, wizualizację danych czy uczenie maszynowe [199].

Zanim przystąpiono do przygotowania kodu określono metodykę odczytu danych, bazując na ich strukturze. Metodykę analizy przedstawionych danych zdefiniować można w następujący sposób: analizie podlegały ścieżki (*Tracks*) ułożone chronologicznie, które są zestawami punktów:

$$Track = \{TP_i\}, i = 1 \dots N_{TP} \quad (1)$$

gdzie każdy z punktów *TP* ma zdefiniowany czas *t* i lokalizację (*lon*, *lat*):

$$TP = \langle t, lon, lat \rangle \quad (2)$$



Rys. 3.3. Wykresy przykładowych podróży rowerami miejskimi Wavelo

(źródło: opracowanie własne)

Dla wygodniejszej obróbki danych zastosowana została dualna definicja ścieżki, gdzie podróż opisana jest także jako zestaw segmentów podróży:

$$Track = \{TS_j\}, j = 1 \dots N_{TS} \quad (3)$$

gdzie TS_j jest j-tym segmentem danej ścieżki i jest zdefiniowany przez parę sąsiadujących punktów TP_o i TP_d :

$$TS = \{TP_o, TP_d\} \quad (4)$$

Do dalszej analizy przygotowany został program, który umożliwił prezentację danych jako zestawu parametrów podróży:

- unikalnego numeru identyfikacyjnego podróży (ID),
- czasu podróży (t_{tr}),
- całkowitej długości podróży (d_s),
- średniej prędkości podróży (v_{tr}),
- średniej prędkości jazdy (v_s),
- współczynnika wydłużenia trasy (r)
- sumarycznego czasu postojów (t_{idle}).

Przedstawienie danych o podróżach rowerowych w takim formacie pozwoliło uzyskać próbki zmiennych losowych charakteryzujących liczbowe parametry popytu. Każda z podróży ($Trip$) może zatem być opisana jako:

$$Trip = \langle ID, Track, t_{tr}, d_s, v_{tr}, v_s, r, t_{idle} \rangle \quad (5)$$

gdzie $Track$ jest odniesieniem do danej ścieżki GPS. Wstępna analiza zbioru danych pokazała jednak, że część informacji o podróżach jest nieprzydatna, tj. rekordy zawierały informacje o podróżach o zerowym dystansie lub zerowym czasie trwania. W części rekordów

zaobserwowano natomiast problem z lokalizatorem GPS. Z tego powodu konieczne było przeprowadzenie procedury czyszczenia danych, która została opisana w podrozdziale 3.1.

Aby określić wspomniane wyżej parametry każdej z podróży zastosowano opisane poniżej procedury. Numer identyfikacyjny każdej podróży przypisywany był w poniższy sposób:

```
dla podróży w pliku z zestawem podróży przypisz kolejną liczbę całkowitą większą od 0
```

W celu wyznaczenia czasu podróży zastosowano następujący pseudokod:

```
dla podróży w pliku z zestawem podróży przypisz różnicę pomiędzy czasem odczytu lokalizacji pierwszego punktu, a czasem odczytu lokalizacji ostatniego punktu
```

Całkowita długość podróży obliczona została jak poniżej:

```
dla podróży w pliku z zestawem podróży przypisz sumę dystansów wszystkich segmentów podróży
```

Średnia prędkość każdej z podróży [km/h] w zestawie wyznaczona została według następującej procedury:

```
dla podróży w pliku z zestawem podróży:  
    jeżeli czas podróży jest równy 0 to przypisz 0  
    w przeciwnym razie przypisz wynik działania: 3600 *  
    całkowity dystans podróży / całkowity czas podróży  
    koniec warunku
```

Średnia prędkość jazdy wyznaczona została według następującej procedury:

```
dla podróży w pliku z zestawem podróży:  
    jeżeli czas podróży jest równy 0 lub czas podróży jest równy  
    czasowi sumarycznego postoju w czasie podróży to przypisz 0  
    w przeciwnym razie przypisz wynik działania: 3600 *  
    całkowity dystans podróży / (całkowity czas podróży -  
    sumaryczny czas postojów w czasie podróży)  
    koniec warunku
```

Współczynnik wydłużenia trasy wyznaczono w oparciu o pseudokod:

```
dla podróży w pliku z zestawem podróży:
    jeżeli dystans w linii prostej pomiędzy pierwszym,
    a ostatnim punktem jest równy 0 to przypisz 0
    w przeciwnym razie przypisz wynik działania: całkowity
    dystans podróży / dystans w linii prostej pomiędzy pierwszym
    a ostatnim punktem podróży
    koniec warunku
```

Ostatni z parametrów opisujących podróz, tj. sumaryczny czas postojów w trakcie trwania podróży, określono w następujący sposób:

```
dla podróży w pliku z zestawem podróży przypisz sumę czasów
trwania segmentów tej podróży dla których dystans jest równy 0
```

Sumaryczny czas trwania postojów można zdefiniować także w następujący sposób:

$$t_{idle} = \sum_{TS_{idle}} t_s, TS_{idle} = \{TS_j: d_{sj} = 0\}, j = 1 \dots N_{TS} \quad (6)$$

gdzie TS_{idle} jest zestawem wszystkich segmentów, dla których dystans d_s równy jest 0. Przygotowane w ten sposób dane poddane zostały wstępnej ocenie, która wykazała istnienie rekordów zaburzających poprawną analizę zbioru danych, np. podróże o zerowym dystansie lub czasie trwania. W tym celu przeprowadzono proces eliminacji uszkodzonych rekordów, co zostało opisane w podrozdziale 3.1.

3.1. Weryfikacja analizowanego zbioru danych

Aby dobrze przeanalizować wyniki zebranych danych należy przeprowadzić ich weryfikację, tj. sprawdzić ich poprawność poprzez przeprowadzenie, tzw. czyszczenia posiadanego zbioru. Czyszczenie danych (ang. *data cleaning*, *data cleansing*, *data scrubbing*) to proces wykrywania oraz usuwania błędów oraz niespójności w celu polepszenia jakości danych. Jest to istotny etap w procesie analizy danych ze względu na niebezpieczeństwo jakie niesie za sobą analiza

błędnych lub niespójnych danych i bazowanie na nich w przygotowywanych prognozach. Przede wszystkim może prowadzić to do błędnego rozumowania, co jest kluczowe zwłaszcza przy wykorzystywaniu wyników analizy danych do podejmowania decyzji biznesowych. Na przykładzie marketingu można to zobrazować przykładem kampanii reklamowej wykorzystującej dane niskiej jakości i docierającej do użytkowników z nietrafnymi ofertami, co nie tylko zmniejsza satysfakcję klientów, ale także powoduje utratę znaczącej okazji do sprzedaży. W finansach niedokładne i niekompletne dane mogą prowadzić do naruszeń przepisów czy opóźnionych decyzji z powodu ręcznych kontroli i nieoptymalnych strategii handlowych, a w produkcji i logistyce, gdzie wycena zapasów zależy od dokładnych danych, jeśli ich brakuje lub są one niespójne, może to prowadzić do problemów z dostawą i niezadowolenia klientów [200]. Zestawy „surowych” danych z brakami lub błędami mogą tworzyć zafalszowany obraz określonej sytuacji, stąd przed fazą analizy konieczne jest wyczyszczenie zbioru danych. Proces ten polega głównie na identyfikacji błędów, ich wykrywaniu i korygowaniu. Różne rodzaje problemów z danymi występują, gdy firmy łączą zbiory danych z wielu miejsc, pobierają dane z sieci lub otrzymują dane od klientów lub innych działów. Niektóre przykładowe problemy z danymi to:

- zduplikowane dane: istnieją dwa lub więcej identycznych rekordów, co może powodować błędne przedstawienie stanu zapasów lub powielanie materiałów marketingowych lub niepotrzebne czynności rozliczeniowe;
- konflikt danych: gdy istnieją te same rekordy z różnymi atrybutami, oznacza to, że dane są w konflikcie, np. firma z różnymi wersjami adresów może powodować problemy z dostawą;
- niekompletne dane: dane, które mają brakujące atrybuty, np. listy plac pracowników mogą nie być przetwarzane z powodu braku numerów PESEL w bazie danych;
- nieprawidłowe dane: atrybuty danych nie są zgodne ze standardami, np. zapis 8-cyfrowy numeru telefonu zamiast 9 cyfr lub kodu pocztowego w złym formacie.

Mimo że dane wymagają często szybkiej analizy, proces czyszczenia danych jest złożony i czasochłonny, aby mieć pewność, że wyczyszczone dane mają lepszą jakość. Znaczenie eksperta dziedzinowego w procesie czyszczenia danych jest niezaprzeczalne, ponieważ weryfikacja i walidacja są głównymi problemami dotyczącymi oczyszczanych danych [201].

W literaturze odnaleźć można wiele rozwiązań problemów związanych z czyszczeniem danych. Można je podzielić na tradycyjne czyszczenie i czyszczenie w przypadku dużych zbiorów danych. Tradycyjne metody czyszczenia danych nazywane są tradycyjnymi, ponieważ nie

nadają się do przetwarzania dużych ilości danych. *Potter's Wheel* i *Intelliclean* to tylko niektóre przykłady tradycyjnego czyszczenia. Przykładami metod stworzonych do czyszczenia dużych zbiorów danych są: Cleanix, SCARE (*SCalable Automatic REpairing*), KATARA i BigDancing. Dla przykładu pierwsza z metod, tj. Cleanix, rozwiązuje cztery rodzaje problemów z jakością danych, którymi są: wykrywanie nieprawidłowych wartości, niepełne wypełnienie danych, duplikacja i rozwiązywanie konfliktów. Metoda ta została opracowana z uwzględnieniem funkcji skalowalności, ujednoczenia i użyteczności, które umożliwiają Cleanix równoległe czyszczenie danych i raportowanie ich jakości. W przypadku metody SCARE w procesie naprawy i oczyszczania wykorzystywane są techniki uczenia maszynowego i metody prawdopodobieństwa. Wymagają one jednak dokładnego modelowania korelacji między atrybutami baz danych, gdyż niektóre atrybuty tych samych rekordów mogą być zanieczyszczone [201]. Dobór techniki czyszczenia nie jest jednak oczywisty i zależy przede wszystkim od rodzaju analizowanych danych. Ze względu na specyfikę danych przygotowywane są często metody ich oczyszczania skrojone pod konkretne potrzeby. Bez względu na to można wyznaczyć kilka często wykorzystywanych etapów czyszczenia danych, tj.: usunięcie nieistotnych wartości, usunięcie zduplikowanych wartości, korekta lapsusów językowych, tzw. „literówek”, przekonwertowanie formatu danych (np. z tekstowego na liczbowy) i uzupełnienie brakujących danych. W przypadku analizowanych w niniejszej dysertacji danych opracowano autorską metodę ich czyszczenia w oparciu o eliminację uszkodzonych rekordów oraz usunięcie rekordów zawierających dane o niezrealizowanych podróżach [202].

3.1.1. Metodyka weryfikacji analizowanego zbioru danych

Proponowana metodyka weryfikacji (czyszczenia) danych obejmuje trzy główne etapy:

- **etap I** - eliminacja uszkodzonych danych: surowy zestaw danych zwykle zawiera zapisy z uszkodzonymi danymi spowodowanymi przerwami w sygnale lokalizatorów GPS, takie zakłócenia sygnału powodują nierealistyczny czas podróży rowerem;
- **etap II** - wyłączenie podróży o parametrach równych zero: niektóre ścieżki zawierają wartości zerowe czasu trwania podróży lub dystansu podróży; zazwyczaj takie zapisy danych przedstawiają sytuacje, w których rower był odblokowany ze stacji, ale nie został wyjęty ze stojaka;
- **etap III** - wyłączenie podróży, które nie zostały zakończone: niektóre rekordy charakteryzują się niezerowym czasem podróży, ale bardzo małą (mniej niż 10 m)

długością podróży; zapisy te są spowodowane przez przypadki, gdy rower został odblokowany ze stacji, a następnie pozostawiony w pobliżu stacji odblokowania lub zablokowany ponownie na tej samej stacji po pewnym czasie bez wykorzystywania go do odbycia podróży. Wartość 10 m dobrana została na podstawie deklarowanej przez operatora dokładności lokalizatorów GPS w rowerach Wavelo.

Procedurę I etapu czyszczenia podróży można przedstawić w postaci pseudokodu:

```
dla podróży w pliku z zestawem podróży:  
    jeżeli różnica w czasie odczytu dwóch kolejnych punktów na  
    trasie jest większa niż 5 min to odrzuć daną podróż  
    z zestawu podróży  
    w przeciwnym razie zostaw daną podróż w zestawie podróży  
    koniec warunku
```

Procedurę II etapu czyszczenia podróży można przedstawić w postaci pseudokodu:

```
dla podróży w pliku z zestawem podróży po I etapie czyszczenia:  
    jeżeli czas podróży lub dystans podróży jest równy 0 to  
    odrzuć daną podróż z zestawu podróży  
    w przeciwnym razie zostaw daną podróż w zestawie podróży  
    koniec warunku
```

Procedurę III etapu czyszczenia podróży można przedstawić w postaci pseudokodu:

```
dla podróży w pliku z zestawem podróży po II etapie czyszczenia:  
    jeżeli dystans podróży jest mniejszy od 10 m to odrzuć daną  
    podróż z zestawu podróży  
    w przeciwnym razie zostaw daną podróż w zestawie podróży  
    koniec warunku
```

Wyniki przeprowadzonej procedury oczyszczania danych przedstawione zostały w kolejnym podrozdziale.

3.1.2. Wyniki weryfikacji analizowanego zbioru danych

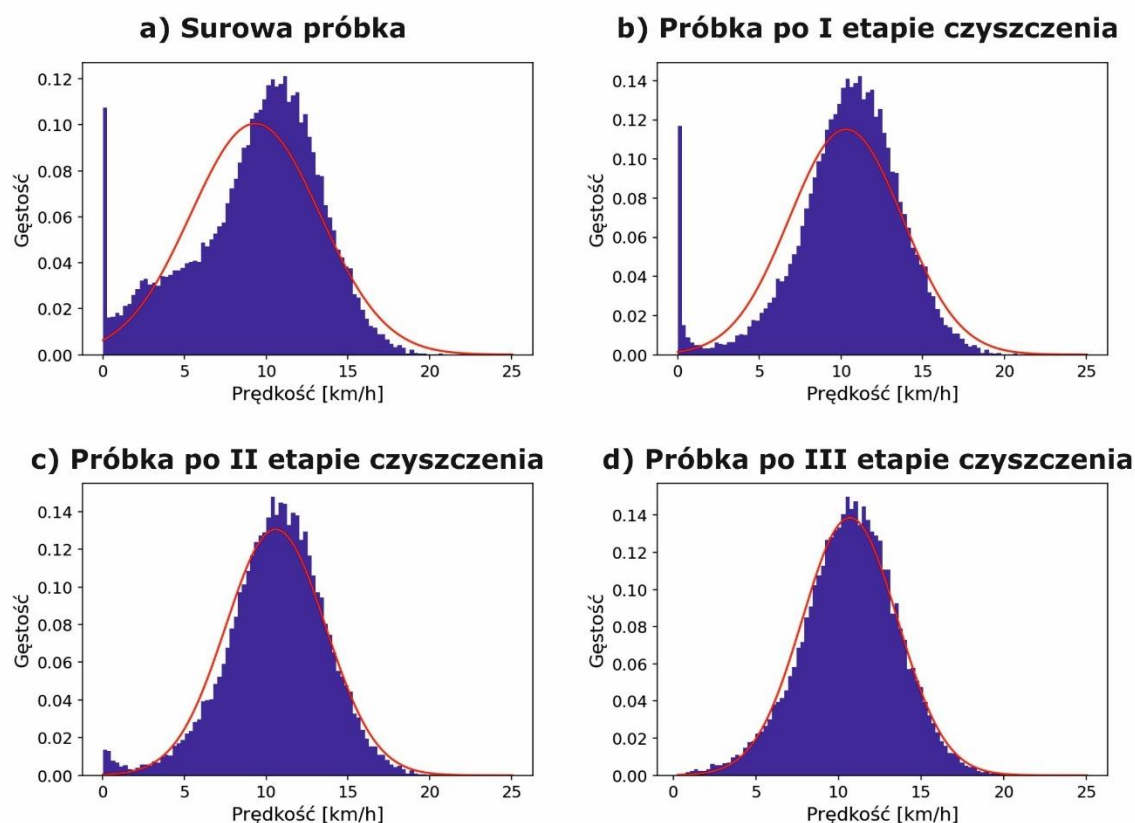
W ramach opisanej powyżej procedury weryfikacji danych po etapie I usunięto 5946 uszkodzonych rekordów, co stanowi 17,0% próbki danych. Na etapie II z próby wyłączono 784 ścieżki - 40 rekordów z zerowym czasem trwania podróży i 744 rekordy z zerowym dystansem podróży. Łącznie w etapie II odrzucono 2,1% podróży z pierwotnej próbki. W etapie III wykluczono 380 rekordów reprezentujących podróże z odległością podróży mniejszą niż 10 m – odrzucone rekordy stanowią 1% próbki surowych danych. W rezultacie uzyskano próbkę 27859 rekordów zawierających dane dotyczące wykonanych podróży. Uzyskany zestaw zawiera tylko zrealizowane podróże reprezentujące rzeczywiste zapotrzebowanie na podróże rowerowe w obrębie systemu rowerów miejskich w badanym okresie. Poniżej przedstawiono podstawowe statystyki opisujące wyczyszczonej próbkę danych, tj. wartość średnią, odchylenie minimalne, wartość minimalną, maksymalną oraz kwantyle 25%, 50% i 75% dla sześciu parametrów opisujących podróże.

Tab. 3.2. Statystyki oczyszczonej próbki danych

	Czas podróży [min]	Dystans podróży [km]	Śr. prędk. podróży [km/h]	Śr. prędk. jazdy [km/h]	Współcz. wydłuż. trasy	Czas postojów [min]
Średnia	23,17	3,90	10,72	11,60	83,20	2,61
Odch. stand.	25,20	3,45	2,85	2,67	683,62	9,91
Min	1,42	0,11	0,32	1,38	1,00	0,00
25%	9,92	1,70	8,91	9,85	1,20	0,42
50%	16,58	2,96	10,81	11,60	1,33	0,67
75%	27,58	5,03	12,62	13,37	1,58	1,58
Max	524,08	54,63	25,05	25,25	33106,27	504,58

źródło: opracowanie własne

Podczas oczyszczania danych, analizując histogramy rozkładu powyższych parametrów, zaobserwowano proces normalizowania się rozkładu średniej prędkości podróży, co pozwala stwierdzić, że opracowana metodyka oczyszczania danych jest poprawna. Zestawienie histogramów średniej prędkości, sporządzonych po każdym etapie czyszczenia danych, przedstawiono na Rys. 3.4.



Rys. 3.4. Rozkład średniej prędkości podróży w surowej próbce danych i próbce po każdym z etapów czyszczenia danych
(źródło: opracowanie własne)

Oczyszczona według opisanej powyżej procedury próbka posłużyła do dalszych analiz tras przejazdu użytkowników systemu rowerów miejskich Wavelo. W niniejszej rozprawie doktorskiej prócz parametrów opisujących całą podróż rowerem miejskim skupiono się także na analizie postojów rowerzystów. W tym celu konieczne było przeprowadzenie procesu filtrowania postojów branych pod uwagę do dalszych analiz, co zostało opisane w podrozdziale 3.2.

3.2. Weryfikacja danych o liczbie i czasie postojów użytkowników rowerów miejskich

Jak wspomniano wyżej, analizie poddane zostały także postoje użytkowników systemu rowerów miejskich Wavelo, a dokładniej ich lokalizacja i czas trwania. Pojedynczy postój (*Stopover*) zdefiniować można jako:

$$TS_{idle} = \{TS_j: d_{sj} = 0\}, j = 1 \dots N_{TS}$$

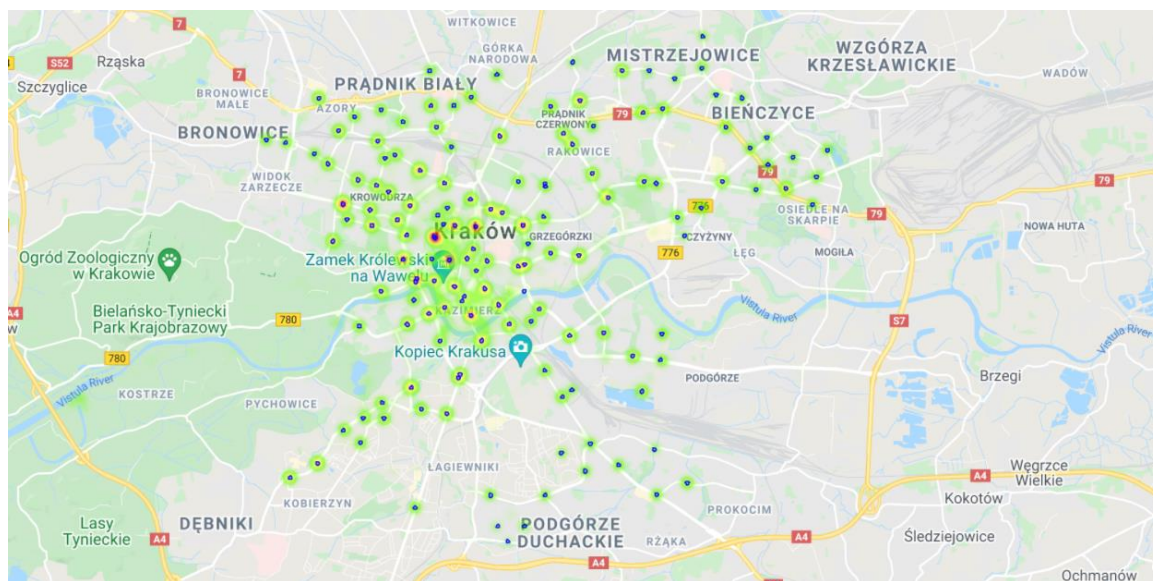
$$Stopover = TS_{idle}\{TS_k, TS_{k+1}\}, 1 \leq k \leq N_{TS}$$
(7)

Należy przez to rozumieć, że za pojedynczy postój uznaje się zestaw segmentów TS_{idle} , składających się z sąsiadujących ze sobą segmentów TS_j , których dystans d_{sj} równy jest 0. Powyższa definicja pozwala na określenie więcej niż jednego postoju w ramach każdej z podróży. Pojedynczy postój opisany został dodatkowo trzema parametrami: czasem trwania t oraz długością i szerokością geograficzną (lon, lat):

$$Stopover = \langle t, lon, lat \rangle$$
(8)

W pierwszym kroku przygotowano mapę ciepła pokazującą gdzie najczęściej postojów miało miejsce. Mapa ciepła, zwana też mapą termiczną (ang. *heatmap*), to dwuwymiarowa, graficzna prezentacja danych, w których wartości zmiennej są wyświetlane w postaci kolorów. Mapy ciepła są atrakcyjne z dwóch powodów. Po pierwsze, intuicyjny charakter skali kolorów w odniesieniu do temperatury minimalizuje ilość nauki niezbędnej do jej zrozumienia – z doświadczenia wiemy, że żółty jest cieplejszy niż zielony, pomarańczowy jest cieplejszy niż żółty, a czerwony jest gorący. Nietrudno więc zorientować się, że ilość ciepła jest proporcjonalna do poziomu reprezentowanej zmiennej. Po drugie, mapy cieplne pokazują dane bezpośrednio nad bodźcem. Ponieważ dane nie mogą być bliżej elementów, do których się odnoszą, odczytanie mapy cieplnej wymaga niewielkiego wysiłku. Mapy ciepła mogą mieć wielką wartość w artykułach, raportach i prezentacjach, ponieważ zawierają podsumowanie dużych ilości danych, które byłyby znacznie trudniejsze do uchwycenia, gdyby były przedstawione liczbowo. Mapy te pomagają nam szybko zobaczyć „ogólny obraz”, w tym wszelkie wzorce lub trendy, które mogą występować w danych [203]. Mapy te wykorzystywane

są wielu dziedzinach, począwszy od stron internetowych i pokazywania miejsc, gdzie odwiedzający stronę internetową klikają najczęściej, po analizy dużych zbiorów danych przestrzennych, np. z takim z jakim mamy do czynienia w niniejszej pracy. Rys. 3.5 pokazuje przygotowaną dla zbioru danych z lokalizacjami postojów mapę ciepła. Po nałożeniu na nią lokalizacji stacji rowerowych istniejących w okresie, z którego pochodzą dane, widać, że największe skupiska postojów występują w sąsiedztwie wypożyczalni. Postoje te związane są z czynnościami związanymi z wypożyczeniem lub oddaniem roweru na stacji.



Rys. 3.5. Mapa ciepła postojów rowerzystów w oczyszczonej próbkę danych
(źródło: opracowanie własne, mapa: Google Maps)

W związku z powyższym zdecydowano o przeprowadzeniu filtrowania postojów celem sprawdzenia czy jest możliwe wydzielenie postojów niespowodowanych czynnościami technicznymi czy kwestiami ruchowymi. Zaproponowana metodyka opisana została w podrozdziale 3.2.1.

3.2.1. Metodyka weryfikacji danych o liczbie i czasie postojów użytkowników rowerów miejskich

W pierwszym kroku opracowanej metodyki weryfikacji (filtrowania) postojów z próbki usunięto postoje, które wystąpiły w odległości do 10 m od którejkolwiek ze stacji wypożyczenia. Przyjęta wartość wiąże się z deklarowaną przez operatora Wavelo dokładnością lokalizatorów GPS w komputerach pokładowych. Po usunięciu z próbki postojów w zasięgu do 10 m od którejkolwiek ze stacji, na kolejnej mapie ciepła zaobserwowano duże skupiska zatrzymań w sąsiedztwie skrzyżowań i przejazdów kolejowych. Ponadto, jako że analiza

dotyczy miasta Krakowa, postanowiono odrzucić postoje, które nastąpiły poza granicami miasta. To wszystko spowodowało, że zaproponowano poniższą, składającą się z pięciu etapów, metodykę weryfikacji postojów:

- **etap I** – eliminacja postojów poza obszarem Krakowa – konieczne ze względu na dalsze analizy;
- **etap II** – eliminacja postojów w sąsiedztwie wypożyczalni rowerów Wavelo;
- **etap III** - wyłączenie postojów krótszych niż 30 sekund; tego typu postoje często związane są z utrudnieniami w ruchu;
- **etap IV** - wyłączenie postojów w sąsiedztwie przejść dla pieszych i przejazdów rowerowych – informacje o przejściach i przejazdach pozyskano ze zwektoryzowanych danych przestrzennych pobranych z map OpenStreetMap [204];
- **etap V** - wyłączenie postojów w sąsiedztwie przejazdów kolejowych – informacje o przejazdach pozyskano ze zwektoryzowanych danych przestrzennych pobranych z map OpenStreetMap [204].

Procedurę I etapu weryfikacji postojów przedstawia poniższy pseudokod:

```
dla postojów w pliku z zestawem postojów:  
    jeżeli postój wystąpił poza obszarem Krakowa to odrzuć dany  
    postój z zestawu postojów  
    w przeciwnym razie zostaw dany postój w zestawie postojów  
    koniec warunku
```

Procedurę II etapu weryfikacji postojów przedstawia poniższy pseudokod:

```
dla postojów w pliku z zestawem postojów po I etapie filtrowania:  
    jeżeli dystans pomiędzy lokalizacją postoju, a lokalizacją  
    którejkolwiek wypożyczalni jest mniejszy od 10 m to odrzuć  
    dany postój z zestawu postojów  
    w przeciwnym razie zostaw dany postój w zestawie postojów  
    koniec warunku
```

III etap filtrowania postojów opisać można w następujący sposób:

dla postojów w pliku z zestawem postojów po II etapie filtrowania:
jeżeli czas trwania postoju **jest większy od 30 s** **to** zostaw dany postój w zestawie postojów
w przeciwnym razie odrzuć dany postój z zestawu postojów
koniec warunku

Etap IV filtrowania postojów został przeprowadzony według poniższej procedury:

dla postojów w pliku z zestawem postojów po III etapie filtrowania:
jeżeli dystans pomiędzy lokalizacją postoju, a lokalizacją któregośkolwiek przejścia dla pieszych **lub** przejazdu rowerowego **jest mniejszy od 50 m** **to** odrzuć dany postój z zestawu postojów
w przeciwnym razie zostaw dany postój w zestawie postojów
koniec warunku

Ostatni etap weryfikacji postojów obrazuje poniższy pseudokod:

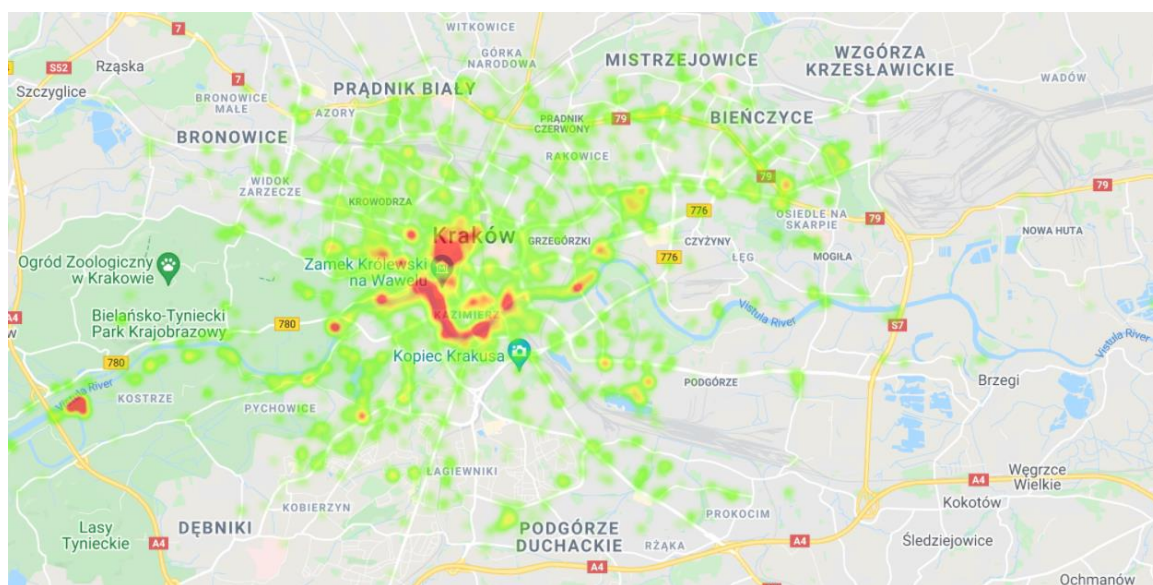
dla postojów w pliku z zestawem postojów po IV etapie filtrowania:
jeżeli dystans pomiędzy lokalizacją postoju, a lokalizacją któregośkolwiek przejazdu kolejowego **jest mniejszy od 50 m** **to** odrzuć dany postój z zestawu postojów
w przeciwnym razie zostaw dany postój w zestawie postojów
koniec warunku

Wyniki weryfikacji postojów według zaproponowanej metodyki opisane zostały w podrozdziale 3.2.2.

3.2.2. Wyniki weryfikacji danych o liczbie i czasie postojów użytkowników rowerów miejskich

W próbie wszystkich postojów znajdowały się 54032 rekordy, spośród których 53989 to postoje na terenie Krakowa (43 postoje odrzucone w ramach etapu I filtrowania). W II etapie filtrowania odrzucone zostały 21863 postoje, w III odrzucono 17043 postoje, w IV etapie

6362, natomiast w ostatnim etapie 77. To pozwoliło na otrzymanie wyfiltrowanej próbki postojów liczącej 8644 rekordy, co stanowi 15% wszystkich postojów. Nie licząc postojów rowerzystów w sąsiedztwie wypożyczalni, próbka po V etapie filtrowania stanowi 32% wszystkich postojów w Krakowie, co pokazuje, że badane zjawisko postojów niezwiązanych z ruchem drogowym nie jest zjawiskiem marginalnym. Po przeprowadzonym procesie filtrowania ponownie sprawdzono rozkład przestrzenny postojów w postaci mapy ciepła (Rys. 3.6).



Rys. 3.6. Mapa ciepła postojów w wyfiltrowanej próbce danych

(źródło: opracowanie własne, mapa: Google Maps)

Ponadto określono podstawowe statystyki wyfiltrowanych postojów (średnia, odchylenie standardowe, wartość minimalna i maksymalna oraz kwantyle: 25%, 50% i 75%). Zostały one przedstawione w Tab. 3.3.

Tab. 3.3. Statystyki wyfiltrowanej próbki postojów

	Średnia	Odch. stand.	Min	25%	50%	75%	Max
Czas postojów [min]	4,66	9,32	0,52	1,33	1,50	4,25	138,17

(źródło: opracowanie własne)

Powyższe dane pokazują, że w wyfiltrowanej próbce danych o postojach najkrótszy z nich trwał 31 s, natomiast najdłuższy 2 h 18 min 10 s przy czym średni postój trwał 4 min 40 s. Przyjęta metodyka pozwoliła zatem wyeliminować z próbki pierwotnej wartości anormalne, np. postój o długości ponad 8 h, co wynikało najprawdopodobniej z pozostawienia roweru przy stacji bez jego zwrócenia w systemie.

3.2.3. Agregacja danych o liczbie i czasie postojów użytkowników rowerów miejskich

W celu dalszych analiz postoje zostały zagregowane do siatki, która podzieliła Kraków na obszary o wymiarach 300×300 m. Wymiar ten przyjęty został z uwagi na analizę lokalizacji postojów i ich koncentrację w obrębie Starego Miasta. Po dokonanej inwentaryzacji wnętrza urbanistycznych i oceny jednorodności tkanki na przykładzie ulicy Floriańskiej mierzącej 335 m, Rynku Głównego o wymiarach 200×200 m (z przekątną od naroża kamienicy przy rogu ulic Wiślniej i św. Anny do naroża kamienicy przy rogu ulic Mikołajskiej i Floriańskiej równą 295 m), ulicy Grodzkiej mierzącej 650 m (2×325 m) określono, że długość 300 m będzie wystarczająca pod kątem jednorodności otoczenia. W doborze rozmiaru siatki posilkowano się także dystansem, który jest rekomendowany jak chodzi o dostępność miejsc rozrywki i odpoczynku – powinny one być dostępne w ciągu 5–10 minut pieszo, co odpowiada odległości 300–800 m [205]. Skrajne współrzędne siatki zostały dobrane tak, by siatka swym zasięgiem obejmowała Kraków. Opisywana siatka przestrzenna (*Grid*) może być opisana jako macierz:

$$Grid = \|\|Field_{ij}\|\|^{N \times M}, \quad i = 1 \dots N, \quad j = 1 \dots M \quad (9)$$

gdzie $Field_{ij}$ jest kwadratowym polem reprezentującym część siatki, do której przypisywane będą określone wartości. Wymiar siatki określają zmienne N i M , które dla Krakowa wynoszą 60 i 100, dzięki czemu pełna siatka posiada 6000 pól, z czego Kraków swym zasięgiem obejmuje 3582 pola.


Do każdego z pól w przygotowanej siatce przypisana została liczba postojów według poniższej metody:

dla każdego pola w siatce z przypisaną wartością początkową **równą 0**:
jeżeli lokalizacja postoju mieści się w danym polu **to** **zwiększ** wartość przypisaną danemu polu o 1
w przeciwnym razie pozostaw wartość przypisaną polu
koniec warunku

Dzięki powyższej metodzie można określić, że każdemu polu (*Field*) przypisano jeden parametr je opisujący, tj. liczba postojów (n_{st}):

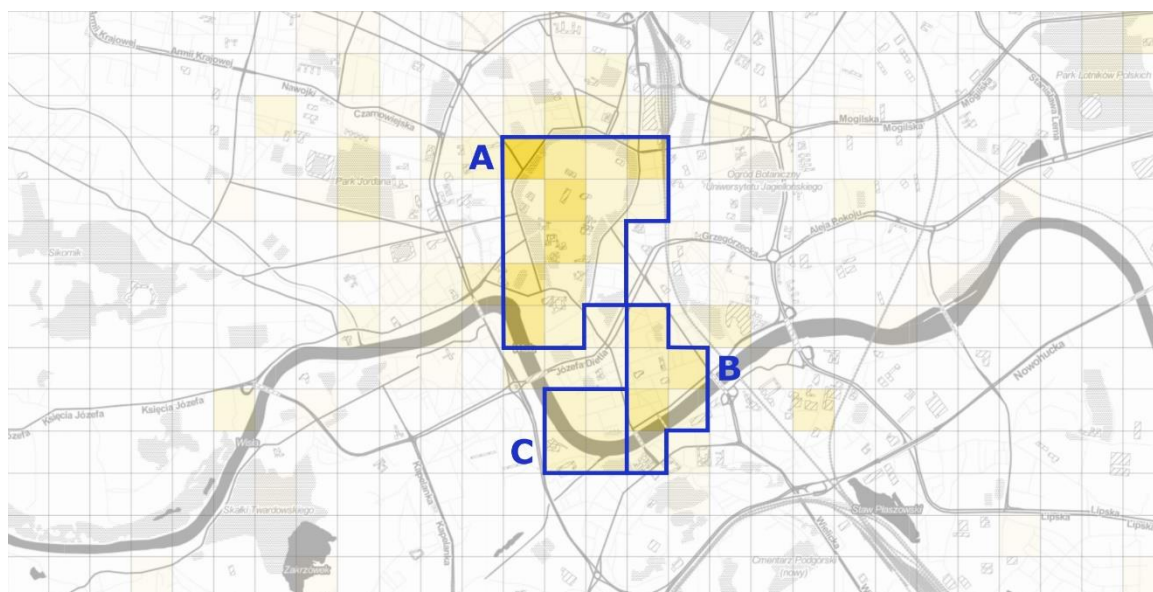
$$Field = \{n_{st}\} \quad (10)$$

Efekt przypisania liczby postojów do pól siatki widoczny jest na Rys. 3.7, który także jest formą mapy ciepła, z tą różnicą, że zastosowano w niej skalę kolorystyczną zbudowaną z odcieni jednej barwy – im ciemniejszy kolor tym większe występowanie opisywanego zjawiska.



Rys. 3.7. Siatka z przypisaną liczbą postojów użytkowników systemu Wavelo
(źródło: opracowanie własne)

Maksymalna liczba postojów, która została przypisana jednemu polu siatki wynosi 285. Analiza powyższej mapy ciepła pokazuje, że najwięcej postojów wystąpiło na obszarze Starego Miasta. Obrazuje to lepiej Rys. 3.8, na którym widać zbliżenie na centrum Krakowa.



Rys. 3.8. Obszary z największą liczbą postojów: A - Stare Miasto z Rynkiem Głównym i Wzgórzem Wawelskim, B - Kazimierz i Stare Podgórze, C – Bulwary Wiślane u ujścia Wilgi
(źródło: opracowanie własne)

Powyższy rysunek pokazuje, że najwięcej postojów występuje w polach, które swym zasięgiem obejmują:

- wnętrze Plant z Rynkiem Głównym i ulicą Grodzką, będącą częścią Drogi Królewskiej, Wzgórze Wawelskie z Bulwarem Czerwieńskim (obszar A na Rys. 3.8),
- wschodnia część Kazimierza z Placem Nowym oraz Bulwary Wiślane po stronie Kazimierza i Starego Podgórze w sąsiedztwie Kładki Ojca Bernatka (obszar B na Rys. 3.8),
- zachodnia część Kazimierza i Bulwary Wiślane w rejonie zakola Wisły z ujściem Wilgi (obszar C na Rys. 3.8).


W podobny sposób jak w przypadku określenia liczby podróży w każdym z pól siatki przypisano jej polom łączny czas postojów w danym polu:

dla każdego pola w siatce z przypisaną wartością początkową **równą 0**:
jeżeli lokalizacja postoju mieści się w danym polu **to**
zwiększ wartość przypisaną danemu polu o czas danego postoju
w przeciwnym razie pozostaw wartość przypisaną polu
koniec warunku

Dzięki powyższej metodzie można określić, że każdemu polu (*Field*) przypisano jeden parametr je opisujący, tj. sumaryczny czas postojów (t_{st}):

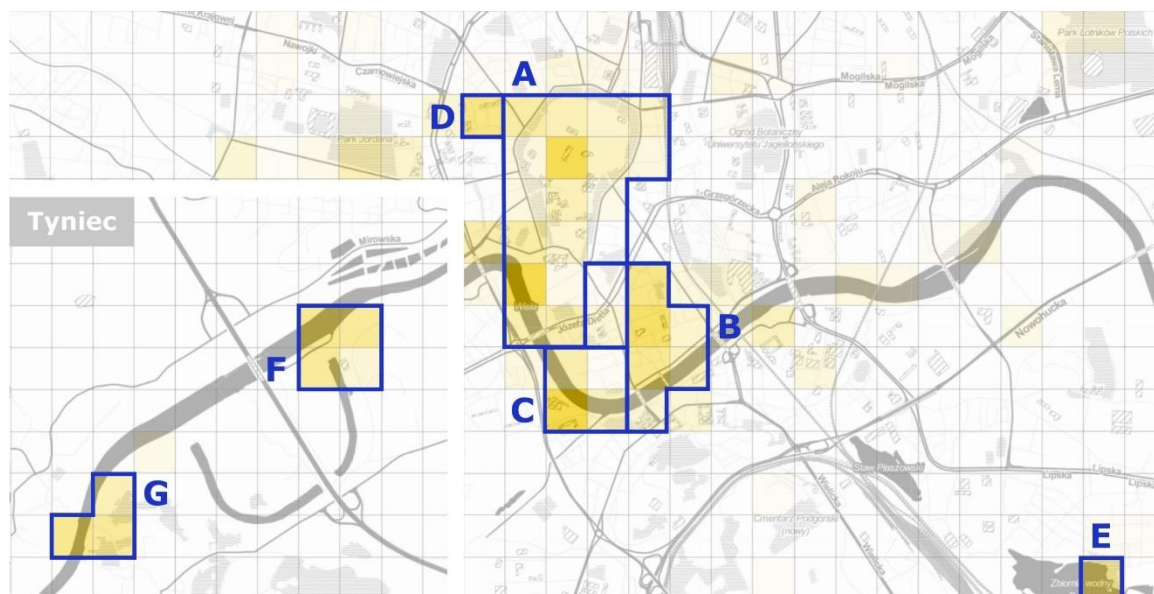
$$Field = \{t_{st}\} \quad (11)$$

Dzięki powyższej procedurze uzyskano siatkę, która ukazana jest na Rys. 3.9.



Rys. 3.9. Siatka z przypisanym łącznym czasem [w min] postojów użytkowników systemu Wavelo
(źródło: opracowanie własne)

Maksymalny sumaryczny czas postojów w badanym okresie, który został przypisany jednemu polu siatki, wynosi 17 h 17 min 25 s. Analiza powyższej mapy ciepła pokazuje, że najdłużej postoje trwały na obszarze Starego Miasta, ale także w dwóch lokalizacjach na zachodzie Krakowa, w sąsiedztwie Wisły. Szczegóły widoczne są na Rys. 3.10.



Rys. 3.10. Obszary z najdłuższym czasem postojów: A - Stare Miasto z Rynkiem Głównym i Wzgórzem Wawelskim, B - Kazimierz i Stare Podgórze, C - okolice dawnego Hotelu Forum, D – ul. Dolnych Młynów, E - Zalew Bagry, F - Ośrodek Sportu Kolna, G - Zakon Benedyktynów w Tyńcu

(źródło: opracowanie własne)

Powyższy rysunek pokazuje, że największy sumaryczny czas postojów występuje w polach, które swym zasięgiem obejmują:

- wnętrze Plant z Rynkiem Głównym i Wzgórze Wawelskie z Bulwarem Czerwieńskim (obszar A na Rys. 3.10),
- Kazimierz z Placem Nowym oraz Bulwary Wiślane po stronie Kazimierza i Starego Podgórze w sąsiedztwie Kładki Ojca Bernatka (obszar B na Rys. 3.10),
- okolice dawnego hotelu Forum z klubokawiarnią Forum Przestrzenie (obszar C na Rys. 3.10),
- okolice nieistniejącego już kompleksu gastronomicznego przy ul. Dolnych Młynów (obszar D na Rys. 3.10)
- Zalew Bagry (obszar E na Rys. 3.10),
- Ośrodek Rekreacji i Sportu Kolna wraz z torem kajakowym (obszar F na Rys. 3.10),
- Zakon Benedyktynów w Tyńcu (obszar G na Rys. 3.10).

Przedstawiona analiza liczby oraz czasu postojów potwierdza tezę, że możliwe jest wskazanie dwóch obszarów Krakowa, mianowicie Rynku Głównego wraz ze zlokalizowanymi w jego pobliżu zabytkami oraz Wzgórze Wawelskiego, które od wieków stanowią wiodące atrakcje,

stanowiąc fundamenty atrakcyjności Krakowa, przyciągając zarówno turystów jak i mieszkańców [206].

3.2.4. Dychotomizacja danych o liczbie i czasie postojów użytkowników rowerów miejskich

W toku analiz postojów użytkowników systemu rowerów miejskich Wavelo zaistniała potrzeba określenia liczby i sumarycznego czasu postojów w formie zmiennej dychotomicznej – 0 jeżeli postojów jest mało (lub ich sumaryczny czas jest niewielki) lub 1 gdy postojów jest dużo (lub ich sumaryczny czas jest znaczący). Aby określić wartość progową dla wartości 0 i 1 dla liczby postojów przyjęto percentyl rzędu 0,95. Obliczony został on dla niezerowych pól w siatce z przypisaną polom liczbą postojów w danym polu i wyniósł 49 postojów. Oznacza to, że wartość 1 zostanie przypisana tym polom, w których wystąpiła większa liczba postojów niż w 95% pozostałych niezerowych pól w siatce z liczbą postojów. Na tej podstawie odbyło się przypisanie wartości zero-jedynkowych polom w siatce z liczbą postojów:

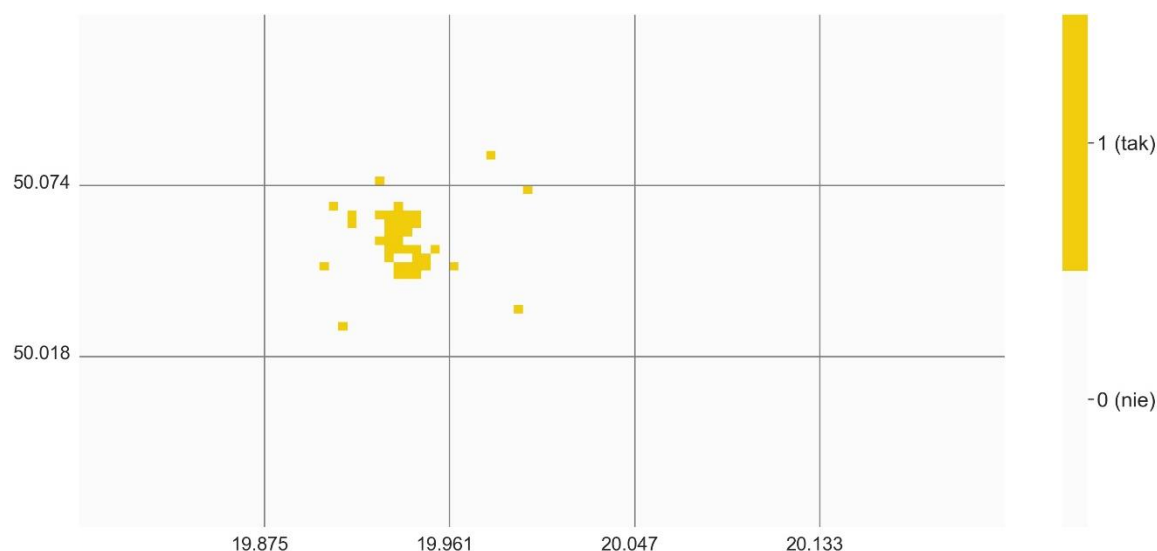
dla każdego pola w siatce z przypisaną wartością początkową **równą 0**:

jeżeli wartość pola o tych samych współrzędnych w siatce z liczbą postojów **znajduje się w 95. percentylu** niezerowych pól w siatce z liczbą postojów **to przypisz** danemu polu wartość **1**

w przeciwnym razie przypisz danemu polu wartość **0**

koniec warunku

Efekt przypisania wartości zero-jedynkowych do pól siatki liczby postojów widoczny jest na Rys. 3.11. Łącznie wartość 1 przypisana została do 41 pól.




Rys. 3.11. Siatka z polami, w których wystąpiła duża liczba postojów użytkowników systemu Wavelo (źródło: opracowanie własne)

Aby określić wartość progową dla wartości 0 i 1 dla sumarycznego czasu postojów przyjęto percentyl rzędu 0,95. Obliczony został on dla niezerowych pól w siatce z przypisanym polem sumarycznym czasem postojów w danym polu i wyniósł 3 h 54 min 10 s. Oznacza to, że wartość 1 zostanie przypisana tym polom, w których wystąpił większy sumaryczny czas postojów niż w 95% pozostałych niezerowych pól w siatce z sumarycznym czasem postojów. Na tej podstawie odbyło się przypisanie wartości zero-jedynkowych polom w siatce z sumarycznym czasem postojów:

dla każdego pola w siatce z przypisaną wartością początkową **równą 0**:
jeżeli wartość pola o tych samych współrzędnych w siatce z sumarycznym czasem postojów **znajduje się w 95. percentylu** niezerowych pól w siatce z sumarycznym czasem postojów **to przypisz** danemu polu wartość 1
w przeciwnym razie przypisz danemu polu wartość 0
koniec warunku

Efekt przypisania wartości zero-jedynkowych do pól siatki sumarycznego czasu postojów widoczny jest na Rys. 3.12. Łącznie wartość 1 przypisana została również do 41 pól.



Rys. 3.12. Siatka z polami, w których wystąpił długi sumaryczny czas postojów użytkowników systemu Wavelo
(źródło: opracowanie własne)

Przygotowane w powyższy sposób zbiory danych opisujące postoje rowerzystów, korzystających z rowerów Wavelo, zostały użyte w procesie modelowania wpływu otoczenia trasy na liczbę i czas postojów użytkowników systemu Wavelo, co zostało opisane w podrozdziale 5.4.

4

||||| Waloryzacja otoczenia trasy

4. Waloryzacja otoczenia trasy

Kluczowym elementem niniejszej dysertacji jest połączenie zmiennych jakościowych i ilościowych w odniesieniu do oceny otoczenia trasy. Z punktu widzenia życia codziennego ważna jest przestrzeń należąca do wszystkich jej użytkowników, np. fragment przestrzeni miasta, bowiem między innymi umożliwia rozwijanie wzajemnych kontaktów pomiędzy nieznanymi sobie osobami poprzez nieograniczone na ogół przebywanie w tym samym miejscu. Taką przestrzeń nazywa się przestrzenią publiczną [207], która w ustawie o planowaniu i zagospodarowaniu przestrzennym z 2003 roku została określona jako *obszar o szczególnym znaczeniu dla zaspokojenia potrzeb mieszkańców, poprawy jakości ich życia i sprzyjający nawiązywaniu kontaktów społecznych ze względu na ich położenie oraz cechy funkcjonalno-przestrzenne* [208]. Jej konstruowaniem, badaniem i kształtowaniem zajmuje się wiele nauk, takich jak: architektura, urbanistyka, historia, socjologia, ekologia, planowanie przestrzenne, psychologia, antropologia, ekonomia, nauki polityczne, prawo, nauki techniczne oraz geografia humanistyczna. Przestrzeń miejska jako typ podprzestrzeni geograficznej odznacza się specyficzną organizacją, funkcją, fizjonomią oraz statusem prawnym. Głównym atrybutem owej przestrzeni jest jej urządzenie zgodne z indywidualnymi i zbiorowymi potrzebami mieszkańców miast [209].

Jednym z aspektów jaki wiąże się z analizą przestrzeni jest jej waloryzacja. Najczęściej miejscem stanowiącym przedmiot szczególnego zainteresowania władz oraz obywateli, jest centrum, punkt ciężenia społecznego i kulturalnego, teren spotkań, symbol rozkwitu i dobrobytu miasta albo jego upadku. Jednocześnie miejsca, w których przebywamy na co dzień i które odwiedzamy jako turyści, skłaniają do refleksji i budzą emocje. Szczególna rola przypada tu przestrzeniom publicznym miasta. Stanowią one swoisty „kod genetyczny miasta”, według którego może się ono odtwarzać ze zniszczeń lub degradacji. Jego podstawowym nośnikiem jest natomiast kultura – utrwalająca kształt tych przestrzeni [210]. Na potrzeby oceny gospodarowania przestrzenią miast znane są różne metody. Należą do nich m.in. badania rynku i zachowań konsumentów, badania jakości przestrzeni (oceny piękna scenerii, mapa wartości emocjonalnej), metody waloryzacji środowiska (wyceny dóbr nierynkowych), które znajdują także zastosowanie w badaniu przestrzeni publicznych miast [211]. Przestrzenie publiczne miasta są w różny sposób odbierane przez ich użytkowników. O rodzaju wrażeń decyduje wiele czynników, wśród których na plan pierwszy wysuwa się stopień możliwości realizacji potrzeb społecznych. Nie bez znaczenia są także takie kwestie jak sposób jej fizycznego ukształtowania, w tym rodzaj i charakter detalu. Przestrzenie te bowiem decydują o krajobrazie miasta oraz czytelności jego struktury, a więc harmonii pomiędzy funkcją i formą

[210]. Istotną rolę w odbiorze przestrzeni i jej ocenie spełniają walory krajobrazowe miasta, przez co rozumie się zespół elementów środowiska naturalnego oraz elementów pozaprzyrodniczych, które, wspólnie lub każde z osobna, są przedmiotem zainteresowania mieszkańców i turystów. Walory kulturowe są jednym z głównych elementów atrakcyjności turystyczno-krajobrazowej miast, które w wielu wypadkach stanowią trzon ich potencjału turystycznego. Walory krajobrazowe miast nie ograniczają się jedynie do elementów kulturowych. W wielu wypadkach istotną rolę w przyciąganiu ruchu turystycznego odgrywają także walory przyrodnicze, szczególnie z punktu widzenia ich wartości poznawczych [212].

Waloryzacja przestrzeni geograficznej jest postępowaniem badawczym mającym na celu ocenę wartości owej przestrzeni z punktu widzenia realizacji określonych potrzeb człowieka [209]. Krajobraz kulturowy tworzy historycznie ukształtowany fragment przestrzeni geograficznej, powstały w wyniku zespolenia oddziaływań środowiskowych i kulturowych, tworzących specyficzną strukturę, która objawia się regionalną odrębnością, postrzeganą jako swoista fizjonomia [213]. W literaturze znaleźć można kilka metod związanych z waloryzacją krajobrazu, który można oceniać, używając kryteriów takich jak: dawność, historyczność, autentyczność, wartość estetyczna, harmonia, wyjątkowość czy wartość emocjonalna. Wśród metod oceny krajobrazu wymienić można: metodę macierzy wartości Bajerowskiego, metodę krzywej wrażeń Wejcherta, metodę WIT Litwin, metodę SBE czy metodę WNET [214], [215]. Metoda macierzy Bajerowskiego opiera się głównie na kryterium wartości estetycznej. Polega ona na wykorzystaniu informacji zawartych w treści map topograficznych oraz map ewidencji gruntów, bowiem wiele cech przestrzeni można zidentyfikować jedynie w wyniku analiz materiałów kartograficznych [215]. Metoda krzywej wrażeń przedstawia graficzne napięcia wrażeń i doznań emocjonalnych, występujących u obserwatora w trakcie przesuwania się ciągiem czasoprzestrzennym [214]. Ilustracja ta stanowi umowne i względne porównanie oddziaływania kolejnych obrazów. Doznania i oceny te mają charakter subiektywny, jednak przyjmuje się, że istnieje wybrana grupa obserwatorów reagująca podobnie na widziane obrazy. W literaturze spotyka się również metodę dyferencjału semantycznego – to specyficzna metoda ilościowej oceny obrazu (wyobrażeń) obiektu, jaki posiada badana osoba, opracowana przez C. E. Osgooda, G. J. Succiego i P. H. Tannenbauma w 1957 roku. Badanie to można przeprowadzić, odnosząc się do kategorii ładu przestrzennego takich jak: ład urbanistyczno-architektoniczny, ład funkcjonalny, ład estetyczny, ład społeczny oraz ład ekologiczny [216].

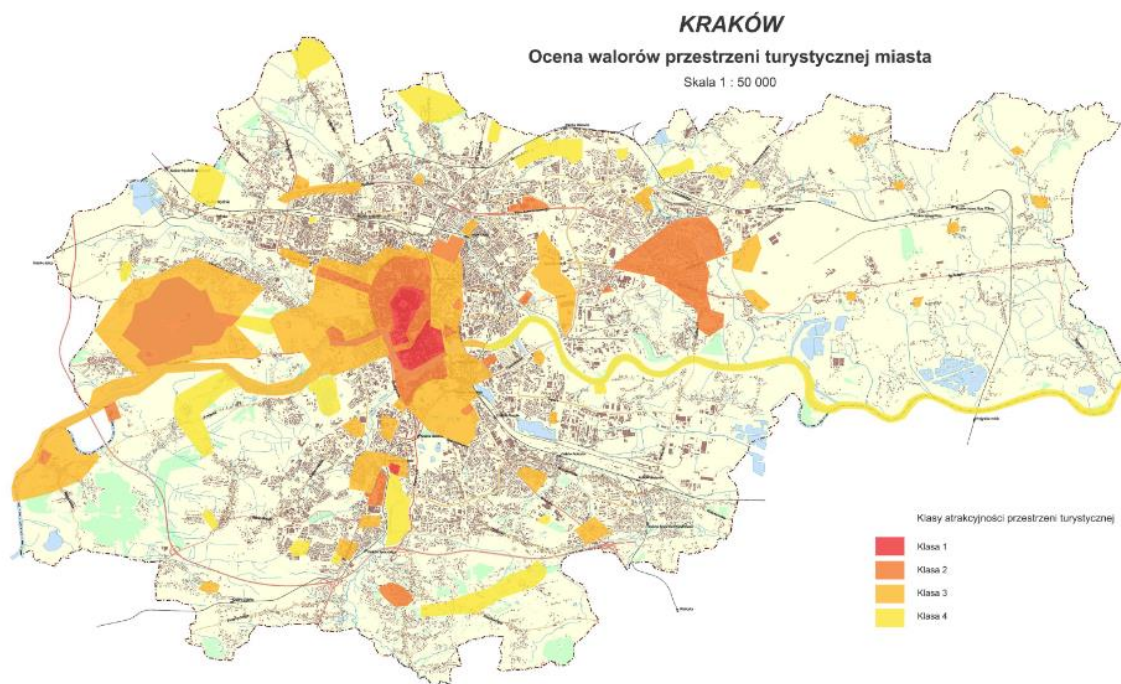
W przypadku waloryzacji przestrzeni Krakowa odnaleziono w literaturze badania związane z waloryzacją przestrzeni turystycznej miasta. Ruch turystyczny w Krakowie od dawna skupiał się w historycznym centrum miasta (Stare Miasto, Wawel i Kazimierz), czyli w obszarze układu

urbanistycznego wpisanego na listę światowego dziedzictwa UNESCO, a obecnie przenosi się także na dzielnice sąsiednie – Kleparz, Krowodrzę, Zabłocie i Stare Podgórze oraz do Nowej Huty, co jest m.in. efektem działań dekoncentrujących ruch turystyczny. W następstwie przeobrażeń własnościowych oraz wzrastającego ruchu turystycznego Śródmieście Krakowa zmieniło charakter z dzielnicy mieszkaniowo-usługowej na usługowo-mieszkaniową. Równocześnie prowadzona rewitalizacja Starego Miasta sprzyjała rozwojowi turystyki, poprawiając stan estetyczny i sanitarny dzielnicy [217]. Działania związane z rozwojem ruchu turystycznego wpłynęły też na zwiększenie atrakcyjności określonych przestrzeni miasta dla mieszkańców Krakowa.

W 2008 roku na zlecenie Biura ds. Turystyki Urzędu Miasta Krakowa na Uniwersytecie Jagiellońskim opracowano raport dotyczący waloryzacji przestrzeni miejskiej dla potrzeb turystyki. Celem oceny przestrzeni miasta Krakowa było określenie jej atrakcyjności z punktu widzenia realizacji potrzeb turystycznych osób przyjezdnych. Opracowanie to dotychczas nie zostało zaktualizowane. Na potencjał turystyczny przestrzeni geograficznej Krakowa, będący przedmiotem oceny, składają się zasoby turystyczne oraz infrastruktura turystyczna, dlatego do procedury oceniającej Autorzy wybrali następujące cechy:

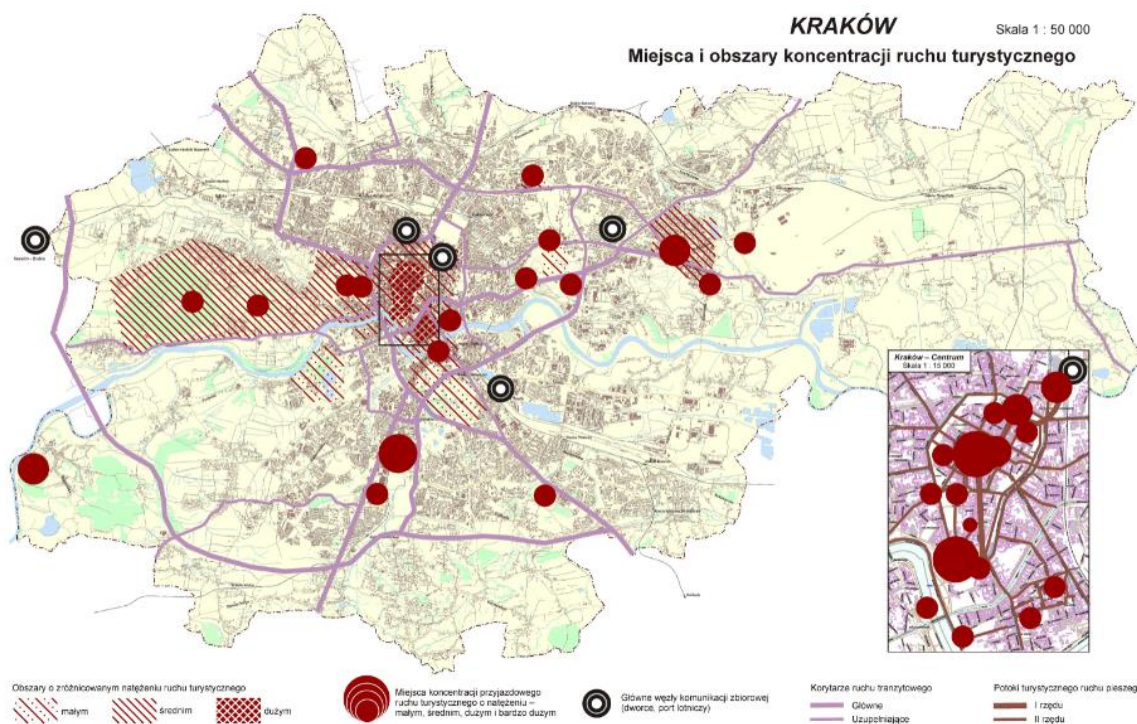
- walory przyrodnicze przestrzeni miasta;
- walory kulturowe przestrzeni miasta;
- zagospodarowanie w zakresie bazy noclegowej;
- zagospodarowanie w zakresie bazy gastronomicznej;
- zagospodarowanie w zakresie bazy towarzyszącej [209].

Analiza powyższych aspektów związanych z przestrzenią turystyczną pozwoliła na przygotowanie oceny walorów przestrzeni turystycznej Krakowa i sklasyfikowanie czterech grup przestrzeni, co widać na Rys. 4.1. Do klasy I zakwalifikowano obszary Starego Miasta i Kazimierza, do klasy II tereny przyległe wraz ze Starym Podgórzem, a także starą Nową Hutę czy tereny Lasu Wolskiego.



Rys. 4.1. Ocena walorów przestrzeni turystycznej Krakowa
(źródło:[209])

Analiza przestrzeni turystycznej Krakowa przez badaczy z Uniwersytetu Jagiellońskiego pozwoliła też na określenie miejsc i obszarów koncentracji ruchu turystycznego (Rys. 4.2).



Rys. 4.2. Miejsca i obszary koncentracji ruchu turystycznego w Krakowie
(źródło:[209])

Powyższe materiały posłużyły do oceny przestrzeni turystycznej Krakowa, jednakże wstępna analiza mapy ciepła z liczbą i czasem postojów użytkowników systemu rowerów miejskich Wavelo pokazała, że miejsca te są popularne również wśród użytkowników systemu, którzy w podobnych miejscach zatrzymywali się rekreacyjnie. Z tego powodu do oceny atrakcyjności otoczenia trasy postanowiono zastosować podobne cechy przestrzeni, tj. występujące na jej obszarze walory krajobrazowe w postaci walorów kulturowych i przyrodniczych, które pojawiają się w literaturze także do oceny atrakcyjności otoczenia korytarzy tras rowerowych [135]. Należy mieć przy tym na uwadze, że walory krajobrazu kulturowego i przyrodniczego określane są często w sposób subiektywny. Zaproponowana metoda waloryzacji otoczenia trasy opiera się na analizie walorów krajobrazu kulturowego w postaci różnych kategorii zabytków oraz walorów krajobrazu przyrodniczego w postaci parków, cieków wodnych i zbiorników wodnych. Dla przygotowanej w podrozdziale 3.2.3. siatki Krakowa przeanalizowano występowanie zabytków, parków, cieków wodnych i zbiorników wodnych, co stanowi liczbowe przedstawienie miar jakości otoczenia. Zaproponowana metodyka waloryzacji otoczenia trasy została przedstawiona w poniższych podrozdziałach.

4.1. Analiza walorów kulturowych na potrzeby opracowania waloryzacji otoczenia trasy

Dane na temat zabytków wpisanych do rejestru zabytków Krakowa lub gminnej ewidencji zabytków pozyskano z Obserwatorium Miasta Krakowa, będącego częścią Miejskiego Systemu Informacji Przestrzennej [218]. Stosując przyjętą w Obserwatorium klasyfikację zabytków, podzielono je na następujące grupy:

- zabytki architektury i budownictwa – obejmujące budynki różnego przeznaczenia: mieszkalne, sakralne, gospodarcze, etc.;
- zabytki techniki – obejmujące budowle inżynierskie, np. Bulwary Wiślane, Aleje Waszyngtona, wiadukt Talowskiego na ul. Lubicz;
- zabytkowe obszary i tereny zielone, np. Planty, Park Krakowski, Młynówka Królewska, obszar pasa startowego dawnego lotniska Rakowice-Czyżyny;
- układy urbanistyczne, np. układ urbanistyczny Starego Miasta, Nowego Świata czy Nowej Huty.

Dla każdej z grup wymienionych powyżej stworzono, analogicznie do postojów, siatkę, w której każde z pól ma przypisaną wartość. Co ważne siatka ta ma te same wymiary jak


w przypadku postojów. Jeśli chodzi o pierwszą grupę zabytków, tj. zabytki architektury i budownictwa, każdemu polu przypisana została liczba zabytków z tej grupy, która zlokalizowana jest na obszarze danego pola siatki. Z uwagi na punktowy charakter zabytków z tej kategorii następowało to w oparciu o centroidę zabytku w następujący sposób:

dla każdego pola w siatce z przypisaną wartością początkową **równą 0**:
jeżeli centroida zabytku architektury i budownictwa mieści się w danym polu **to zwiększ** wartość przypisaną danemu polu o 1
w przeciwnym razie pozostaw wartość przypisaną polu
koniec warunku

Dzięki powyższej metodzie można określić, że każdemu polu (*Field*) przypisano jeden parametr je opisujący, tj. liczbę zabytków architektury i budownictwa (z_1):

$$Field = \{z_1\} \quad (12)$$

Efekt przypisania liczby zabytków z kategorii architektury i budownictwa polom siatki widoczny jest na Rys. 4.3.



Rys. 4.3. Siatka z przypisaną liczbą zabytków w kategorii architektura i budownictwo
 (źródło: opracowanie własne)

Maksymalna liczba zabytków architektoniczno-budowlanych, która została przypisana jednemu polu siatki wynosi 109 dla obszaru w sąsiedztwie Rynku Głównego. Dodatkowo na potrzeby analizy atrakcyjności otoczenia powyższe dane przekształcono w zmienną dychotomiczną – 0 jeżeli zabytków tej kategorii jest mało lub 1 gdy jest ich dużo. Aby określić wartość progową dla wartości 0 i 1 dla liczby zabytków kategorii architektura i budownictwo przyjęto percentyl rzędu 0,95. Obliczony został on dla niezerowych pól w siatce z przypisaną połom liczbą zabytków w danym polu i wyniósł 51 zabytków. Oznacza to, że wartość 1 zostanie przypisana tym polom, w których znajduje się więcej zabytków architektoniczno-budowlanych niż w 95% pozostałych niezerowych pól w siatce z liczbą zabytków. Na tej podstawie odbyło się przypisanie wartości zero-jedynkowych połom w siatce z liczbą zabytków:

dla każdego pola w siatce z przypisaną wartością początkową **równą 0**:
jeżeli wartość pola o tych samych współrzędnych w siatce z liczbą zabytków arch-bud **znajduje się w 95. percentylu** niezerowych pól w siatce z liczbą zabytków arch-bud **to przypisz** danemu polu wartość 1
w przeciwnym razie przypisz danemu polu wartość 0
koniec warunku

Dzięki powyższej metodzie można określić, że każdemu polu (*Field*) przypisano jeden parametr je opisujący, tj. określone zero-jedynkowo występowanie zabytków architektoniczno-budowlanych w danym polu ($z_{1'}$):

$$Field = \{z_{1'}\}, \quad z_{1'} = \{0, 1\} \quad (13)$$

Efekt przypisania wartości zero-jedynkowych do pól siatki liczby zabytków architektoniczno-budowlanych widoczny jest na Rys. 4.4a. Łącznie wartość 1 przypisana została do 43 pól.

W przypadku pozostałych trzech kategorii zabytków, tj. zabytków techniki, zabytkowych obszarów i terenów zielonych oraz układów urbanistycznych zastosowano od razu przypisanie wartości zero-jedynkowych, które jednak w tym wypadku, z uwagi na obszarowy charakter zabytków, oznaczają obecność przynajmniej jednego zabytku danej kategorii w określonym polu. Wartość 0 oznacza brak takiego zabytku, wartość 1 znaczy, że zabytek danej kategorii

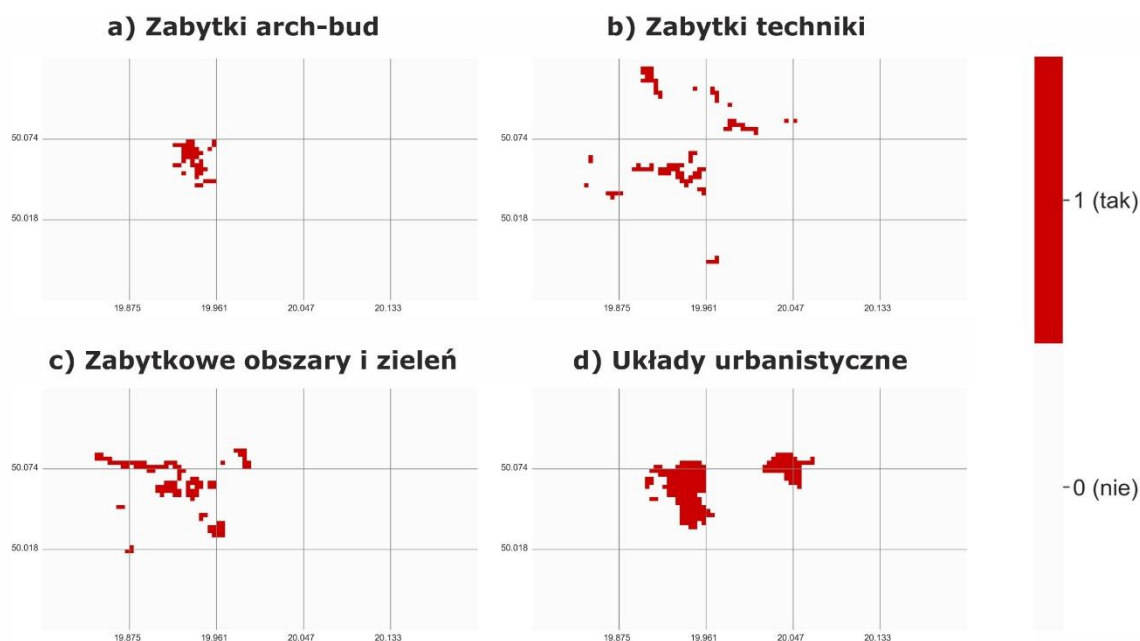
znajduje się w określonym polu. Przypisanie polu obecności zabytku danej kategorii odbyło się na podstawie procedury:

dla każdego pola w siatce z przypisaną wartością początkową **równą 0**:
jeżeli którykolwiek zabytek określonej kategorii i dane pole mają część wspólną **to przypisz** danemu polu wartość 1
w przeciwnym razie pozostaw wartość przypisaną polu
koniec warunku

Przy użyciu opisanej powyżej metody możliwe jest przypisanie każdemu polu (*Field*) jednego parametru je opisującego, tj. określenie zero-jedynkowo występowania zabytków określonej kategorii w danym polu (z):

$$Field = \{z\}, \quad z = \{0, 1\} \quad (14)$$

Dzięki zastosowanej metodzie otrzymano 92 pola (Rys. 4.4b), w których występują zabytki techniki, 105 pól z zabytkowymi obszarami lub terenami zielonymi (Rys. 4.4c) i 187 pól z układami urbanistycznymi (Rys. 4.4d).



Rys. 4.4. Siatki z polami, w których występują walory kulturowe określonej kategorii
 (źródło: opracowanie własne)

4.2. Analiza walorów przyrodniczych na potrzeby opracowania waloryzacji otoczenia trasy

Dane na temat walorów przyrodniczych również pozyskano z Obserwatorium Miasta Krakowa [218]. Do analizy wzięto pod uwagę następujące grupy:

- parki;
- parki leśne;
- ciek wodne;
- zbiorniki wodne.

W przypadku cieków i zbiorników wodnych odrzucono te, które nie cechują się dogodną infrastrukturą rowerową. Dokonano tego z uwagi na fakt, iż przygotowywana waloryzacja otoczenia trasy służyć ma określeniu związków z parametrami podróży rowerzystów, a więc dany obszar musi być dla nich teoretycznie dostępny. Z tego powodu w waloryzacji otoczenia trasy, z punktu widzenia rowerzystów, odrzucona została np. rzeka Wilga lub odcinek Wisły od Łęgu w dół rzeki do granicy miasta, z uwagi na brak infrastruktury umożliwiającej poruszanie się po wałach wzdłuż rzeki.

Dla każdej z grup wymienionych powyżej stworzono, analogicznie do walorów kulturowych, siatkę, w której każde z pól ma przypisaną wartość 0 lub 1. Z uwagi na obszarowy charakter walorów przyrodniczych przypisane wartości oznaczają obecność przynajmniej jednego waloru przyrodniczego danej kategorii w określonym polu. Wartość 0 oznacza brak takiego waloru, wartość 1 oznacza, że walor przyrodniczy danej kategorii znajduje się w określonym polu. Przypisanie polu obecności waloru danej kategorii odbyło się na podstawie procedury:

dla każdego pola w siatce z przypisaną wartością początkową **równą 0**:

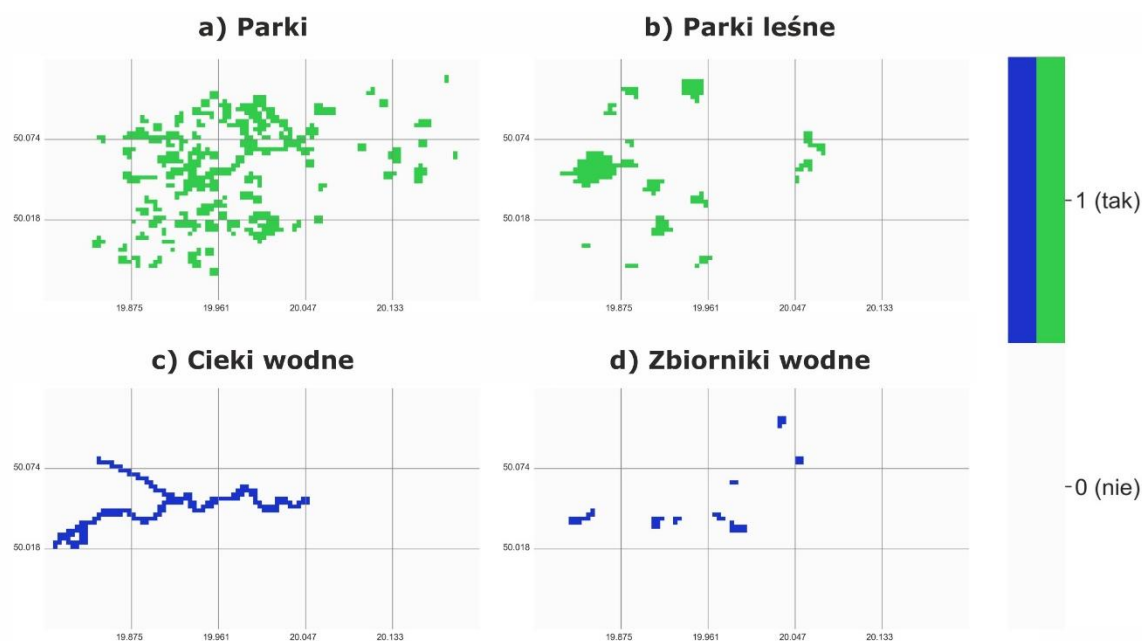
jeżeli którykolwiek walor przyrodniczy określonej kategorii i dane pole mają część wspólną **to przypisz** danemu polu wartość **1**

w przeciwnym razie pozostaw wartość przypisaną polu
koniec warunku

Przy użyciu opisanej powyżej metody możliwe jest przypisanie każdemu polu (*Field*) jednego parametru je opisującego, tj. określenie zero-jedynkowo występowania waloru przyrodniczego określonej kategorii w danym polu (*p*):

$$Field = \{p\}, \quad p = \{0, 1\} \quad (15)$$

Dzięki zastosowanej metodzie otrzymano 585 pól (Rys. 4.5a), w których występują parki, 185 pól z parkami leśnymi (Rys. 4.5b), 163 pola z ciekami wodnymi z towarzyszącą infrastrukturą rowerową (Rys. 4.5c) i 45 pól ze zbiornikami wodnymi z towarzyszącą infrastrukturą rowerową (Rys. 4.5d).



Rys. 4.5. Siatki z polami, w których występują walory przyrodnicze określonej kategorii
(źródło: opracowanie własne)


4.3. Metodyka i wyniki opracowania waloryzacji otoczenia trasy

Zbiory danych przestrzennych otrzymane w ramach działań opisanych w podrozdziałach 4.1 oraz 4.2 posłużyły do opracowania waloryzacji otoczenia trasy. W pierwszej kolejności zbadano korelację wszystkich ośmiu zmiennych opisujących walory kulturowe i walory przyrodnicze:

- z_1 – liczba zabytków architektury i budownictwa;
- z_2 – obecność zabytków techniki;
- z_3 – obecność zabytkowych obszarów i terenów zielonych;
- z_4 – obecność układów urbanistycznych;
- p_1 – obecność parków;
- p_2 – obecność parków leśnych;

- p_3 – obecność cieków wodnych z towarzyszącą infrastrukturą rowerową;
- p_4 – obecność zbiorników wodnych z towarzyszącą infrastrukturą rowerową.

Analiza korelacji w statystyce polega na zbadaniu czy dwie zmienne są ze sobą istotnie statystycznie powiązane. Innymi słowy, sprawdza czy jakiegokolwiek dwie cechy, atrybuty lub własności (wyrażone liczbowo) współwystępują ze sobą. Obliczany współczynnik zawsze waha się od -1 do 1. W analizie korelacji ważne jest to, że nie bada ona związku przyczynowo-skutkowego, a po prostu związek/współwystępowanie dwóch zmiennych [219]. Korelacja powyższych zmiennych przedstawiona została w postaci macierzy korelacji liniowej Pearsona na Rys. 4.6.



Rys. 4.6. Macierz korelacji zmiennych opisujących walory kulturowe i przyrodnicze

(źródło: opracowanie własne)

Powyzsza macierz pokazuje, że pomiędzy zmiennymi nie występuje niemal żadna zależność. Wyjątek stanowią zmienne z_3 i p_1 oraz z_1 i z_3 , które cechuje słaba zależność, a także para zmiennych z_1 i z_4 , tj. zabytki budowlano-architektoniczne i układy urbanistyczne, które cechuje średnia zależność na poziomie 0,64 [220]. Część źródeł podaje jednak inną klasyfikację (J.Guilford'a), mówiącą, że korelację na poziomie 0,5-0,7 należy klasyfikować jako silną/wysoką zależność [219]. Z tego powodu postanowiono odrzucić z katalogu zmiennych opisujących walory kulturowo-przyrodnicze zmienną mówiącą o obecności układu urbanistycznego (z_4). Finalnie do określenia atrakcyjności otoczenia trasy pozostawiono siedem zmiennych (z_1 w wersji dychotomicznej, z_2 , z_3 oraz od p_1 do p_4).

4.3.1. Metodyka opracowania waloryzacji otoczenia trasy

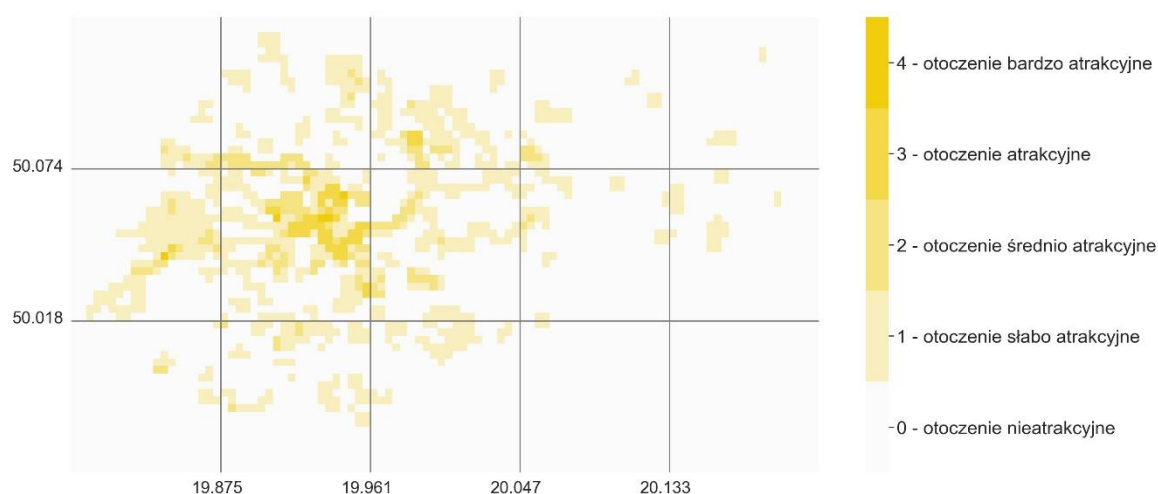
Aby określić atrakcyjność otoczenia zsumowano dla każdego pola wartości wszystkich siedmiu zmiennych i stworzono nową siatkę waloryzacyjną według poniższego pseudokodu:

dla każdego pola w siatce z przypisaną wartością początkową 0 **przypisz** sumę wartości pola o tych samych współrzędnych w siatce z obecnością: (1) zabytków arch-bud, (2) zabytków techniki, (3) zabytkowych obszarów i terenów zielonych, (4) parków, (5) parków leśnych, (6) cieków wodnych, (7) zbiorników wodnych

Opisaną powyżej procedurę przypisania poziomu atrakcyjności otoczenia trasy (A_j) do każdego z pól ($Field_j$) siatki waloryzacyjnej o wymiarach $N \times M$ można przedstawić następująco:

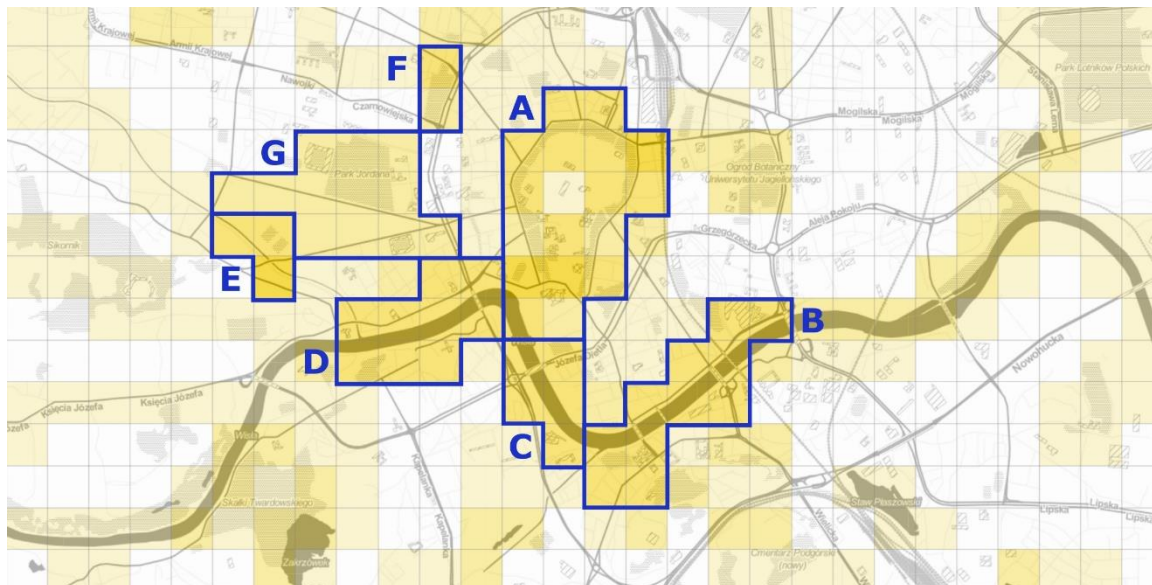
$$Field_j = \{A_j\}, \quad A_j = \sum_{i=1}^3 z_{ij} + \sum_{i=1}^4 p_{ij}, \quad j = \{1, \dots, N \times M\} \quad (16)$$

Teoretyczna suma jednego pola w siatce waloryzacyjnej wynosi 7, jednakże w przypadku opracowanych dla Krakowa danych, w praktyce wyniosła ona 4, tzn., że w jednym polu siatki waloryzacyjnej występują maksymalnie 4 rodzaje walorów kulturowo-przyrodniczych. Wyniki waloryzacji przedstawiono na Rys. 4.7.



Rys. 4.7. Waloryzacja otoczenia trasy
(źródło: opracowanie własne)

Analiza mapy ciepła z podkładem mapowym (Rys. 4.8) potwierdza najwyższy poziom atrakcyjności obszarów położonych w centrum Krakowa.



Rys. 4.8. Najatrakcyjniejsze obszary Krakowa: A - Stare Miasto ze Wzgórzem Wawelskim, B – Bulwary/Stare Podgórze, C – Bulwary/okolice dawnego Hotelu Forum, D – Bulwary/Stare Dębnie, E – Bulwary Rudawy, F - Park Krakowski, G - Błonia z Parkiem Jordana
(źródło: opracowanie własne)

Łącznie na terenie miasta 5 pól otrzymało najwyższą (czwartą) kategorię, 46 pól otrzymało kategorię trzecią, kategoria druga przypisana została 133 polom, kategoria pierwsza 794 polom. Pozostałe 2604 pola przypisaną mają kategorię zerową. Rys. 4.8 pokazuje, że do najbardziej atrakcyjnych obszarów Krakowa należą:

- Stare Miasto z Wzgórzem Wawelskim i Bulwarem Czerwieńskim (obszar A na Rys. 4.8);
- Bulwar Podolski i Kurlandzki oraz obszary Kazimierza i Starego Podgórze w sąsiedztwie Bulwarów Wiślanych (obszar B na Rys. 4.8);
- okolice dawnego hotelu Forum z klubokawiarnią Forum Przestrzenie oraz Bulwary: Wołyński i Kurlandzki (obszar C na Rys. 4.8);
- Bulwar Rodła i Poleski oraz obszary Starych Dębnie i Salwatora w sąsiedztwie Bulwarów Wiślanych (obszar D na Rys. 4.8);
- Bulwary Rudawy (obszar E na Rys. 4.8);
- Park Krakowski im. Marka Grechuty (obszar F na Rys. 4.8);
- Błonia Krakowskie wraz z Parkiem im. Henryka Jordana (obszar G na Rys. 4.8).

4.3.2. Walidacja opracowanej metodyki waloryzacji otoczenia trasy

Otrzymałą w powyższy sposób siatkę waloryzacyjną poddano walidacji. Przygotowana w ramach pracy waloryzacja odnosi się ogółem do przestrzeni i nie uwzględniała jedynie względów turystycznych, ale również rekreacyjne. Rekreacja to forma działania wybrana dobrowolnie przez człowieka ze względu na osobiste zainteresowania i dla odpoczynku, rozrywki lub rozwoju własnej osobowości; podejmowana poza obowiązkami zawodowymi, społecznymi i domowymi, w czasie wolnym od pracy [221]. Przyjęto takie podejście ze względu na brak informacji w próbie danych o podróżach rowerowych Wavelo o typie użytkownika czy wykupionego abonamentu. Stąd też przyjęta ocena atrakcyjności otoczenia trasy skupiła się na walorach rekreacyjnych. Mimo to walidacja siatki waloryzacyjnej odbyła się w porównaniu z przygotowaną dla Urzędu Miasta Krakowa (UMK) oceną przestrzeni turystycznej, z uwagi na zbieżności obszarów rekreacyjnych i turystycznych oraz brak dostępnych innych badań. Porównując waloryzacją przygotowaną dla UMK (Rys. 4.1) oraz tę w ramach niniejszej pracy (Rys. 4.7 i Rys. 4.8) widać, że większość najbardziej atrakcyjnych obszarów pokrywa się. W Tab. 4.1 zestawiono najbardziej atrakcyjne miejsca i obszary według raportu UMK i porównano z wynikami opracowanej waloryzacji, przypisując każdemu z miejsc ocenę według raportu UMK oraz według opracowanej w niniejszej pracy metodyki.

Tab. 4.1. Porównanie ocen w waloryzacji przestrzeni Krakowa

Miejsce/obszar	Oficjalna ocena ⁸	Przyjęta metoda ⁹
Stare Miasto (wewnątrz Plant)	1	3
Wzgórze Wawelskie	1	4
Bulwary Wiślane (od ujścia Rudawy po Most Kotlarski)	2	3
Kazimierz	1	1-2
Ogród Botaniczny	3	2
Błonia	3	2
Bulwary Rudawy	3	3
Park Krakowski im. Marka Grechuty	3	2-3
Park im. Henryka Jordana	3	2
Las Wolski	2	1
Kopiec Piłsudskiego	2	2

⁸ Klasa 1 jest oceną najwyższą, klasa 4 najniższą [209]

⁹ Klasa 4 jest oceną najwyższą, klasa 0 najniższą

Miejsce/obszar	Oficjalna ocena ⁸	Przyjęta metoda ⁹
Stare Podgórze (okolice Kładki Bernatka i Cricoteki)	2	3
Kopiec Krakusa	3	2
Zalew Bagry	-	2
Sanktuaria w Łagiewnikach	4	1
Zakrzówek	4	1
Opactwo Benedyktynów w Tyńcu	2	1
Stara część Nowej Huty (okolice Placu Centralnego)	2	1
Park Lotników Polskich	3	1-2
Zalew Nowohucki	2	2

(źródło: opracowanie własne)

Wyniki pokazują, że opracowana metoda pozwoliła poprawnie zidentyfikować najbardziej atrakcyjne miejsca Krakowa z pewnymi wyjątkami. Spośród 20 przeanalizowanych miejsc w 15 przypadkach obie metody zakwalifikowały obiekty w ten sam sposób, tj. jako bardzo atrakcyjne lub jako te o niskiej atrakcyjności. Opracowana metodyka wyżej niż w raporcie UMK ocenia Zalew Bagry. Powodów tego stanu rzeczy można upatrywać w tym, że raport datowany jest na 2008 rok, zanim Zalew w Bagrach przeszedł szereg prac rewitalizacyjnych tak, by mógł pełnić rekreacyjną rolę dla mieszkańców Krakowa. Ponadto różnice w ocenie widoczne są także w przypadku Lasu Wolskiego z Kopcem Piłsudskiego, Opactwie Benedyktynów w Tyńcu i starej części Nowej Huty. Miejsca te wyżej ocenione zostały w raporcie UMK. Wynika to z faktu, że przyjęta w pracy metoda nie skupia się na (często subiektywnej) ocenie wartości danego waloru kulturowo-przyrodniczego, a bierze pod uwagę jedynie jego obecność na danym obszarze. Ponadto obszar Nowej Huty utracił na ocenie ze względu na odrzucenie zmiennej mówiącej o obecności obszaru urbanistycznego.

Pomimo zaobserwowanych różnic można stwierdzić, że opracowana metodyka pozwala na skuteczną ocenę atrakcyjności otoczenia trasy, a co ważne może być łatwo zaaplikowana do waloryzacji przestrzeni innych miast ze względu na łatwość pozyskania danych o liczbie walorów kulturowych oraz przyrodniczych.

5

||||| **Modelowanie dla potrzeb określenia
wpływu otoczenia trasy na parametry
podróży rowerami miejskimi**

5. Modelowanie dla potrzeb określenia wpływu otoczenia trasy na parametry podróży rowerami miejskimi

Wśród wymienionych w poprzednich rozdziałach parametrów, mogących opisać podróż rowerem miejskim, wymienić można: czas podróży, długość podróży oraz współczynnik wydłużenia trasy. To właśnie te trzy parametry zostały zbadane pod kątem wpływu na nie atrakcyjności otoczenia trasy, a w przypadku współczynnika wydłużenia trasy została określona, ściślej mówiąc, zależność pomiędzy wzrostem atrakcyjności trasy, a wydłużeniem trasy. Analizy te mają na celu znalezienie odpowiedzi na postawione pytanie czy poziom atrakcyjności otoczenia trasy ma wpływ na długość wybieranej trasy i czas jej trwania. Ponadto są poszukiwaniem odpowiedzi na pytanie czy użytkownicy rowerów miejskich wybierają dłuższą trasę ze względu na jej atrakcyjność. Ciekawym zagadnieniem jest także analiza postojów rowerzystów pod kątem ich lokalizacji i czasu trwania. W tym aspekcie badane jest to czy otoczenie trasy wpływa na liczbę i czas postojów rowerzystów.

W pierwszej kolejności z zestawu podróży wybrano jedynie te, które w całości przebiegają w Krakowie. Podjęto ten krok ze względu na to, że siatka waloryzacyjna z poziomem atrakcyjności otoczenia trasy została przygotowana dla obszaru w granicach miasta. Spośród 27859 podróży w całości po Krakowie przebiegały trasy 27780 podróży, co stanowi 99,7% wszystkich podróży. Następnie każdej z podróży przebiegającej w całości na terenie Krakowa przypisano jej wartość zgodną z atrakcyjnością otoczenia trasy, czyli wartość pól w siatce waloryzacyjnej (wyznaczonej w rozdziale 4), przez które dana trasa przebiega:

dla każdego punktu na trasie każdej podróży z wartością początkową poziomu atrakcyjności otoczenia trasy **równą** 0:

dla każdego pola w siatce waloryzacyjnej:

jeżeli punkt danej trasy podróży należy do danego pola **to zwiększ** wartość poziomu atrakcyjności otoczenia trasy o wartość danego pola w siatce waloryzacyjnej (o ile poprzedni punkt na trasie nie należał do tego samego pola)

w przeciwnym wypadku pozostaw wartość poziomu atrakcyjności otoczenia trasy

koniec warunku

Finalnie każda z podróży ma przypisaną wartość, będącą sumą wartości pól z siatki waloryzacyjnej, przez które przebiega trasa. Wartość ta określona została mianem **poziomu atrakcyjności otoczenia trasy**. W zbiorze wszystkich podróży na terenie Krakowa najniższa wartość poziomu atrakcyjności otoczenia trasy wyniosła 0,0, największa 225,0, przy czym średnio poziom ten wynosi 17,3, a kwantyl 75% wynosi 23,0. Na potrzeby analizy współczynnika wydłużenia trasy w podobny sposób wartość atrakcyjności trasy przypisano także najkrótszej teoretycznej trasie, tj. łączącej źródło i cel podróży w linii prostej. Na potrzeby analizy wyznaczono parametr nazwany **współczynnikiem zmiany poziomu atrakcyjności otoczenia trasy**, który jest nawiązaniem do współczynnika wydłużenia trasy i mówi o ile razy zwiększył bądź zmniejszył się poziom atrakcyjności wybranej trasy w stosunku do atrakcyjności najkrótszej teoretycznej trasy pomiędzy źródłem, a celem danej podróży. W przypadku gdy najkrótsza teoretyczna trasa posiadała współczynnik atrakcyjności trasy 0, przypisywano jej wartość 1 celem uniknięcia dzielenia przez 0 podczas obliczania współczynnika zmiany poziomu atrakcyjności otoczenia trasy. Współczynnik zmiany poziomu atrakcyjności otoczenia trasy pomiędzy 0, a 1 mówi, że wybrana trasa jest mniej atrakcyjna niż teoretyczna najkrótsza trasa. Gdy jego wartość jest większa od 1 znaczy to, że wybrana przez użytkownika trasa jest atrakcyjniejsza od teoretycznej najkrótszej trasy. Współczynnik zmiany poziomu atrakcyjności otoczenia trasy w analizowanym przypadku przyjął wartość maksymalną 195,0, a średnio wybrana przez użytkownika rowerów Wavelo trasa była 3,42 razy bardziej atrakcyjna aniżeli najkrótsza teoretyczna trasa.

Dzięki powyższemu każda z podróży została na tym etapie analizy opisana za pomocą:

- unikalnego numeru identyfikacyjnego podróży (ID),
- czasu podróży (t_{tr}),
- całkowitej długości podróży (d_s),
- współczynnika wydłużenia trasy (r)
- poziomu atrakcyjności otoczenia trasy (a)
- współczynnika zmiany poziomu atrakcyjności trasy (w).

Przedstawienie danych o podróżach rowerowych w takim formacie pozwoliło uzyskać próbki zmiennych losowych charakteryzujących liczbowe parametry popytu. Każda z podróży ($Trip$) może zatem być opisana jako:

$$Trip = \langle ID, Track, t_{tr}, d_s, r, a, w \rangle \quad (17)$$

gdzie *Track* jest odniesieniem do danej ścieżki GPS. W przypadku analizy czasu podróży, długości podróży i współczynnika wydłużenia trasy w pierwszej kolejności zbadano korelację liniową Pearsona oraz korelację rang Spearmana. O ile w przypadku korelacji Pearsona związek między zmiennymi musi być liniowy, o tyle współczynnik korelacji rang Spearmana pokazuje dowolną monotoniczną zależność (także nieliniową) i jest bardziej odporny na odstające przypadki w próbach niż korelacja Pearsona [219]. Ponadto współczynniki korelacji rangowej są właściwsze jeżeli jedna lub obie ze zmiennych X i Y nie mają charakteru ilościowego i mogą być wyrażone jedynie na skali porządkowej, a tak możemy opisać zmienne opisujące atrakcyjność otoczenia trasy.

Celem określenia zależności w pracy zastosowano dwa modele regresyjne: regresję liniową i logistyczną. Pierwszy z nich to regresja liniowa, która jest najprostszym wariantem regresji w statystyce. Zakłada ona, że zależność pomiędzy zmienną objaśnianą a objaśniającą jest zależnością liniową. Tak jak w analizie korelacji, jeżeli jedna wartość wzrasta to druga wzrasta (dodatnia korelacja) lub spada (korelacja ujemna). W regresji liniowej zakłada się, że wzrostowi jednej zmiennej towarzyszy wzrost lub spadek na drugiej zmiennej. Co więcej, nazwa regresji liniowej odnosi się do faktu, że funkcja regresji przyjmuje postać funkcji liniowej [219]:

$$y = \beta_0 + \beta_1 * x \quad (18)$$

gdzie:

- x – predyktor, zmienna wyjaśniająca, objaśniająca,
- y – zmienna zależna, zmienna wyjaśniana, objaśniana,
- β_0, β_1 – współczynniki regresji.

Regresja logistyczna jest jedną z metod regresji przynależącą do klasy ogólnych modeli liniowych, wykorzystywaną w sytuacjach, w których zmienna zależna mierzona jest na skali nominalnej (zazwyczaj jest to zmienna dychotomiczna), natomiast zmienne niezależne mogą być mierzone na skalach nominalnych, porządkowych (w obu przypadkach wymagane jest rekodowanie do wartości binarnych) lub ilościowych [219]. W przypadku regresji logistycznej, w przeciwieństwie do regresji liniowej, celem nie jest przewidzenie wartości zmiennej zależnej na podstawie wykorzystanych predyktorów, ale przewidzenia prawdopodobieństwa na wystąpienia jakiegoś zdarzenia. Ogólna postać regresji logistycznej przedstawia się następująco:

$$y = f(U) = \frac{1}{1 + e^{-U}} \quad (19)$$

$$U = \beta_0 + \beta_1 * x_1 + [...] + \beta_n * x_n$$

gdzie:

- $x_1 \dots x_n$ – predyktory, zmienne wyjaśniające, objaśniane,
- y – zmienna zależna, zmienna wyjaśniana, objaśniana,
- $\beta_0 \dots \beta_n$ – współczynniki regresji.

Najpopularniejszym wskaźnikiem do oceny jakości przygotowanych modeli jest współczynnik determinacji, inaczej zwany współczynnikiem określoności lub R-kwadrat (R^2). Współczynnik ten jest miarą tego, jaki procent zmienności zmiennej zależnej (objaśnianej) jest wyjaśniany za pomocą zmiennej niezależnej (zmienna objaśniająca, predyktor) bądź modelu statystycznego [219].

Ponadto w przypadku opracowanych modeli regresyjnych sprawdzono czy współczynniki regresji są istotne statystycznie. W tym celu obliczono statystykę t-Studenta (t), korzystając z poniższego wzoru [219]:

$$t = \frac{b_i}{s_{b_i}} \quad (20)$$

gdzie:

- b_i – współczynnik regresji b ;
- s_{b_i} – błąd standardowy dla danego współczynnika regresji, wyznaczany z poniższego wzoru:

$$SE = \frac{s}{\sqrt{N}}$$

gdzie:

- SE – błąd standardowy średniej;
- s – odchylenie standardowe;
- N – liczba obserwacji.

(21)

Otrzymany wynik statystyki t ma rozkład t-Studenta dla liczby stopni swobody wyznaczonej na podstawie wzoru:

$$df = n - p - 1 \quad (22)$$

gdzie:

- df – liczba stopni swobody;
- n – liczba obserwacji;
- p – liczba predyktorów w modelu.


Poziom istotności wartości obliczonej statystyki t odczytywany jest z tablic testu t-Studenta. Aby to zrobić, prócz wartości statystyki t i liczby stopni swobody df , musimy znać także poziom istotności α (poziom prawdopodobieństwa), dla którego dany wynik będzie wskazywał na istotną zależność [219]. Podczas określania istotności współczynnika regresji β_i stawiana jest hipoteza zerowa H_0 oraz hipoteza alternatywna H_1 :

$$\begin{aligned} H_0: \beta_i &= 0 \\ H_1: \beta_i &\neq 0 \end{aligned} \quad (23)$$

Wyznaczona statystyka t porównywana jest z wartością t_k , która jest wartością krytyczną rozkładu t-Studenta dla określonej liczby stopni swobody df i poziomu istotności α . Jeżeli $|t| < t_k$ to odrzucamy hipotezę zerową, przyjmując hipotezę alternatywną. Jeśli $|t| > t_k$ to nie ma podstaw aby odrzucić hipotezę zerową, co oznacza, że dany współczynnik regresji jest statystycznie istotny [219].

5.1. Model wpływu otoczenia trasy na czas podróży rowerami miejskimi

W pierwszym kroku zbiór podróży podzielony został na zbiór treningowy (80%) i zbiór testowy (20%). Na tym etapie zbadano korelację liniową Pearsona i korelację rang Spearmana dla zbadania czy istnieje współzależność pomiędzy poziomem atrakcyjności trasy a czasem trwania podróży (Rys. 5.1).

Rys. 5.1. Korelacja czasu podróży (t) i poziomu atrakcyjności otoczenia trasy (a)

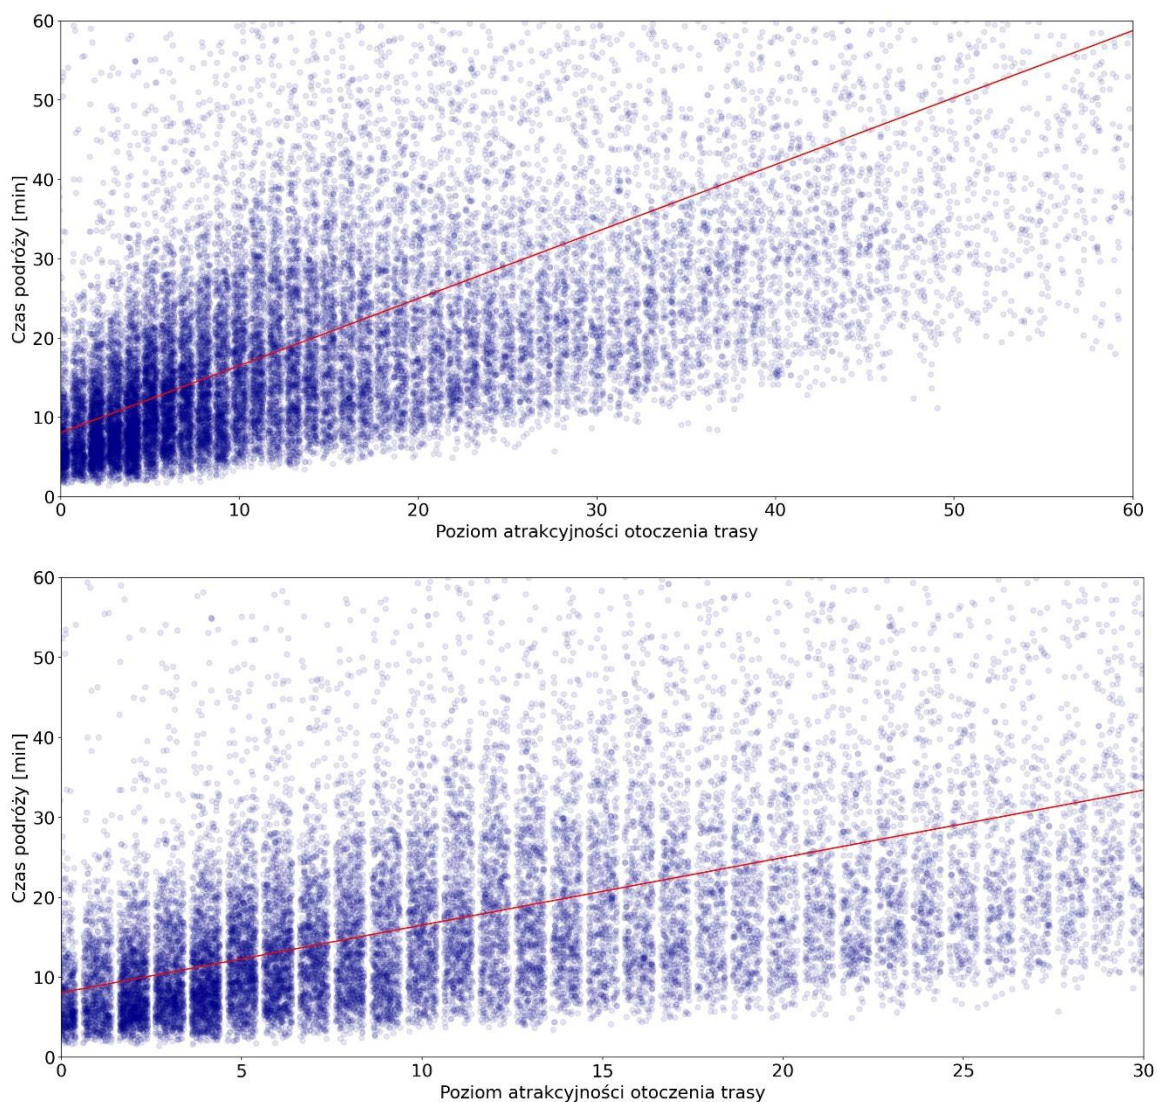
(źródło: opracowanie własne)

Wysoki wskaźnik korelacji Pearsona wskazuje na silną, rosnącą korelację liniową pomiędzy czasem podróży a atrakcyjnością otoczenia trasy. W kolejnym kroku opracowano model regresji liniowej na podstawie danych ze zbioru treningowego. Model opisujący tę zależność, pozwalający na obliczenie zmiennej objaśnianej, jaką jest czas podróży (t), dzięki znajomości wartości zmiennej objaśniającej, jaką jest poziom atrakcyjności otoczenia trasy (a), ukazany został poniżej:

$$t \cong 0,84 * a + 8,07 \quad (24)$$

Dla współczynnika regresji przy zmiennej a obliczono wartość statystyki t-Studenta, przy liczbie stopni swobody równej 22222 i poziomie istotności $\alpha = 99,9\%$. Obliczona statystyka t-Studenta wynosi 6,479 (dla błędu standardowego średniej zmiennej a wynoszącego 0,130) i jest większa od wartości krytycznej testu t-Studenta dla określonej liczby stopni swobody i poziomu istotności. Oznacza to, że na poziomie prawdopodobieństwa równym 99,9% współczynnik regresji opracowanego modelu jest istotny statystycznie.

Dzięki powyższemu modelowi dla zbioru testowego zmiennych objaśniających obliczono wartości predykowane zmiennej objaśnianej, co ukazano na Rys. 5.2.




Rys. 5.2. Wykres zależności atrakcyjności otoczenia trasy i czasu podróży
(źródło: opracowanie własne)

Analiza powyższego rysunku pozwala zauważyć, że im poziom atrakcyjności otoczenia trasy jest wyższy, tym podróż trwa dłużej. Współczynnik R^2 opisujący miarę jakości dopasowania powyższego modelu wynosi 0,48, co oznacza, że model wyjaśnia niemal 50% zmienności, co w analizowanym przypadku można uznać za wynik satysfakcjonujący, jednakże ukazujący, że poziom atrakcyjności trasy nie jest jedynym czynnikiem wpływającym na czas podróży rowerem miejskim.

5.2. Model wpływu otoczenia trasy na długość podróży rowerami miejskimi

W pierwszym kroku dla zbioru treningowego zbadano korelację liniową Pearsona i korelację rang Spearmana dla zbadania czy istnieje współzależność pomiędzy poziomem atrakcyjności trasy a długością podróży (Rys. 5.3).



Rys. 5.3. Korelacja długości podróży (d) i poziomu atrakcyjności otoczenia trasy (a)

(źródło: opracowanie własne)

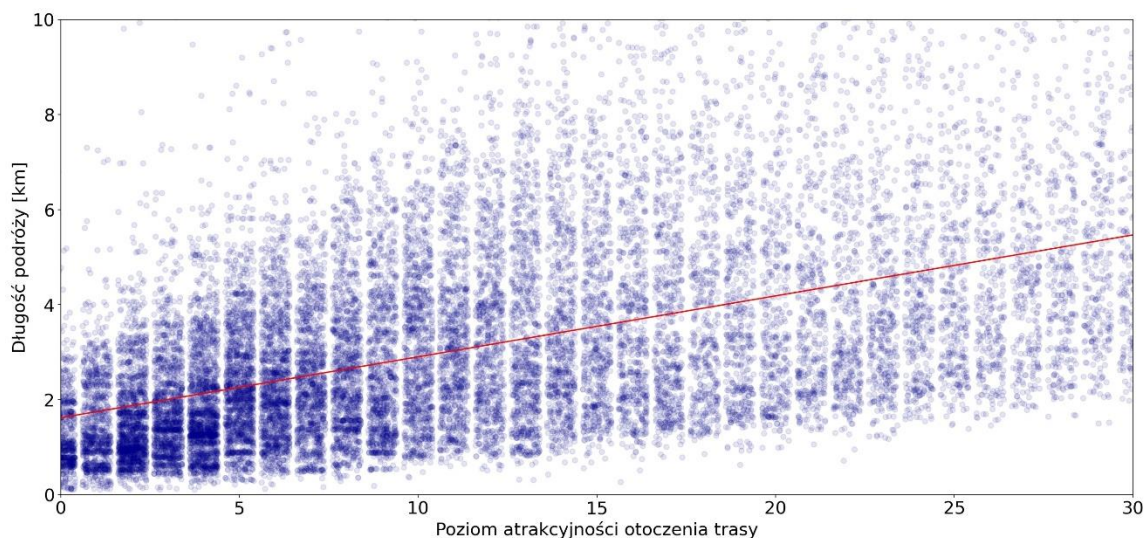
Wysoki wskaźnik korelacji Pearsona wskazuje na silną, rosnącą korelację liniową pomiędzy długością podróży a atrakcyjnością otoczenia trasy. W kolejnym kroku opracowano model regresji liniowej na podstawie danych ze zbioru treningowego. Model opisujący tę zależność, pozwalający na obliczenie zmiennej objaśnianej, jaką jest długość podróży (d), dzięki znajomości wartości zmiennej objaśniającej, jaką jest poziom atrakcyjności otoczenia trasy (a), ukazany został poniżej:

$$d \cong 0,13 * a + 1,62 \quad (25)$$

Dla współczynnika regresji przy zmiennej a obliczono wartość statystyki t-Studenta, przy liczbie stopni swobody równej 22222 i poziomie istotności $\alpha = 99,9\%$. Obliczona statystyka t-Studenta wynosi 1,002 (dla błędu standardowego średniej zmiennej a wynoszącego 0,130) i jest mniejsza od wartości krytycznej testu t-Studenta dla określonej liczby stopni swobody i poziomu istotności. Oznacza to, że na poziomie prawdopodobieństwa równym 99,9%

współczynnik regresji opracowanego modelu nie jest istotny statystycznie. Na poziomie prawdopodobieństwa $\alpha = 84\%$ wartość statystyki t-Studenta jest większa od wartości krytycznej testu t-Studenta dla określonej liczby stopni swobody i poziomu istotności. Oznacza to, że na poziomie prawdopodobieństwa równym 84% współczynnik regresji opracowanego modelu jest istotny statystycznie.

Dzięki powyższemu modelowi dla zbioru testowego zmiennych objaśniających obliczono wartości predykowane zmiennej objaśnianej, co ukazano na Rys. 5.4.

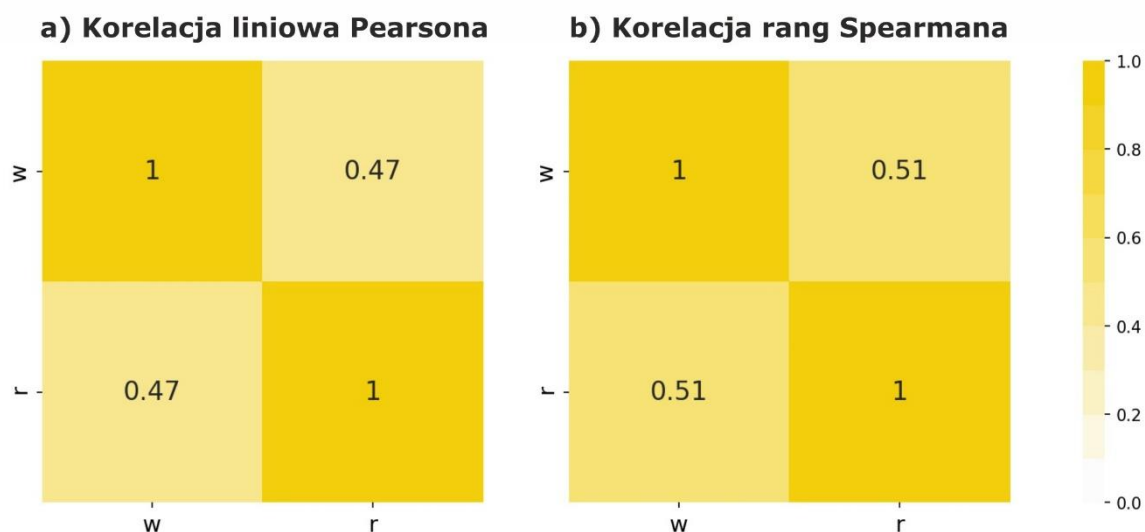


Rys. 5.4. Wykres zależności atrakcyjności otoczenia trasy i długości podróży
(źródło: opracowanie własne)

Analiza powyższego rysunku pozwala zauważyć, że im poziom atrakcyjności otoczenia trasy jest wyższy, tym podróż jest dłuższa. Współczynnik R^2 opisujący miarę jakości dopasowania powyższego modelu wynosi 0,59, co oznacza, że model wyjaśnia 59% zmienności, co w analizowanym przypadku można uznać za wynik satysfakcjonujący, jednakże ukazujący, że poziom atrakcyjności trasy nie jest jedynym czynnikiem wpływającym na długość podróży rowerem miejskim.

5.3. Model wpływu otoczenia trasy na współczynnik wydłużenia trasy w podróżach rowerami miejskimi

W pierwszym kroku dla zbioru treningowego zbadano korelację liniową Pearsona i korelację rang Spearmana dla zbadania czy istnieje współzależność pomiędzy współczynnikiem zmiany poziomu atrakcyjności otoczenia trasy a współczynnikiem wydłużenia trasy (Rys. 5.5).



Rys. 5.5. Korelacja współczynnika wydłużenia trasy (r) i współczynnika zmiany poziomu atrakcyjności otoczenia trasy (w)

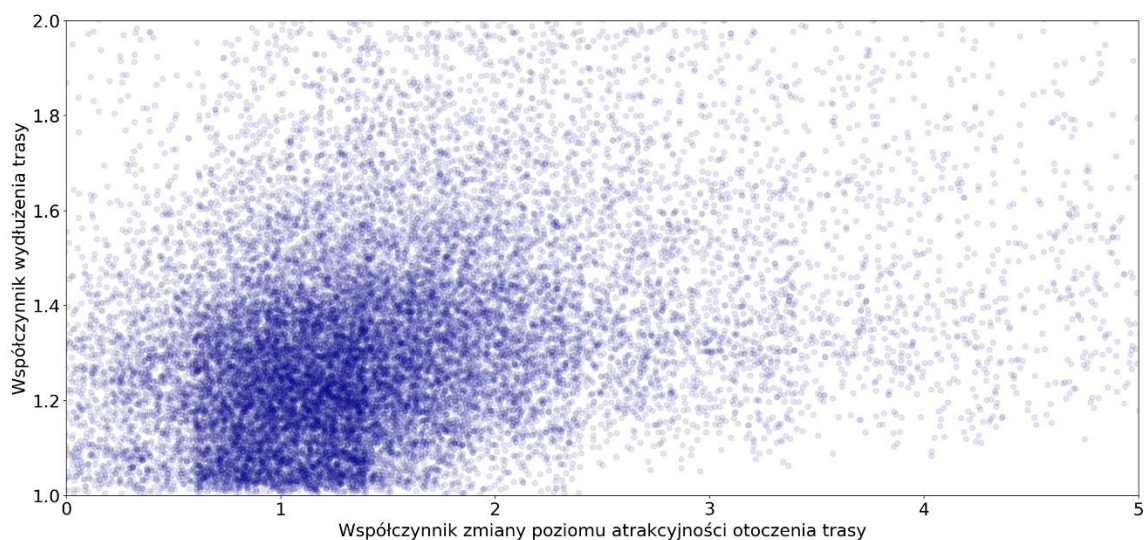
(źródło: opracowanie własne)

Wskaźnik korelacji Pearsona wskazuje na średnią, rosnącą korelację liniową pomiędzy współczynnikiem wydłużenia trasy a współczynnikiem zmiany poziomu atrakcyjności otoczenia trasy. W kolejnym kroku opracowano model regresji liniowej na podstawie danych ze zbioru treningowego. Model opisujący tę zależność, pozwalający na obliczenie zmiennej objaśnianej, jaką jest współczynnik wydłużenia trasy (r), dzięki znajomości wartości zmiennej objaśniającej, jaką jest współczynnik zmiany poziomu atrakcyjności otoczenia trasy (w), ukazany został poniżej:

$$r \cong 31,73 * w - 27,78 \quad (26)$$

Dla współczynnika regresji przy zmiennej w obliczono wartość statystyki t-Studenta, przy liczbie stopni swobody równej 22222 i poziomie istotności $\alpha = 99,9\%$. Obliczona statystyka t-Studenta wynosi 478,119 (dla błędu standardowego średniej zmiennej w wynoszącego 0,066) i jest większa od wartości krytycznej testu t-Studenta dla określonej liczby stopni swobody i poziomu istotności. Oznacza to, że na poziomie prawdopodobieństwa równym 99,9% współczynnik regresji opracowanego modelu jest istotny statystycznie.

Dzięki powyższemu modelowi dla zbioru testowego zmiennych objaśniających obliczono wartości predykowane zmiennej objaśnianej, co ukazano na Rys. 5.6.



Rys. 5.6. Wykres zależności współczynnika zmiany poziomu atrakcyjności otoczenia trasy i współczynnika wydłużenia trasy
(źródło: opracowanie własne)

Analiza powyższego rysunku pozwala zauważyć, że im poziom atrakcyjności otoczenia trasy jest wyższy, tym podróż jest dłuższa. Współczynnik R^2 opisujący miarę jakości dopasowania powyższego modelu wynosi 0,23, co oznacza, że model wyjaśnia jedynie 23% zmienności, co dowodzi, że istnieje pewien wpływ wzrostu poziomu atrakcyjności trasy na wzrost współczynnika wydłużenia trasy, jednakże oprócz współczynnika wzrostu poziomu atrakcyjności trasy są inne czynniki, które uwarunkowują wydłużenie trasy.

5.4. Modele wpływu otoczenia trasy na liczbę i czas postojów użytkowników rowerów miejskich

Przed przystąpieniem do analizy wpływu otoczenia trasy na postoje użytkowników systemu rowerów miejskich dokonano podziału całej próbki danych o postojach na zbiór treningowy (80%) i testowy (20%). Analiza ta odbywała się na kanwie przygotowanej wcześniej siatki. To znaczy, że analiza miała na celu znalezienie zależności pomiędzy zmiennymi opisującymi atrakcyjność otoczenia trasy (opisanymi w rozdziale 4), a liczbą postojów użytkowników systemu rowerów miejskich (Rys. 3.7) i sumarycznym czasem tychże postojów (Rys. 3.9).

5.4.1. Modele regresji liniowej wpływu otoczenia trasy na liczbę i czas postojów użytkowników rowerów miejskich

W pierwszej kolejności, dzięki programowi napisanemu w języku Python, na podstawie zbiorów treningowych zmiennej objaśniającej i objaśnianej sprawdzono jakość dopasowania modelu wpływu poziomu atrakcyjności otoczenia danego pola siatki waloryzacyjnej na liczbę postojów w tym polu. Przy współczynniku korelacji Pearsona 0,41 i współczynniku determinacji R^2 równym 0,16 stwierdzono, że model ten jest niskiej jakości i nie wyjaśnia w sposób wystarczający analizowanej zmienności. Postanowiono zatem przygotować model w oparciu o cząstkowe zmienne objaśniające mówiące o walorach kulturowych i walorach przyrodniczych, o których mowa w rozdziale 4. Zmienne użyte do budowy modelu to:

- x_1 – liczba zabytków architektury i budownictwa;
- x_2 – obecność zabytków techniki;
- x_3 – obecność zabytkowych obszarów i terenów zielonych;
- x_4 – obecność parków;
- x_5 – obecność parków leśnych;
- x_6 – obecność cieków wodnych z towarzyszącą infrastrukturą rowerową;
- x_7 – obecność zbiorników wodnych z towarzyszącą infrastrukturą rowerową.

Spośród powyższych zmiennych zmienna x_1 jest zmienną liczbową, natomiast zmienne od x_2 do x_7 to zmienne dychotomiczne. Dla zbioru treningowego każdej ze zmiennych objaśniających (od x_1 do x_7) i zbioru treningowego zmiennej objaśnianej y_1 , mówiącej o liczbie postojów w każdym z pól siatki, określono model regresji liniowej, który przyjął postać:

$$y_1 \cong 0,84 * x_1 + 0,25 * x_2 + 4,40 * x_3 + 1,07 * x_4 - 0,61 * x_5 + 4,52 * x_6 + 4,38 * x_7 - 0,11 \quad (27)$$

W Tab. 5.1 zawarto informacje o wartości błędów standardowych średniej dla każdego współczynnika regresji oraz wartości statystyki t-Studenta.


Tab. 5.1. Wartości błędów standardowych i statystyk t-Studenta dla współczynników regresji modelu regresji liniowej wpływu otoczenia trasy na liczbę postojów użytkowników rowerów miejskich

Zmienna objaśniająca, której współczynnik badany jest pod kątem istotności statystycznej	Wartość błędu standardowego średniej danej zmiennej	Wartość statystyki t-Studenta
x_1	0,108	7,745
x_2	0,002	139,645
x_3	0,002	2324,571
x_4	0,004	249,881
x_5	0,002	246,889
x_6	0,002	1950,991
x_7	0,001	3516,848

(źródło: opracowanie własne)

Dla każdego ze współczynników obliczone statystyki t-Studenta są większe aniżeli wartość krytyczna testu t-Studenta dla liczby stopni swobody równej 4792 i poziomu istotności $\alpha = 99,9\%$, która wynosi 3,091. Oznacza to, że na poziomie prawdopodobieństwa równym 99,9% współczynniki regresji opracowanego modelu są istotne statystycznie.

Dzięki powyższemu modelowi dla zbioru testowego zmiennych objaśniających obliczono wartości predykowane zmiennej objaśnianej y_i i porównano je z wartościami rzeczywistymi (Rys. 5.7).



Rys. 5.7. Porównanie predykowanych i rzeczywistych wartości liczby postojów

(źródło: opracowanie własne)

Po porównaniu ich z wartościami w zbiorze testowym otrzymano współczynnik determinacji R^2 równy 0,42. To znaczy, że otrzymany model wyjaśnia 42% zmienności, a na liczbę postojów wpływ mają także inne czynniki aniżeli obecność walorów krajobrazowych.

Ten sam zestaw zmiennych objaśniających użyto do sprawdzenia zależności między nimi, a łącznym sumarycznym czasem postojów. Na podstawie zbioru treningowego każdej ze zmiennych objaśniających (od x_1 do x_7) i zbioru treningowego zmiennej objaśnianej y_2 , mówiącej o sumarycznym czasie postojów w każdym z pól siatki, określono model regresji liniowej, który przyjął postać:

$$y_2 \cong 3,37 * x_1 + 19,64 * x_2 + 21,51 * x_3 + 5,34 * x_4 - 3,59 * x_5 + 55,87 * x_6 + 39,76 * x_7 - 0,07 \quad (28)$$

W poniższej tabeli zawarto informacje o wartości błędów standardowych średniej dla każdego współczynnika regresji oraz wartości statystyki t-Studenta.

Tab. 5.2. Wartości błędów standardowych i statystyk t-Studenta dla współczynników regresji modelu regresji liniowej wpływu otoczenia trasy na czas postojów użytkowników rowerów miejskich


Zmienna objaśniająca, której współczynnik badany jest pod kątem istotności statystycznej	Wartość błędu standardowego średniej danej zmiennej	Wartość statystyki t-Studenta
x_1	0,108	31,071
x_2	0,002	10970,503
x_3	0,002	11363,981
x_4	0,004	1247,070
x_5	0,002	1453,005
x_6	0,002	24115,459
x_7	0,001	31924,629

(źródło: opracowanie własne)

Dla każdego ze współczynników obliczone statystyki t-Studenta są większe aniżeli wartość krytyczna testu t-Studenta dla liczby stopni swobody równej 4792 i poziomu istotności $\alpha = 99,9\%$,

która wynosi 3,091. Oznacza to, że na poziomie prawdopodobieństwa równym 99,9% współczynniki regresji opracowanego modelu są istotne statystycznie.

Dzięki powyższemu modelowi dla zbioru testowego zmiennych objaśniających obliczono wartości predykowane zmiennej objaśnianej y_2 (Rys. 5.8).



Rys. 5.8. Porównanie predykowanych i rzeczywistych wartości sumarycznego czasu postojów
(źródło: opracowanie własne)

Po porównaniu ich z wartościami w zbiorze testowym otrzymano współczynnik determinacji R^2 równy 0,32, co oznacza, że otrzymany model wyjaśnia nieco ponad 30% zmienności, a na łączny czas postojów wpływ mają także inne czynniki aniżeli walory krajobrazowe.

Biorąc pod uwagę losowość zachowań komunikacyjnych powyższe wyniki można uznać za zadowalające. Jednakże ze względu na fakt, iż celem pracy jest otrzymanie narzędzia do identyfikacji miejsc, w których należy rozwijać punktową infrastrukturę dla rowerzystów oraz dbać o umieszczanie elementów małej architektury stwierdzono, że nie jest koniecznym znalezienie modelu, dzięki któremu możliwe będzie określenie dokładnej liczby postojów lub sumarycznego czasu postojów. Uznano, że wystarczające będzie znalezienie modelu, który określi czy postojów będzie „wiele” czy „niewiele lub wcale”. Podobnie rzecz ma się z sumarycznym czasem postojów. Ponadto dychotomiczny charakter sześciu z siedmiu zmiennych objaśniających wpływa na średni poziom współczynników determinacji R^2 w przypadku modelu regresji liniowej. Rozwiązanie postawionego problemu przedstawiono w podrozdziale 5.4.2.

5.4.2. Modele regresji logistycznej wpływu otoczenia trasy na liczbę i czas postojów użytkowników rowerów miejskich


Za użyciem modelu logistycznego przemawia cel jakim jest przewidzenie czy na danym obszarze wystąpi dużo postojów użytkowników rowerów miejskich czy nie. Podobnie przewidzieć można czy czas tych postojów będzie długi czy też nie. W modelu logistycznym, określającym wpływ zmiennych objaśniających opisujących atrakcyjność otoczenia na zaistnienie dużej liczby postojów, wykorzystano zmienną objaśnianą, mówiącą o liczbie postojów, sprowadzoną do wartości zero-jedynkowych, gdzie 1 oznacza, że na danym obszarze jest prawdopodobne wystąpienie dużej liczby postojów (Rys. 3.11).

Po pierwsze, dzięki programowi napisanemu w języku Python, na podstawie zbioru treningowego zmiennej objaśniającej opisującej poziom atrakcyjności otoczenia trasy dla danego pola siatki waloryzacyjnej (a) i zbioru treningowego zmiennej objaśnianej y_3 , mówiącej o prawdopodobieństwie tego, że liczba postojów będzie duża, określono model regresji logistycznej, który przyjął postać:

$$y_3 \cong \frac{1}{1 + e^{-(1,77*a-6,13)}} \quad (29)$$

Dla współczynnika regresji przy zmiennej a obliczono wartość statystyki t-Studenta, przy liczbie stopni swobody równej 4798 i poziomie istotności $\alpha = 99,9\%$. Obliczona statystyka t-Studenta wynosi 240,572 (dla błędu standardowego średniej zmiennej a wynoszącego 0,007) i jest większa od wartości krytycznej testu t-Studenta dla określonej liczby stopni swobody i poziomu istotności. Oznacza to, że na poziomie prawdopodobieństwa równym 99,9% współczynnik regresji opracowanego modelu jest istotny statystycznie.


Dzięki powyższemu modelowi dla zbioru testowego zmiennych objaśniających obliczono wartości predykowane zmiennej objaśnianej y_3 . Oceny jakości i poprawności modelu klasyfikacyjnego dokonano na podstawie tablicy (macierzy) pomyłek (ang. *confusion matrix*). Macierz ta ma wymiar $N \times N$, gdzie wiersze odpowiadają poprawnym klasom decyzyjnym (klasy rzeczywiste), a kolumny decyzjom przewidywanym przez klasyfikator (klasy predykowane). Liczba n_{ij} na przecięciu wiersza i oraz kolumny j to liczba przykładów z klasy i -tej, które zostały zaklasyfikowane do klasy j -tej [222]. Tablica pomyłek dla powyżej opracowanego modelu przedstawiona jest na Rys. 5.9.



Rys. 5.9. Tablica pomyłek dla modelu wpływu atrakcyjności otoczenia na liczbę postojów
(źródło: opracowanie własne)

Na powyższej tablicy wartość 1192 odpowiada liczbie przewidywań prawdziwie negatywnych (ang. *True-Negative*), wartość 1 to liczba przewidywań prawdziwie pozytywnych (ang. *True-Positive*), wartość 0 mówi o liczbie przewidywań fałszywie negatywnych (ang. *False-Negative*), natomiast wartość 7 określa liczbę przewidywań fałszywie pozytywnych (ang. *False-Positive*).

Dokładność (ang. *accuracy*) otrzymanego modelu wynosi 99,4%, precyzja (ang. *precision*), czyli stosunek wyników prawdziwie ujemnych do sumy prawdziwie ujemnych i fałszywie dodatnich wynosi 100%, a czułość modelu (ang. *recall*) określająca stosunek wyników prawdziwie dodatnich do sumy prawdziwie dodatnich i fałszywie ujemnych wynosi 12,5%. Wskaźniki te potwierdzają bardzo dobrą jakość dopasowania modelu. Ponadto jakość klasyfikacji powyższego modelu została zwizualizowana za pomocą krzywej ROC. Krzywa ta to jeden ze sposobów wizualizacji jakości klasyfikacji, pokazujący zależności wskaźników TPR (ang. *True-Positive Rate*) oraz FPR (ang. *False-Positive Rate*). Krzywa ROC reprezentuje informacje statystyczne odkryte w problemach klasyfikacji binarnej i jest kluczowym pojęciem w uczeniu maszynowym i inżynierii danych [223]. Krzywa ROC dla modelu wpływu otoczenia trasy na liczbę postojów przedstawiona jest na Rys. 5.10.



Rys. 5.10. Krzywa ROC dla modelu wpływu atrakcyjności otoczenia na liczbę postojów
(źródło: opracowanie własne)


Na powyższym rysunku prócz krzywej zamieszczono informację o polu pod krzywą (auc – ang. *area under ROC curve*). Dzięki temu wskaźnikowi można określić jakość klasyfikacji za pomocą krzywej ROC. W analizowanym przypadku wskaźnik ten wynosi 0,97, tj. zbliża się do 1, która oznacza klasyfikator idealny.

W drugim kroku opracowano model logistyczny dla zbadania tego czy istnieje zależność pomiędzy atrakcyjnością otoczenia a prawdopodobieństwem wystąpienia długich postojów użytkowników rowerów miejskich. Z pomocą opracowanego w języku Python programu, na podstawie zbioru treningowego zmiennej objaśniającej opisującej poziom atrakcyjności otoczenia trasy dla danego pola siatki waloryzacyjnej (a) i zbioru treningowego zmiennej objaśnianej y_4 , mówiącej o prawdopodobieństwie tego, że łączny czas postojów będzie duży, określono model regresji logistycznej, który przyjął postać:

$$y_4 \cong \frac{1}{1 + e^{-(1,75 \cdot a - 5,99)}} \quad (30)$$

Dla współczynnika regresji przy zmiennej a obliczono wartość statystyki t-Studenta, przy liczbie stopni swobody równej 4798 i poziomie istotności $\alpha = 99,9\%$. Obliczona statystyka t-Studenta wynosi 237,853 (dla błędu standardowego średniej zmiennej a wynoszącego 0,007) i jest większa od wartości krytycznej testu t-Studenta dla określonej liczby stopni swobody i poziomu istotności. Oznacza to, że na poziomie prawdopodobieństwa równym 99,9% współczynnik regresji opracowanego modelu jest istotny statystycznie.

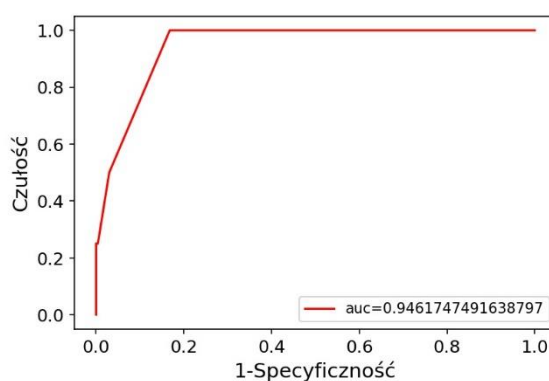
Z użyciem powyższego modelu dla zbioru testowego zmiennych objaśniających obliczono wartości predykowane zmiennej objaśnianej y_4 . Oceny jakości i poprawności modelu klasyfikacyjnego także dokonano na podstawie tablicy pomyłek, która dla powyżej opracowanego modelu przedstawiona została na Rys. 5.11.



Rys. 5.11. Tablica pomyłek dla modelu wpływu atrakcyjności otoczenia na łączny czas postojów
(źródło: opracowanie własne)

Na powyższej tablicy wartość 1196 odpowiada liczbie przewidywań prawdziwie negatywnych (ang. *True-Negative*), wartość 1 to liczba przewidywań prawdziwie pozytywnych (ang. *True-Positive*), wartość 0 mówi o liczbie przewidywań fałszywie negatywnych (ang. *False-Negative*), natomiast wartość 3 określa liczbę przewidywań fałszywie pozytywnych (ang. *False-Positive*).

Dokładność (ang. *accuracy*) otrzymanego modelu wynosi 99,8%, precyzja (ang. *precision*), wynosi 100%, a czułość modelu (ang. *recall*) wynosi 25%. Wskaźniki te potwierdzają bardzo dobrą jakość dopasowania modelu. Ponadto jakość klasyfikacji powyższego modelu została zwizualizowana za pomocą krzywej ROC (Rys. 5.12).



Rys. 5.12. Krzywa ROC dla modelu wpływu atrakcyjności otoczenia na łączny czas postojów
(źródło: opracowanie własne)

W analizowanym przypadku wskaźnik *auc* wynosi niemalże 0,95, tj. zbliża się do 1, która oznacza klasyfikator idealny, co tylko potwierdza bardzo dobrą jakość opracowanego modelu.

6

||||| Podsumowanie

6. Podsumowanie

Rozwój zrównoważonej mobilności w miastach jest ogólnosięciowym trendem, który można zaobserwować w ostatnich latach. W hasła związane ze zrównoważoną mobilnością wpisują się wszelkie działania mające na celu zmianę wzorców mobilności ludzi w kierunku proekologicznych rozwiązań takich jak przyjazny dla środowiska transport publiczny czy rozwój ruchu pieszego i rowerowego. Najpełniejszym wyrazem idei zrównoważonego transportu w miastach są systemy rowerów publicznych, które stały się tematem niniejszej pracy na przykładzie systemu, który funkcjonował w Krakowie. Dokonany obszerny przegląd aktualnego stanu badań nad ruchem rowerowym, w tym systemami rowerów publicznych, pokazał, że temat ten leży w polu zainteresowań wielu badaczy, począwszy od geografów, urbanistów, przez socjologów, lekarzy, na planistach transportu i analitykach danych skończywszy. W literaturze znaleźć można szereg publikacji związanych z korzyściami ruchu rowerowego, jego udziale w podziale zadań przewozowych czy olbrzymiej roli w kreowaniu zrównoważonych obszarów miejskich.

W ramach niniejszej dysertacji opisano także odnalezione w literaturze metody prognozowania ruchu rowerowego, a także metody jego modelowania, co było kluczowe z uwagi na podjęty w pracy temat modelowania wpływu otoczenia trasy na parametry podróży rowerami miejskimi. To właśnie powiązanie użytkowania rowerów publicznych z otoczeniem trasy poskutkowało poszerzeniem przeglądu stanu badań o pozycje związane z metodami oceny krajobrazu i waloryzacji przestrzeni publicznej. W literaturze odnaleziono badania, w których poszukiwano zależności pomiędzy zagospodarowaniem przestrzennym, a obłożeniem stacji roweru publicznego, jednakże żadne ze znalezionych badań nie odnosiły się do wpływu otoczenia trasy na postoje rowerzystów korzystających z usług systemu roweru publicznego. W literaturze znaleziono pozycje, w których badacze udowodnili wpływ otoczenia trasy na długość podróży, jednak otoczenie to było opisywane innymi niż walory kulturowo-przyrodnicze parametrami.

W ramach pracy analizie poddany został zestaw danych z systemu rowerów publicznych Wavelo, który funkcjonował do 2020 roku w Krakowie. Przed etapem analitycznym opracowano autorską metodę oczyszczania danych o podróżach rowerami publicznymi, zgromadzonych w formacie GPX. Metoda ta pozwoliła na usunięcie uszkodzonych rekordów oraz wyeliminowanie tych podróży, które miały zerowy dystans lub czas podróży. W ramach przygotowania danych do dalszych analiz opracowana została także metodyka filtrowania postojów użytkowników systemu rowerów publicznych, która miała na celu eliminację

postojów związanych z czynnościami technicznymi w sąsiedztwie wypożyczalni lub z utrudnieniami w ruchu. Aby móc przygotować model wpływu otoczenia trasy na wybrane parametry podróży rowerami miejskimi zaproponowano także metodykę waloryzacji otoczenia trasy, dzięki której opracowana została siatka waloryzacyjna, w której każdemu z pól siatki przypisany został poziom atrakcyjności otoczenia trasy. Metoda ta oparta została o walory krajobrazowe występujące w przestrzeni, które podzielono na walory kulturowe (zabytki) i walory przyrodnicze (parki, ciek i zbiorniki wodne).

W oparciu o wyczyszczone dane o podróżach użytkowników systemu Wavelo, ich postojach oraz dzięki zgromadzonym danym o atrakcyjności otoczenia trasy, opracowano modele liniowe, które udowadniają istnienie zależności pomiędzy atrakcyjnością otoczenia trasy, a długością i czasem trwania podróży. Wyniki dużo lepszej jakości o współczynniku determinacji R^2 rzędu ponad 99% uzyskano poprzez opracowanie modeli regresji logistycznej, dzięki którym możliwe jest wyznaczenie obszarów, w których z bardzo wysokim prawdopodobieństwem nastąpi duża liczba postojów użytkowników rowerów miejskich lub sumaryczny czas tychże postojów będzie znaczący. Aplikacja powyższych modeli możliwa jest w dużych i średnich miastach.

Głównym celem pracy było opracowanie narzędzia, które pomoże decydentom i urbanistom w wyznaczaniu miejsc, które są atrakcyjne dla użytkowników rowerów miejskich. W praktyce pozwala to na identyfikację miejsc, w których powinno się zwrócić szczególną uwagę na kształtowanie przestrzeni publicznej pod kątem urządzeń małej architektury i lokalizowania mebli miejskich umożliwiających odpoczynek. Ponadto zidentyfikowane dzięki opracowanemu modelowi miejsca są wskazówką dla operatorów systemów rowerów publicznych gdzie powinno się zwrócić szczególną uwagę na lokalizowanie „stacji wirtualnych”, czyli stref, gdzie możliwe jest pozostawienie roweru bez fizycznie zainstalowanych stacji. Biorąc pod uwagę rozwój wspomnianych w pracy hulajnóg elektrycznych, często zastępujących rowery miejskie, możliwe jest użycie opracowanego modelu do wyznaczenia miejsc atrakcyjnych także dla użytkowników tego typu systemu, co jest kluczowe dla decydentów w wyznaczaniu stref, w których można pozostawić hulajnogi elektryczne. Jest to istotne z uwagi na przepisy w ramach nowelizacji Prawa o ruchu drogowym, które weszły w maju 2021 roku, mówiące o konieczności pozostawiania hulajnóg elektrycznych w miejscach wyznaczonych przez zarządcę drogi [224]. Wniosek ten wymaga jednak dodatkowych badań, które porównają wzorce mobilności użytkowników rowerów publicznych i hulajnóg elektrycznych.

6.1. Wnioski generalne

Na podstawie wszystkich analiz przeprowadzonych w pracy sformułowano następujące wnioski i rekomendacje:

- Ocena atrakcyjności otoczenia trasy w oparciu o walory kulturowo-przyrodnicze daje podstawę do waloryzacji przestrzeni publicznej pod kątem użytkowników rowerów publicznych, która jest sumą walorów kulturowych i przyrodniczych występujących na danym obszarze;
- Wraz ze wzrostem poziomu atrakcyjności otoczenia danej trasy rośnie długość podróży rowerem miejskim – zależność tę opisuje model regresji liniowej;
- Wraz ze wzrostem poziomu atrakcyjności otoczenia danej trasy rośnie czas podróży rowerem miejskim – zależność tę opisuje model regresji liniowej;
- Istnieje średnia korelacja pomiędzy współczynnikiem wydłużenia trasy a współczynnikiem zmiany poziomu atrakcyjności otoczenia trasy;
- Mediana współczynnika wydłużenia trasy wynosząca 1,33 i kwantyl 75% równy 1,58 sugerują, że podczas kształtowania tras rowerowych należy wziąć pod uwagę fakt, iż nie powinny one być dłuższe 1,3-1,5 razy niż najkrótsza odległość między źródłem a celem podróży;
- Większość postojów użytkowników rowerów publicznych związana jest z czynnościami związanymi z wypożyczeniem roweru ze stacji;
- Istotna część postojów użytkowników rowerów miejskich ma podłoże rekreacyjne i związane jest z atrakcyjnością otoczenia;
- Prawdopodobieństwo wystąpienia dużej liczby postojów użytkowników rowerów publicznych możliwe jest do obliczenia za pomocą modelu regresji logistycznej;
- Prawdopodobieństwo wystąpienia dużego sumarycznego czasu postojów użytkowników rowerów publicznych możliwe jest do obliczenia za pomocą modelu regresji logistycznej;
- Kształtowanie przestrzeni publicznej i jego aranżacja w zakresie doboru obiektów małej architektury powinno odbywać się z uwzględnieniem potrzeb rowerzystów.

6.2. Kierunki dalszych badań

Jako kontynuację prowadzonych badań proponuje się:

- Próbę opracowania modelu pozwalającego szacować liczbę podróży na konkretnych trasach pomiędzy źródłem a celem podróży, z wykorzystaniem poszerzonej o inne czynniki metodyki waloryzacji przestrzeni;
- Porównanie zmiany poziomu atrakcyjności otoczenia trasy w odniesieniu do najkrótszej trasy, niebędącej najkrótszą teoretyczną trasą (linią prostą);
- Analizę parametrów podróży rowerami miejskimi w zależności od kategorii atrakcyjności obszaru;
- Porównanie wzorców mobilności użytkowników rowerów publicznych i systemów hulajnog elektrycznych, a także użytkowników rowerów prywatnych;
- Rozszerzenie zaproponowanej metodyki o możliwość określania miejsc, w których powinny być instalowane stacje ładowania rowerów elektrycznych.

Spis rysunków

Rys. 2.1. Zagregowane wyniki ECC2017 dla Rzymu, Dublina, Warszawy i Pragi	36
Rys. 2.2. Udział podróży pieszych i rowerowych w krajach europejskich.....	41
Rys. 2.3. Udział podróży rowerowych w wybranych krajach, w zależności od motywacji podróży.....	42
Rys. 2.4. Czas podróży od drzwi do drzwi różnymi środkami transportu.....	49
Rys. 2.5. Systemy rowerów miejskich na świecie.....	64
Rys. 3.1. Fragment pliku w formacie GPX	73
Rys. 3.2. Struktura analizowanego pliku GPX.....	73
Rys. 3.3. Wykresy przykładowych podróży rowerami miejskimi Wavelo.....	75
Rys. 3.4. Rozkład średniej prędkości podróży w surowej próbie danych i próbie po każdym z etapów czyszczenia danych.....	83
Rys. 3.5. Mapa ciepła postojów rowerzystów w oczyszczonej próbie danych.....	85
Rys. 3.6. Mapa ciepła postojów w wyfiltrowanej próbie danych.....	88
Rys. 3.7. Siatka z przypisaną liczbą postojów użytkowników systemu Wavelo	90
Rys. 3.8. Obszary z największą liczbą postojów: A - Stare Miasto z Rynkiem Głównym i Wzgórzem Wawelskim, B - Kazimierz i Stare Podgórze, C – Bulwary Wiślane u ujścia Wilgi	91
Rys. 3.9. Siatka z przypisanym łącznym czasem [w min] postojów użytkowników systemu Wavelo	92
Rys. 3.10. Obszary z najdłuższym czasem postojów: A - Stare Miasto z Rynkiem Głównym i Wzgórzem Wawelskim, B - Kazimierz i Stare Podgórze, C - okolice dawnego Hotelu Forum, D – ul. Dolnych Młynów, E - Zalew Bagry, F - Ośrodek Sportu Kolna, G - Zakon Benedyktynów w Tyńcu.....	93
Rys. 3.11. Siatka z polami, w których wystąpiła duża liczba postojów użytkowników systemu Wavelo	95
Rys. 3.12. Siatka z polami, w których wystąpił długi sumaryczny czas postojów użytkowników systemu Wavelo.....	96
Rys. 4.1. Ocena walorów przestrzeni turystycznej Krakowa	101
Rys. 4.2. Miejsca i obszary koncentracji ruchu turystycznego w Krakowie.....	101
Rys. 4.3. Siatka z przypisaną liczbą zabytków w kategorii architektura i budownictwo	103
Rys. 4.4. Siatki z polami, w których występują walory kulturowe określonej kategorii	105
Rys. 4.5. Siatki z polami, w których występują walory przyrodnicze określonej kategorii	107
Rys. 4.6. Macierz korelacji zmiennych opisujących walory kulturowe i przyrodnicze	108

Rys. 4.7. Waloryzacja otoczenia trasy.....	109
Rys. 4.8. Najatrakcyjniejsze obszary Krakowa: A - Stare Miasto ze Wzgórzem Wawelskim, B – Bulwary/Stare Podgórze, C – Bulwary/okolice dawnego Hotelu Forum, D – Bulwary/Stare Dębniki, E – Bulwary Rudawy, F - Park Krakowski, G - Błonia z Parkiem Jordana.....	110
Rys. 5.1. Korelacja czasu podróży (t) i poziomu atrakcyjności otoczenia trasy (a)	119
Rys. 5.2. Wykres zależności atrakcyjności otoczenia trasy i czasu podróży	120
Rys. 5.3. Korelacja długości podróży (d) i poziomu atrakcyjności otoczenia trasy (a)	121
Rys. 5.4. Wykres zależności atrakcyjności otoczenia trasy i długości podróży	122
Rys. 5.5. Korelacja współczynnika wydłużenia trasy (r) i współczynnika zmiany poziomu atrakcyjności otoczenia trasy (w).....	123
Rys. 5.6. Wykres zależności współczynnika zmiany poziomu atrakcyjności otoczenia trasy i współczynnika wydłużenia trasy.....	124
Rys. 5.7. Porównanie predykowanych i rzeczywistych wartości liczby postojów	126
Rys. 5.8. Porównanie predykowanych i rzeczywistych wartości sumarycznego czasu postojów	128
Rys. 5.9. Tablica pomyłek dla modelu wpływu atrakcyjności otoczenia na liczbę postojów	130
Rys. 5.10. Krzywa ROC dla modelu wpływu atrakcyjności otoczenia na liczbę postojów...	131
Rys. 5.11. Tablica pomyłek dla modelu wpływu atrakcyjności otoczenia na łączny czas postojów	132
Rys. 5.12. Krzywa ROC dla modelu wpływu atrakcyjności otoczenia na łączny czas postojów	132

Spis fotografii

Fot. 2.1. Welocypedy z 1886 roku	21
Fot. 2.2. Parkingi Bike and Ride w Monachium (po lewej) i w Krakowie przy pętli tramwajowej Kurdwanów P+R (po prawej).....	35
Fot. 2.3. Licznik rowerowy w Warszawie	54
Fot. 2.4. Rowery Wavelo na stacji wypożyczeń przy Placu Wszystkich Świętych.....	65

Spis tabel

Tab. 3.1. Warunki pogodowe na stacji pomiarowej Kraków-Balice w dniach 31.05-7.06.2017 roku.....	72
Tab. 3.2. Statystyki oczyszczonej próbki danych.....	82
Tab. 3.3. Statystyki wyfiltrowanej próbki postojów	88
Tab. 4.1. Porównanie ocen w waloryzacji przestrzeni Krakowa.....	111
Tab. 5.1. Wartości błędów standardowych i statystyk t-Studenta dla współczynników regresji modelu regresji liniowej wpływu otoczenia trasy na liczbę postojów użytkowników rowerów miejskich.....	126
Tab. 5.2. Wartości błędów standardowych i statystyk t-Studenta dla współczynników regresji modelu regresji liniowej wpływu otoczenia trasy na czas postojów użytkowników rowerów miejskich.....	127

Bibliografia

- [1] J. D. Hunt and J. E. Abraham, “Influences on bicycle use,” *Transportation (Amst.)*, vol. 34, no. 4, pp. 453–470, 2007, doi: 10.1007/s11116-006-9109-1.
- [2] I. N. Sener, N. Eluru, and C. R. Bhat, “An Analysis of Bicycle Route Choice Preferences Using a Web-Based Survey to Examine Bicycle Facilities,” *Transportation (Amst.)*, vol. 36, no. 5, pp. 511–539, 2009.
- [3] C. Rudloff and B. Lackner, “Modeling Demand for Bikesharing Systems,” *Transp. Res. Rec. J. Transp. Res. Board*, vol. 2430, no. 1, pp. 1–11, Jan. 2014, doi: 10.3141/2430-01.
- [4] S. Shaheen, S. Guzman, and H. ZZZZhang, “Bikesharing in Europe, the Americas, and Asia,” *Transp. Res. Rec. J. Transp. Res. Board*, vol. 2143, no. January 2010, pp. 159–167, 2010, doi: 10.3141/2143-20.
- [5] S. Pogodzińska, “Szacowanie natężenia ruchu rowerowego na podstawie danych z systemu rowerów miejskich,” *Transp. Miej. i Reg.*, vol. 1, pp. 5–11, 2018.
- [6] Z. Wang, L. Cheng, Y. Li, and Z. Li, “Spatiotemporal characteristics of bike-sharing usage around rail transit stations: Evidence from Beijing, China,” *Sustain.*, vol. 12, no. 4, 2020, doi: 10.3390/su12041299.
- [7] J. Wang and G. Lindsey, “Neighborhood socio-demographic characteristics and bike share member patterns of use,” *J. Transp. Geogr.*, vol. 79, p. 102475, Jul. 2019, doi: 10.1016/j.jtrangeo.2019.102475.
- [8] J.-P. Rodrigue, C. Comtois, and B. Slack, *The Geography of Transport Systems*. 2009.
- [9] T. D. Tran, N. Ovtracht, and B. F. D’Arcier, “Modeling bike sharing system using built environment factors,” *Procedia CIRP*, vol. 30, pp. 293–298, 2015, doi: 10.1016/j.procir.2015.02.156.
- [10] M. Fall and M. Dąbrowski, “Jak rowery miejskie tworzą „smart cities”,” in *Biała Księga Mobilności 2015*, 2015, pp. 118–121.
- [11] A. Rudnicki and T. Kopta, “Planistyczno-komunikacyjne aspekty rozwoju komunikacji rowerowej,” *Transp. Miej.*, no. 5/6, pp. 42–49, 1996.
- [12] D. Miłaszewicz and B. Ostapowicz, “Warunki zrównoważonego rozwoju transportu w świetle dokumentów ue,” *Zeszyt Nauk. Unim. Szczecińskiego. Stud. i Pr. Wydż. Nauk Ekon. i Zarządzania*, vol. 24, no. 24, pp. 103–118, 2011, [Online]. Dostępne: https://wneiz.pl/nauka_wneiz/sip/sip24-2011/SiP-24-8.pdf.
- [13] “What is Big Data? | Oracle.” <https://www.oracle.com/big-data/guide/what-is-big-data.html> (Dostęp Feb. 03, 2019).
- [14] G. Press, “12 Big Data Definitions: What’s Yours?,” 2014.

- <https://www.forbes.com/sites/gilpress/2014/09/03/12-big-data-definitions-whats-yours/#2277b91013ae> (Dostęp Feb. 03, 2019).
- [15] “Big data | meaning in the Cambridge English Dictionary.” <https://dictionary.cambridge.org/dictionary/english/big-data> (Dostęp Feb. 03, 2019).
- [16] M. Dębowska-Mróż and P. Lis, “Kształtowanie przestrzeni transportowej dedykowanej pieszym i rowerzystom jako element poprawy mobilności w miastach,” *Autobusy*, vol. 12, pp. 522–527, 2017.
- [17] *Organizacja przestrzeni ulic w obszarach śródmiejskich - Poradnik*. Warszawa: Ministerstwo Infrastruktury i Rozwoju, 2013.
- [18] S. Turner, L. Sandt, J. Toole, R. Benz, and R. Patten, “FHWA University Course on Bicycle and Pedestrian Transportation: Student Workbook,” 2006. [Online]. Dostępne: <https://www.fhwa.dot.gov/publications/research/safety/pedbike/05085/pdf/combinedlo.pdf>.
- [19] “Velocipede Bicycle Club 1886 Greeting Card for Sale by Daniel Hagerman.” <https://fineartamerica.com/featured/velocipede-bicycle-club-1886-daniel-hagerman.html?product=greeting-card> (Dostęp May 30, 2021).
- [20] A. Zalewski, “Może jednak komunikacja rowerowa...,” *Transp. Miej.*, no. 3, pp. 55–58, 1987.
- [21] J. Kuzmyak Richard and J. Dill, “Walking and Bicycling in the United States: The Who, What, Where, and Why,” *TR News*, no. 280, pp. 4–15, 2012.
- [22] “Cycling: The Way Ahead for Towns and Cities,” 1999. [Online]. Dostępne: <http://booksandjournals.brillonline.com/content/10.1163/1571809042388581>.
- [23] C. Hydén, A. Nilsson, and R. Risser, “How to enhance WALking and CYcliNG instead of shorter car trips and to make these modes safer Public,” 1999.
- [24] T. Kopta, “Zdrowotne aspekty użytkowania roweru,” *Transp. Miej.*, no. 3, pp. 24–27, 1999.
- [25] *Declaration of Luxembourg on Cycling as a climate friendly Transport Mode*. Ministère du Développement durable et des Infrastructures, 2015, p. 5.
- [26] A. Zalewski, “Modele ruchu rowerowego w miastach i aglomeracjach,” in *Zeszyty Naukowo-Techniczne Stowarzyszenia Inżynierów i Techników Komunikacji w Krakowie. Seria: Materiały Konferencyjne: Ogólnopolska Konferencja Naukowo-Techniczna Modelowanie podróży i prognozowanie ruchu*, 2009, pp. 263–275.
- [27] H. Gonzalo-Orden, A. Linares, L. Velasco, J. M. Díez, and M. Rojo, “Bikeways and Cycling Urban Mobility,” *Procedia - Soc. Behav. Sci.*, vol. 160, no. August 2015, pp. 567–576, 2014, doi: 10.1016/j.sbspro.2014.12.170.
- [28] I. N. Sener, N. Eluru, and C. R. Bhat, “Who are Bicyclists? Why and how much are they Bicycling?” *Transp. Res. Rec. J. Transp. Res. Board*, vol. 2134, no. 1, pp. 63–72, Jan. 2009, doi: 10.3141/2134-08.

- [29] A. Zalewski, "Metody i środki promocji użytkowania roweru jako środka transportu," *Transp. Miej.*, no. 5/6, pp. 1–8, 1996.
- [30] G. Debrezion, E. A. J. H. Pels, and P. Rietveld, "The Impact of Rail Transport on Real Estate Prices: An Empirical Analysis of the Dutch Housing Market," *SSRN Electron. J.*, Mar. 2006, doi: 10.2139/ssrn.895270.
- [31] K. J. Krizek, "Two Approaches to Valuing Some of Bicycle Facilities' Presumed Benefits," *J. Am. Plan. Assoc.*, vol. 72, no. 3, pp. 309–320, 2006.
- [32] H. Garrett-Peltier, "Pedestrian and Bicycle Infrastructure: a National Study of Employment Impacts Executive Summary Pedestrian and Bicycle Infrastructure: a National Study of Employment Impacts," Amhrest, 2011. Dostęp: Jan. 26, 2019. [Online]. Dostępne: https://www.peri.umass.edu/fileadmin/pdf/published_study/PERI_ABikes_June2011.pdf.
- [33] M. Meschik, "Reshaping City Traffic Towards Sustainability Why Transport Policy should Favor the Bicycle Instead of Car Traffic," *Procedia - Soc. Behav. Sci.*, vol. 48, pp. 495–504, 2012, doi: 10.1016/j.sbspro.2012.06.1028.
- [34] *Plan B, The Comprehensive State Bicycle Plan for Minnesota*. Minnesota Department of Transportation, 1992.
- [35] M. Neun and H. Haubold, "The EU Cycling Economy – Arguments for an Integrated EU Cycling Policy," Bruksela, 2016.
- [36] C. J. Fegan, "National Bicycling and Walking Study," Nov. 1992. [Online]. Dostępne: <http://ntl.bts.gov/lib/25000/25000/25077/study.html>.
- [37] J. Pucher and R. Buehler, "Cycling for Everyone: Lessons from Europe," *Transp. Res. Rec. J. Transp. Res. Board*, vol. 2074, no. December, pp. 58–65, 2008, doi: 10.3141/2074-08.
- [38] J. Parkin, M. Wardman, and M. Page, "Estimation of the determinants of bicycle mode share for the journey to work using census data," *Transportation (Amst.)*, vol. 35, no. 1, pp. 93–109, Nov. 2007, doi: 10.1007/s11116-007-9137-5.
- [39] J. de D. Ortúzar, A. Iacobelli, and C. Valeze, "Estimating demand for a cycle-way network," *Transp. Res. Part A Policy Pract.*, vol. 34, no. 5, pp. 353–373, Jun. 2000, doi: 10.1016/S0965-8564(99)00040-3.
- [40] C. Ashley and C. Bannister, "Cycling to Work from Wards in a Metropolitan Area," *Traffic Eng. + Control*, 1989.
- [41] M. A. Stinson and C. R. Bhat, "An analysis of commuter bicyclist route choice using a stated preference survey," *Transp. Res. Rec. J. Transp. Res. Board*, vol. 1828, no. 1, pp. 107–115, 2003, doi: 10.3141/1828-13.
- [42] R. Cervero and M. Duncan, "Walking, Bicycling, and Urban Landscapes: Evidence

- from the San Francisco Bay Area,” *Am. J. Public Health*, vol. 93, no. 9, pp. 1478–1483, 2003, doi: 10.2105/AJPH.93.9.1478.
- [43] I. N. Sener, N. Eluru, and C. R. Bhat, “An analysis of bicycle route choice preferences in Texas, US,” *Transportation (Amst.)*, vol. 36, no. 5, pp. 511–539, Sep. 2009, doi: 10.1007/s11116-009-9201-4.
- [44] Y. He, Z. Song, Z. Liu, and N. N. Sze, “Factors Influencing Electric Bike Share Ridership: Analysis of Park City, Utah,” *Transp. Res. Rec.*, vol. 2673, no. 5, pp. 12–22, May 2019, doi: 10.1177/0361198119838981.
- [45] K. W. Axhausen and R. L. Smith, “Bicyclist link evaluation: a stated-preference approach,” *Transp. Res. Rec. J. Transp. Res. Board*, vol. 1085, pp. 7–15, 1986.
- [46] M. Beim, “Problemy ruchu rowerowego w Poznaniu,” Uniwersytet im. Adama Mickiewicza w Poznaniu, 2003.
- [47] T. Kopta, “Dlaczego rower nie jest w Polsce powszechnym środkiem komunikacji?,” *Transp. Miej.*, no. 2, pp. 51–55, 1985.
- [48] H. Knoflacher and H. P. Kloss, “Radverkehrsanlagen - Ergebnisse einer Erhebung,” *Strassenverkehrstechnik*, no. 4, pp. 109–116, 1979.
- [49] C. E. Ohrn, “Predicting the Type and Volume of Purposeful Bicycle Trips,” *Transp. Res. Rec.*, vol. 570, 1976.
- [50] S. Hanson and P. Hanson, “Problems in integrating bicycle travel into the urban transportation planning process,” *Transp. Res. Rec.*, no. 570, pp. 24–30, 1976.
- [51] J. Dill and T. Carr, “Bicycle Commuting and Facilities in Major U.S. Cities: If You Build Them, Commuters Will Use Them – Another Look,” *Transp. Res. Rec. J. Transp. Res. Board*, vol. 1828, p. 0, 2003.
- [52] M. Nankervis, “The effect of weather and climate on bicycle commuting,” *Transp. Res. Part A Policy Pract.*, vol. 33, no. 6, pp. 417–431, Aug. 1999, doi: 10.1016/S0965-8564(98)00022-6.
- [53] M. Winters, M. C. Friesen, M. Koehoorn, and K. Teschke, “Utilitarian Bicycling: a multilevel analysis of climate and personal influences,” *Am. J. Prev. Med.*, vol. 32, no. 1, pp. 52–58, Jan. 2007, doi: 10.1016/j.amepre.2006.08.027.
- [54] A. Zalewski, “Wpływ infrastruktury komunikacyjnej i czynników środowiskowych na ruch rowerowy w miastach średnich,” 1993.
- [55] L. Aultman-Hall, F. L. Hall, and B. B. Baetz, “Analysis of Bicycle Commuter Routes Using Geographic Information Systems: Implications for Bicycle Planning,” *Transp. Res. Rec. J. Transp. Res. Board*, vol. 1578, no. 1, pp. 102–110, Jan. 1997, doi: 10.3141/1578-13.

- [56] T. Kopta, "Użytkowanie roweru w krajach zmotoryzowanych," *Transp. Miejs.*, no. 2, pp. 49–52, 1984.
- [57] A. Brzeziński and K. Jesionkiewicz, "Problemy rozwoju systemu transportu rowerowego w miastach," 2005.
- [58] K. Shafizadeh and D. Niemeier, "Bicycle Journey-to-Work: Travel Behavior Characteristics and Spatial Attributes," *Transp. Res. Rec. J. Transp. Res. Board*, vol. 1578, no. 1, pp. 84–90, Jan. 1997, doi: 10.3141/1578-11.
- [59] C. Howard and E. K. Burns, "Cycling to Work in Phoenix: Route Choice, Travel Behavior, and Commuter Characteristics," *Transp. Res. Rec. J. Transp. Res. Board*, vol. 1773, no. 1, pp. 39–46, Jan. 2001, doi: 10.3141/1773-05.
- [60] N. Y. Tilahun, D. M. Levinson, and K. J. Krizek, "Trails, lanes, or traffic: Valuing bicycle facilities with an adaptive stated preference survey," *Transp. Res. Part A Policy Pract.*, vol. 41, no. 4, pp. 287–301, 2007, doi: 10.1016/j.tra.2006.09.007.
- [61] M. Jacyna, M. Wasiak, and P. Gołębiowski, "Model ruchu rowerowego dla Warszawy według Warszawskiego Badania Ruchu 2015," *Transp. Miejs. i Reg.*, vol. 10, pp. 5–11, 2016.
- [62] "Mienie gmin i powiatów w latach 2015–2017," Warszawa/Wrocław, 2018. Dostęp: Jan. 26, 2019. [Online]. Dostępne: http://stat.gov.pl/files/gfx/portalinformacyjny/pl/defaultaktualnosci/5483/4/4/1/zm_mienie_gmin_i_powiatow_2015-2017.pdf.
- [63] "GUS - Bank Danych Lokalnych." <https://bdl.stat.gov.pl/BDL/dane/podgrup/tablica> (Dostęp May 30, 2021).
- [64] T. Kopta, "Rower jako uzupełniający środek transportu w miastach," *Transp. Miejs.*, no. 1, pp. 6–10, 1983.
- [65] T. Kopta, B. Lustofin, G. Obara, and M. Rolla, "Ruch rowerowy w Polsce na tle innych krajów UE," Warszawa/Kraków, 2009.
- [66] "Sytuacja gospodarstw domowych w 2017 roku w świetle wyników badania budżetów gospodarstw domowych," 2016.
- [67] "Sytuacja gospodarstw domowych w 2019 r. w świetle wyników badania budżetów gospodarstw domowych," 2020.
- [68] "Status Report on the Downtown Transportation Coordination Program," 1988.
- [69] "Washington State Transportation Policy Plan, Final Report," 1991.
- [70] M. Jacyna, *Modelowanie i ocena systemów transportowych*. Oficyna Wydawnicza Politechniki Warszawskiej, 2009.
- [71] *Konstytucja Rzeczypospolitej Polskiej z dnia 2 kwietnia 1997 roku*. Polska.
- [72] *Ustawa z dnia 27 kwietnia 2001 roku - Prawo ochrony środowiska*. Polska.

- [73] T. Kopta, “Integracja transportu zbiorowego z rowerowym jednym z czynników zrównoważonego transportu,” *Transp. Miej. i Reg.*, no. 6, pp. 8–12, 2007.
- [74] J. G. A. Al, “Integrating transport and environmental policies: perspectives for a sustainable mobility,” 1991.
- [75] M. Głogowska, “Audyty, Ślady, Modele i Gry – Teraźniejszość i Przyszłość Narzędzi Zarządzania Zrównoważonym Rozwojem,” *Śląskie Stud. Reg.*, vol. I, pp. 56–65, 2010.
- [76] T. Kopta, “Bezpieczeństwo a polityka transportowa,” *Transp. Miej.*, no. 1, pp. 13–16, 1999.
- [77] T. Kopta, “Rower w zatrutym przez samochody środowisku,” *Bezpieczna Drog.*, no. 9, pp. 36–38, 2000.
- [78] “Charter of Brussels,” 2009. [Online]. Dostępne: <https://ecf.com/who-we-are/our-mission/charter-brussels%0Ahttp://www.velo-city2009.com/assets/files/VC09-charter-of-brussels.pdf>.
- [79] H. Wit, “Analiza metodą desk research dot. dostępności danych dotyczących poziomu lokalnego oraz dobrych praktyk na podstawie case studies,” Warszawa, 2015.
- [80] “The National Bicycling and Walking Study: 15–Year Status Report,” 2010.
- [81] *National Policies to Promote Cycling*. France: Organisation for Economic Cooperation and Development, 2004.
- [82] W. Starowicz, “Założenia europejskiej Zielonej Księgi dla transportu publicznego,” *TTS Tech. Transp. Sżyn. forum Prod. Konstr. i użytkowników*, vol. 5/6, pp. 60–64, 2007, [Online]. Dostępne: <https://fbc.pionier.net.pl/details/nnl2m3c>.
- [83] *Zielona Księga - W kierunku nowej kultury mobilności w mieście*. Bruksela: Komisja Europejska, 2007.
- [84] “Biała Księga Transportu.” <http://www.transforum-project.eu/pl/transforum/biala-ksiega-transportu.html> (Dostęp Jan. 26, 2019).
- [85] *Biała Księga Transportu - Plan utworzenia jednolitego europejskiego obszaru transportu – dążenie do osiągnięcia konkurencyjnego i zasobooszczędnego systemu transportu*, vol. KOM(2011). Luksemburg, 2011.
- [86] “Clean Transport, Urban Transport: Cycling,” *European Commission*. https://ec.europa.eu/transport/themes/urban/cycling_en (Dostęp Jan. 05, 2019).
- [87] “Bike Ride in Munich.” <https://www.muenchen.de/int/en/traffic/biking/bike-ride.html> (Dostęp May 30, 2021).
- [88] “Bike and ride. Pierwsze rowerowe parkingi już działają w Krakowie.” <https://krakow.wyborcza.pl/krakow/7,44425,25631126,rowerowa-nowosc-dla-kazdego.html> (Dostęp May 30, 2021).
- [89] “Co to jest BYPAD?” <https://bypad.pl/co-to-jest-bypad/> (Dostęp Jan. 22, 2019).

- [90] “STARS - Sustainable Travel Accreditation and Recognition for Schools.” http://starseurope.org/pl/about_stars.php (Dostęp Jan. 26, 2019).
- [91] “European Cycling Challenge.” <http://www.cyclingchallenge.eu/ecc2017> (Dostęp Jan. 26, 2019).
- [92] T. Dombi, “Promocja jazdy na rowerze na przykładzie kampanii European Cycling Challenge,” in *Biała Księga Mobilności 2015*, 2015, pp. 134–137.
- [93] K. Hebel and O. Wyszomirski, “Rower jako środek transportu w podróżach miejskich,” *Autobusy Tech. Eksploat. Syst. Transp.*, vol. 16, pp. 18–21, 2015, [Online]. Dostępne: <http://yadda.icm.edu.pl/baztech/element/bwmeta1.element.baztech-5c251ef3-189c-450c-bea6-41a030dd1d45>.
- [94] A. P. Zając, *Biała Księga Mobilności 2015*. 2015.
- [95] P. Ciesielski, “Realizacja polityk rowerowych na przykładzie Kopenhagi i Krakowa,” *Zarządzanie Publiczne*, vol. 1, no. 25, pp. 125–136, 2014, doi: 10.4467/20843968ZP.14.011.2184.
- [96] T. Kopta, “Kraków miastem rowerów,” *Transp. Miej.*, vol. 5, pp. 1–5, 1994.
- [97] C. Grochowski, “Polityka rozwoju ruchu rowerowego w polskich miastach - raport syntetyczny,” Wrocław, 2016.
- [98] A. Gołędzinowska, “Rower w mieście - polskie doświadczenia,” *Czas. Teh.*, no. 6, pp. 87–93, 2010.
- [99] “STARS – Rowerem do szkoły – zaproszenie dla szkół – Portal Edukacyjny.” https://portaledukacyjny.krakow.pl/aktualnosci/219930,1812,komunikat,stars__rowerem_do_szkoly__zaproszenie_dla_szkol.html (Dostęp Jan. 26, 2019).
- [100] “Mobility and Transport - Road Safety: Cycling as a transport mode,” *European Commission*. https://ec.europa.eu/transport/road_safety/specialist/knowledge/pedestrians/pedestrians_and_cyclists_unprotected_road_users/walking_and_cycling_as_transport_modes_en#_1.2.2_Cycling_as (Dostęp Jan. 05, 2019).
- [101] D. R. Bassett, J. Pucher, R. Buehler, D. L. Thompson, and S. E. Crouter, “Walking, Cycling, and Obesity Rates in Europe, North America, and Australia,” *J. Phys. Act. Heal.*, vol. 5, no. 6, pp. 795–814, 2008, doi: 10.1123/jpah.5.6.795.
- [102] *Eurostat Regional Yearbook - 2017 Edition*. Luksemburg: Eurostat - European Commission, 2017.
- [103] A. Radzimski, “Ruch pieszy i rowerowy jako elementy systemu zrównoważonego transportu miejskiego w Kopenhadze,” *Transp. Miej. i Reg.*, no. 2, pp. 12–20; 39, 2012.
- [104] “62 % af københavnerne cykler til arbejde og uddannelse.”

- <https://web.archive.org/web/20190707123514/https://www.kk.dk/indhold/62-af-koebenhavnerne-cykler-til-arbejde-og-uddannelse> (Dostęp May 30, 2021).
- [105] “Short Distance Passenger Mobility in Europe,” 2005.
- [106] K. Opoczyński, “Synteza wyników GPR 2015 na zamiejskiej sieci dróg krajowych,” Warszawa, 2016. [Online]. Dostępne: <https://www.gddkia.gov.pl/pl/2551/GPR-2015>.
- [107] “GPR 2020 :: Generalna Dyrekcja Dróg Krajowych i Autostrad - Serwis informacyjny.” <https://www.gddkia.gov.pl/pl/3959/GPR-2020> (Dostęp May 30, 2021).
- [108] A. Rudnicki, “Alternatywna polityka transportowa – opcje,” Warszawa, 1998.
- [109] A. Kostelecka, “Warszawskie Badanie Ruchu 2015 wraz z opracowaniem modelu ruchu. Raport z etapu III. Opracowanie wyników badań,” 2015. [Online]. Dostępne: http://transport.um.warszawa.pl/sites/default/files/WBR_2015_Etap_III_Raport_Wersja_06_2016.pdf.
- [110] P. Ostaszewski and D. Dudek, “Pomiary ruchu rowerowego 2020,” Warszawa, 2020.
- [111] R. Czubiński, “Gdańsk: Większy ruch rowerowy w trakcie pandemii - Transport Publiczny.” <https://www.transport-publiczny.pl/wiadomosci/gdansk-wiekszy-ruch-rowerowy-w-trakcie-pandemii-67348.html> (Dostęp May 30, 2021).
- [112] “Dla rowerzystów - Zarząd Transportu Publicznego w Krakowie.” <http://ztp.krakow.pl/rowery/#otwarte-dane> (Dostęp May 30, 2021).
- [113] M. Romanowska, “ECF: Miasta europejskie przesiadają się na rower. Pandemia impulsem do zmian - Transport Publiczny.” <https://www.transport-publiczny.pl/wiadomosci/ecf-miasta-europejskie-przesiadaja-sie-na-rower-pandemia-impulsem-do-zmian-67983.html> (Dostęp May 30, 2021).
- [114] E. Biernat, S. Buchholtz, and P. Bartkiewicz, “Motivations and barriers to bicycle commuting: Lessons from Poland,” *Transp. Res. Part F Traffic Psychol. Behav.*, vol. 55, pp. 492–502, 2018, doi: 10.1016/j.trf.2018.03.024.
- [115] “Boulder Valley Travel Study,” 1991.
- [116] J. Broach, J. Dill, and J. Gliebe, “Where do cyclists ride? A route choice model developed with revealed preference GPS data,” *Transp. Res. Part A Policy Pract.*, vol. 46, no. 10, pp. 1730–1740, Dec. 2012, doi: 10.1016/j.tra.2012.07.005.
- [117] E. Deakin, “Utilitarian Cycling, A Case Study Of The Bay Area And Assessment Of The Market For Commute Cycling,” 1985.
- [118] G. Sammer and G. Röschel, “Mobilitätsverhalten der Grazer Wohnbevölkerung 2008,” Graz, 2009.
- [119] M. D. Everett and J. Spencer, “Empirical Evidence on the Determinants of Mass

- Bicycle Commuting in the United States: A Cross Community Analysis,” *Transp. Res. Rec.*, vol. 912, 1983.
- [120] “Your Driving Costs,” 1991.
- [121] C. R. O. W., *Sign Up For the Bike - Postaw na rower - podręcznik projektowania przyjaznej dla rowerów infrastruktury*. Kraków: Polski Klub Ekologiczny, 1999.
- [122] R. Nair, E. Miller-Hooks, R. C. Hampshire, and A. Bušić, “Large-Scale Vehicle Sharing Systems: Analysis of Vélib’,” *Int. J. Sustain. Transp.*, vol. 7, no. 1, pp. 85–106, 2013, doi: 10.1080/15568318.2012.660115.
- [123] T. Kopta, M. Hyla, A. Buczyński, and B. Lustofin, “Konkurencyjność roweru w zakresie czasu podróży,” Warszawa/Kraków, 2012. [Online]. Dostępne: https://www.gddkia.gov.pl/userfiles/articles/i/infrastruktura-rowerowa_3000/konkurencyjnosc_roweru_w_czasie.pdf.
- [124] A. Yamamoto, H. Kobayashi, and K. Uesaka, “A study of bicycle travel speed,” 2012.
- [125] T. Kopta, *Rower w ruchu drogowym*. Warszawa: Wydawnictwo Komunikacji i Łączności, 1984.
- [126] R. Rakower, J. Łabędzki, and J. Gadziński, “Konkurencyjność ruchu rowerowego w przestrzeni miejskiej,” *Transp. Miej. i Reg.*, no. 2, pp. 31–38, 2011.
- [127] M. R. Virkler and R. Balasubramanian, “Flow Characteristics on Shared Hiking/Biking/Jogging Trails,” *Transp. Res. Rec. J. Transp. Res. Board*, vol. 1636, no. 1, pp. 43–46, Jan. 1998, doi: 10.3141/1636-07.
- [128] S. Bernardi and F. Rupi, “An Analysis of Bicycle Travel Speed and Disturbances on Off-street and On-street Facilities,” *Transp. Res. Procedia*, vol. 5, pp. 82–94, 2015, doi: 10.1016/j.trpro.2015.01.004.
- [129] A. El-Geneidy, K. J. Krizek, and M. Iacono, “Predicting Bicycle Travel Speeds Along Different Facilities Using GPS Data: A Proof of Concept Model,” *86th Annu. Meet. Transp. Res. Board, Washingt. D.C., USA.*, 2007, [Online]. Dostępne: http://tram.mcgill.ca/Research/Publications/Bicycle_travel_speed.pdf.
- [130] J. Parkin and J. Rotheram, “Design speeds and acceleration characteristics of bicycle traffic for use in planning, design and appraisal,” *Transp. Policy*, vol. 17, no. 5, pp. 335–341, 2010, doi: 10.1016/j.tranpol.2010.03.001.
- [131] C. Wolek, “Kształtowanie systemu ruchu rowerowego na przykładzie Wrocławia,” *Transp. Miej. i Reg.*, no. 11, pp. 35–39, 2010.
- [132] M. Hudson, *The Bicycle Planning Book*. Londyn, 1978.
- [133] K. Banet, “Using data on bike-sharing system user stopovers in smart tourism: A case study,” *Commun. - Sci. Lett. Univ. Zilina*, vol. 23, no. 2, pp. C1–C12, Jul. 2021, doi: 10.26552/COM.C.2021.2.G1-G12.

- [134] *Bicycle Facilities – Planning and Design Manual*. Department of Transportation Federal Highway Administration, Washington D.C., 1982.
- [135] R. Baca, “Trasy rowerowe w Polsce Wschodniej - województwo świętokrzyskie. Studium wykonalności,” Warszawa, 2012.
- [136] L. Aultman-Hall, J. Dowds, and B. H. Y. Lee, “Innovative Data Collection for Pedestrians, Bicycles, and Other Non-Motor Vehicle Modes,” *TR News*, pp. 8–9, 2012.
- [137] F. R. Proulx and A. Pozdnukhov, “Bicycle Traffic Volume Estimation using Geographically Weighted Data Fusion,” *J. Transp. Geogr.*, pp. 1–14, 2017.
- [138] “Pomiary ruchu | Rowerowa Warszawa.” <http://rowery.um.warszawa.pl/pomiary-ruchu-rowerowego-0> (Dostęp May 30, 2021).
- [139] J. Froehlich, J. Neumann, and N. Oliver, “Sensing and predicting the pulse of the city through shared bicycling,” *IJCAI Int. Jt. Conf. Artif. Intell.*, no. 3, pp. 1420–1426, 2009, doi: 10.1.1.150.4370.
- [140] J. Barceló, *Fundamentals of Traffic Simulation*, vol. 145. New York, NY: Springer New York, 2010.
- [141] F. Gerrit, “Cycling often lacks in traffic models: FLOW project aims to include active modes,” 2016. <https://ecf.com/news-and-events/news/cycling-often-lacks-traffic-models-flow-project-aims-include-active-modes> (Dostęp Dec. 25, 2018).
- [142] H. Twaddle, T. Schendzielorz, and O. Fakler, “Bicycles in Urban Areas,” *Transp. Res. Rec. J. Transp. Res. Board*, vol. 2434, no. 1, pp. 140–146, Jan. 2014, doi: 10.3141/2434-17.
- [143] E. Cascetta, *Transportation Systems Analysis*, vol. 29. Boston, MA: Springer US, 2009.
- [144] A. Szarata, “Wpływ zmian w strukturze przestrzennej na parametry 4-stadiowego modelu transportowego miasta,” *Czas. Tech.*, no. 3, pp. 249–261, 2010.
- [145] A. Hottenstein, S. Turner, and G. Shunk, “Bicycle and pedestrian travel demand forecasting: literature review,” 1997.
- [146] B. Fenton, A. Nash, and M. Wedderburn, *Ruch pieszy, ruch rowerowy i korki uliczne*. FLOW CIVITAS realizowany w ramach programu “Horyzont 2020,” 2018.
- [147] B. W. Landis, “Bicycle system performance measures,” *ITE J. (Institute Transp. Eng.)*, vol. 66, no. 2, pp. 18–26, 1996.
- [148] H. Xu, J. Ying, H. Wu, and F. Lin, “Public Bicycle Traffic Flow Prediction based on a Hybrid Model,” *Appl. Math. Inf. Sci.*, vol. 7, no. 2, pp. 667–674, Mar. 2013, doi: 10.12785/amis/070234.
- [149] D. Y. Lott, T. Tardiff, and D. F. Lott, “Evaluation by experienced riders of a new bicycle lane in an established bikeway system,” *Transp. Res. Rec.*, vol. 683, pp. 40–46, 1978.

- [150] H. L. Bovy and M. A. Bradley, "Route Choice Analyzed with Stated-Preference Approaches," *Transp. Res. Rec.*, vol. 1037, pp. 11–20, 1985.
- [151] "Calgary commuter cyclist survey 1992/1993; final results," Calgary, 1993.
- [152] C. L. Antonakos, "Environmental and travel preferences of cyclists," *Transp. Res. Rec.*, vol. 1438, pp. 25–33, Jan. 1994, doi: 10.1016/0965-8564(95)90300-3.
- [153] W. Jeffrey Davis, "Bicycle test route evaluation for urban road conditions," in *Transportation Congress: Civil Engineers - Key to the World's Infrastructure, Vol. 2*, B. K. Lall and D. L. Jones Jr., Eds. New York: American Society of Civil Engineers, 1995, pp. 1063–1076.
- [154] M. Guttenplan and R. Patten, "Off-road but on track: using bicycle and pedestrian trails for transportation," *TR News*, vol. 178, no. 3, pp. 7–11, 1995.
- [155] P. Hopkinson and M. Wardman, "Evaluating the demand for new cycle facilities," *Transp. Policy*, vol. 3, no. 4, pp. 241–249, Oct. 1996, doi: 10.1016/S0967-070X(96)00020-0.
- [156] L. Aultman-Hall, "Commuter bicycle route choice: analysis of major determinants and safety implications," McMaster University, 1996.
- [157] B. W. Landis, V. R. Vattikutti, and M. Brannick, "Real-time human perceptions: towards a bicycle level of service," *Transp. Res. Rec.*, vol. 1578, pp. 119–126, 1997.
- [158] M. Jacyna, M. Wasiak, M. Klodawski, and P. Gołębiowski, "Modelling of Bicycle Traffic in the Cities Using VISUM," *Procedia Eng.*, vol. 187, pp. 435–441, 2017, doi: 10.1016/j.proeng.2017.04.397.
- [159] G. Karoń, "Modelowanie popytu oparte na podróżach pojedynczych," *Logistyka*, vol. 4, pp. 323–342, 2012.
- [160] P. DeMaio, "Bike-sharing: History, impacts, models of provision, and future," *J. Public Transp.*, vol. 12, no. 2004, pp. 41–56, 2009, doi: 10.1016/0965-8564(93)90040-R.
- [161] A. A. Campbell, C. R. Cherry, M. S. Ryerson, and X. Yang, "Factors influencing the choice of shared bicycles and shared electric bikes in Beijing," *Transp. Res. Part C Emerg. Technol.*, vol. 67, pp. 399–414, 2016, doi: 10.1016/j.trc.2016.03.004.
- [162] S. Shaheen, S. Guzman, and H. Zhang, "Bikesharing in Europe, the Americas, and Asia," *Transp. Res. Rec. J. Transp. Res. Board*, vol. 2143, no. January 2010, pp. 159–167, 2010, doi: 10.3141/2143-20.
- [163] "The Meddin Bike-sharing World Map." <https://bikesharingworldmap.com/#/all/2.3/115.34/0/> (Dostęp May 30, 2021).
- [164] A. Liszka, "Ruch rowerowy jako integralna część ekologicznego transportu miejskiego - polityka rowerowa miasta Poznania na tle najlepszych praktyk europejskich," *Zeszyt. Nauk. Politech. Poznańskiej. Organ. i Zarządzanie*, vol. 60, no. 60, 2013.

- [165] M. Dębowska-Mróż, P. Lis, A. Szymanek, and T. Zawisza, “Rower miejski jako element systemu transportowego w miastach,” *Autobusy Tech. Eksploat. Syst. Transp.*, vol. 6, pp. 1173–1182, 2017.
- [166] Z. Bryniarska and N. Wilk, “Ocena systemu wypożyczalni rowerów miejskich Wavelo w Krakowie,” *Transp. Miej. i Reg.*, vol. 10, pp. 22–27, 2018.
- [167] “Zobacz, jak promuje się Wavelo - Magiczny Kraków.” https://www.krakow.pl/aktualnosci/205572,29,komunikat,zobacz_jak_promuje_sie_wavelo.html (Dostęp May 30, 2021).
- [168] J. Dybalski, “Kraków. Wavelo nie będzie. Może za rok - Transport Publiczny.” <https://www.transport-publiczny.pl/wiadomosci/krakow-wavelo-nie-bedzie-moze-za-rok-64033.html> (Dostęp May 30, 2021).
- [169] A. Rzędowska, “Rowery 2.0. Droga do smart city?,” Warszawa, 2018.
- [170] A. F. Imani, N. Eluru, A. El-Generdy, M. Rabbat, and U. Haq, “How does land-use and urban form impact bicycle flows: Evidence from the bicycle-1 sharing system (BIXI) in Montreal,” 2014, doi: 10.1002/jgrd.50214.
- [171] I. Frade and A. Ribeiro, “Bicycle Sharing Systems Demand,” *Procedia - Soc. Behav. Sci.*, vol. 111, no. February 2014, pp. 518–527, Feb. 2014, doi: 10.1016/j.sbspro.2014.01.085.
- [172] A. Nikiforiadis, G. Aifadopoulou, J. M. S. Grau, and N. Boufidis, “Determining the optimal locations for bike-sharing stations: Methodological approach and application in the city of Thessaloniki, Greece,” in *Transportation Research Procedia*, Jan. 2021, vol. 52, pp. 557–564, doi: 10.1016/j.trpro.2021.01.066.
- [173] C. Etienne and O. Latifa, “Model-Based count series clustering for bike sharing system usage mining: a case study with the Vélib’ System of Paris,” *ACM Trans. Intell. Syst. Technol.*, vol. 5, no. 3, pp. 1–21, Jul. 2014, doi: 10.1145/2560188.
- [174] J. Zhao, W. Fan, and X. Zhai, “Identification of land-use characteristics using bicycle sharing data: A deep learning approach,” *J. Transp. Geogr.*, vol. 82, no. August 2019, p. 102562, 2020, doi: 10.1016/j.jtrangeo.2019.102562.
- [175] G. Cantelmo, R. Kucharski, and C. Antoniou, “A low dimensional model for bike sharing demand forecasting,” *MT-ITS 2019 - 6th Int. Conf. Model. Technol. Intell. Transp. Syst.*, 2019, doi: 10.1109/MTITS.2019.8883283.
- [176] M. Barth and M. Todd, “Simulation model performance analysis of a multiple station shared vehicle system,” *Transp. Res. Part C Emerg. Technol.*, vol. 7, no. 4, pp. 237–259, 1999, doi: 10.1016/S0968-090X(99)00021-2.
- [177] L. Chen *et al.*, “Dynamic cluster-based over-demand prediction in bike sharing systems,” in *Proceedings of the 2016 ACM International Joint Conference on Pervasive and*

- Ubiquitous Computing - UbiComp '16*, 2016, pp. 841–852, doi: 10.1145/2971648.2971652.
- [178] J. Liu, L. Sun, W. Chen, and H. Xiong, “Rebalancing bike sharing systems: a multi-source data smart optimization,” in *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining - KDD '16*, 2016, pp. 1005–1014, doi: 10.1145/2939672.2939776.
- [179] F. Lin, J. Jiang, J. Fan, and S. Wang, “A stacking model for variation prediction of public bicycle traffic flow,” *Intell. Data Anal.*, vol. 22, no. 4, pp. 911–933, Jun. 2018, doi: 10.3233/IDA-173443.
- [180] Z. Kou and H. Cai, “Understanding bike sharing travel patterns: An analysis of trip data from eight cities,” *Phys. A Stat. Mech. its Appl.*, vol. 515, pp. 785–797, Feb. 2019, doi: 10.1016/j.physa.2018.09.123.
- [181] D. Buck and R. Buehler, “Bike lanes and other determinants of capital bikeshare trips,” *Transp. Res. Rec. J. Transp. Res. Board*, pp. 703–706, 2012, [Online]. Dostępne: <http://scholar.google.com/scholar?hl=en&btnG=Search&q=intitle:Bike+Lanes+and+Other+Determinants+of+Capital+Bikeshare+Trips#0>.
- [182] D. W. Daddio, “Maximizing Bicycle Sharing: an empirical analysis of capital bikeshare usage,” 2012.
- [183] X. Wang *et al.*, “Modeling Bike Share Station Activity: The Effects of Nearby Businesses and Jobs on Trips to and from Stations,” *Transp. Res. Rec.*, 2012.
- [184] R. Rixey, “Station-Level Forecasting of Bikesharing Ridership,” *Transp. Res. Rec. J. Transp. Res. Board*, vol. 2387, pp. 46–55, 2013, doi: 10.3141/2387-06.
- [185] X. Zeng, Y. Yang, S. Chen, and Y. Peng, “Traffic Flow Trend Forecast of Public Bicycle Network Based on ARIMA Model,” in *Proceedings of the 2017 International Conference on Computer, Electronics and Communication Engineering*, 2017, pp. 318–322, doi: 10.12783/dtcse/cece2017/14478.
- [186] P. Lin, J. Weng, S. Hu, D. Alivanistos, X. Li, and B. Yin, “Revealing Spatio-Temporal Patterns and Influencing Factors of Dockless Bike Sharing Demand,” *IEEE Access*, vol. 8, pp. 66139–66149, Apr. 2020, doi: 10.1109/access.2020.2985329.
- [187] J. Brinkmann, *Active Balancing of Bike Sharing Systems*. Braunschweig, Germany, 2020.
- [188] Y. Ni and J. Chen, “Exploring the effects of the built environment on two transfer modes for metros: Dockless bike sharing and taxis,” *Sustain.*, vol. 12, no. 5, Mar. 2020, doi: 10.3390/su12052034.
- [189] V. Albuquerque, F. Andrade, J. C. Ferreira, and M. S. Dias, “Understanding Spatiotemporal Station and Trip Activity Patterns in the Lisbon Bike-Sharing System,” in *Lecture Notes of the Institute for Computer Sciences, Social-Informatics and Telecommunications*

- Engineering, LNICST*, Dec. 2021, vol. 364 LNICST, pp. 16–34, doi: 10.1007/978-3-030-71454-3_2.
- [190] Y. Jing, S. Hu, and H. Lin, “Joint Analysis of Scooter Sharing and Bikesharing Usage: A Structural Equation Modeling Approach,” 2021.
- [191] X. Yan, X. Zhang, Y. Xu, X. Zhao, W. Yang, and I. Bejleri, “Do e-scooters fill mobility gaps and promote equity before and during COVID-19? A spatiotemporal analysis using open big data,” 2021. Dostęp: May 30, 2021. [Online]. Dostępne: <https://www.researchgate.net/publication/350104920>.
- [192] A. S. Bergantino, M. Intini, and L. Tangari, “Influencing factors for potential bike-sharing users: an empirical analysis during the COVID-19 pandemic,” *Res. Transp. Econ.*, vol. 86, p. 101028, May 2021, doi: 10.1016/j.retrec.2020.101028.
- [193] “Historyczne dane pomiarowe – Dane meteorologiczne Kraków Balice.” <https://meteomodel.pl/dane/historyczne-dane-pomiarowe/?data=2017-06-07&rodzaj=st&imgwid=350190566&dni=60&ord=desc> (Dostęp May 18, 2021).
- [194] “GPX: the GPS Exchange Format.” <https://www.topografix.com/gpx.asp> (Dostęp May 18, 2021).
- [195] “XML Introduction.” https://www.w3schools.com/xml/xml_what_is.asp (Dostęp May 18, 2021).
- [196] “GPX - OpenStreetMap Wiki.” <https://wiki.openstreetmap.org/wiki/GPX> (Dostęp May 18, 2021).
- [197] R. Néték and J. Burian, “Analysis of elevation data with time aspects for athletes,” *Proc. Surf. Model. Geosci.*, no. March, p. 10, 2012.
- [198] J. Hunt, *Advanced Guide to Python 3*. 2019.
- [199] “Project Jupyter | Home.” <https://jupyter.org/> (Dostęp May 21, 2021).
- [200] “Data Cleaning in 2021: What it is, Steps to Clean Data & Tools.” <https://research.aimultiple.com/data-cleaning/> (Dostęp May 28, 2021).
- [201] F. Ridzuan and W. M. N. Wan Zainon, “A review on data cleansing methods for big data,” *Procedia Comput. Sci.*, vol. 161, pp. 731–738, 2019, doi: 10.1016/j.procs.2019.11.177.
- [202] V. Naumov and K. Banet, “Estimating parameters of demand for trips by public bicycle system using GPS data,” *Adv. Intell. Syst. Comput.*, vol. 1091 AISC, no. January, pp. 213–224, 2020, doi: 10.1007/978-3-030-35543-2_17.
- [203] A. Bojko, “Informative or Misleading? Heatmaps Deconstructed,” in *Proceedings of the HCII 2009 Conference*, 2009, no. July 2009, doi: 10.1007/978-3-642-02574-7_4.

- [204] “OSM exports for Cracow by BBBike.org.” <https://download.bbbike.org/osm/bbbike/Cracow/> (Dostęp May 19, 2021).
- [205] J. Kronenberg and T. Bergier, Eds., *Wyzwania zrównoważonego rozwoju w Polsce*. Wrocław: Fundacja Sendzimira, 2010.
- [206] J. Ziarkowska and D. Ziarkowski, “Status quo czy panta rhei? Atrakcje turystyczne Krakowa od końca XVIII wieku do czasów współczesnych,” *Tur. Kult.*, vol. 7, pp. 34–53, 2015, Dostęp: May 24, 2021. [Online]. Dostępne: <http://www.turystykakulturowa.org/ojs/index.php/tk/article/view/605>.
- [207] W. Ratajczak, “Przestrzeń publiczna w aspekcie geograficznym i społecznym,” *Biul. Kom. Przestrz. Zagospod. Kraj. PAN*, vol. 183, 2018.
- [208] “Ustawa z dnia 27 marca 2003 r. o planowaniu i zagospodarowaniu przestrzennym,” 2003. <http://prawo.sejm.gov.pl/isap.nsf/DocDetails.xsp?id=WDU20030800717> (Dostęp Feb. 01, 2020).
- [209] R. Faracik *et al.*, *Waloryzacja przestrzeni miejskiej Krakowa dla potrzeb turystyki - raport końcowy*. Kraków: Instytut Geografii i Gospodarki Przestrzennej Uniwersytetu Jagiellońskiego, 2008.
- [210] P. Lorens and J. Martyniuk-Pęczek, “Wprowadzenie do projektowania urbanistycznego,” p. 104, 2014, [Online]. Dostępne: <https://arch.pg.edu.pl/documents/174968/51761959/skrypt7.pdf>.
- [211] P. Serafin, “Waloryzacja przestrzeni publicznych miasta. Studium przypadku Wieliczki,” *Zesz. Nauk. Univ. Ekon. w Krakowie*, no. 12(936), pp. 95–111, 2014, doi: 10.15678/znupek.2014.0936.1207.
- [212] W. Kurek, *Turystyka*. Warszawa: Wydawnictwo Naukowe PWN, 2007.
- [213] U. Myga-Piątek, “Kryteria i metody oceny krajobrazu kulturowego w procesie planowania przestrzennego na tle obowiązujących procedur prawnych,” in *Waloryzacja środowiska przyrodniczego w planowaniu przestrzennym*, Gdańsk/Warszawa, 2007, pp. 101–110.
- [214] U. Litwin, S. Bacior, and I. Piech, “Metodyka waloryzacji i oceny krajobrazu,” 2009.
- [215] O. Kowalska, “Metody oceny krajobrazu kulturowego - Urbnews.pl,” 2014. <http://urbnews.pl/metody-oceny-krajobrazu-kulturowego/> (Dostęp Feb. 02, 2020).
- [216] B. Konecka-Szydłowska, “Ocena przestrzeni publicznej małych miast aglomeracji poznańskiej,” *Kwart. Nauk. Inst. Rozw. Miast*, vol. XIII, no. III/2016, pp. 5–12, 2016.
- [217] M. Tracz and M. Semczuk, “Wpływ turystyki na zmianę funkcji przestrzeni miejskiej na przykładzie Krakowa,” *Biul. Kom. Przestrz. Zagospod. Kraj. PAN*, vol. 272, pp. 272–284, 2018.
- [218] “Miejski System Informacji Przestrzennej - MSIP Kraków.” <https://msip.krakow.pl/> (Dostęp May 24, 2021).

- [219] R. Lyman Ott and M. Longnecker, *An Introduction to Statistical Methods and Data Analysis*, 7th ed. Boston: Cengage Learning, 2015.
- [220] “Siła korelacji, klasyfikacja.” https://www.naukowiec.org/wiedza/statystyka/sila-korelacji--klasyfikacja_512.html (Dostęp May 24, 2021).
- [221] “Rekreacja - Encyklopedia PWN.” <https://encyklopedia.pwn.pl/haslo/rekreacja;3966939.html> (Dostęp May 29, 2021).
- [222] J. Novakovic, A. Veljovi, S. Iic, Z. Papic, and M. Tomovic, “Evaluation of Classification Models in Machine Learning,” *Theory Appl. Math. Comput. Sci.*, vol. 7, no. 1, pp. 39–46, 2017, [Online]. Dostępne: <https://uav.ro/applications/se/journal/index.php/TAMCS/article/view/158>.
- [223] K. Feng, H. Hong, K. Tang, and J. Wang, “Decision Making with Machine Learning and ROC Curves,” *SSRN Electron. J.*, pp. 1–52, 2019, doi: 10.2139/ssrn.3382962.
- [224] “Nowe przepisy dotyczące hulajnog elektrycznych i urządzeń transportu osobistego - Ministerstwo Infrastruktury - Portal Gov.pl.” <https://www.gov.pl/web/infrastruktura/nowe-przepisy-dotyczace-hulajnog-elektrycznych-i-urzadzen-transportu-osobistego> (Dostęp May 30, 2021).

Spis załączników

Do wersji elektronicznej niniejszej pracy dołączone zostały skrypty z kodem przygotowanym w języku Python, które zostały napisane w celu analizy danych o podróżach rowerami miejskimi Wavelo:

- **Skrypt #1** – kod służący czyszczeniu danych i przypisaniu podróżom parametrów je opisujących;
- **Skrypt #2** – kod służący pozyskaniu danych o postojach i ich filtrowaniu wraz z przygotowaniem map ciepła liczby i sumarycznego czasu postojów;
- **Skrypt #3** – kod służący obróbce danych o walorach krajobrazowych wraz z przygotowaniem siatki waloryzacyjnej;
- **Skrypt #4** – kod służący przygotowaniu modeli wpływu atrakcyjności otoczenia trasy na czas trwania podróży, długość podróży i współczynnik wydłużenia trasy;
- **Skrypt #5** – kod służący przygotowaniu modeli wpływu atrakcyjności otoczenia trasy na liczbę i sumaryczny czas postojów.



Politechnika Krakowska
im. Tadeusza Kościuszki

Skrypt #1

Import bibliotek

In []:

```
import math
import xml.etree.ElementTree as ET
from datetime import datetime, timedelta
from matplotlib import pyplot as plt
import numpy as np
from scipy import stats
import csv
import pandas as pd
```

Zdefiniowanie klas

In []:

```
class TrackPoint:

    def __init__(self, time, lat, lon):
        self.time = time
        self.lat = lat # latitude
        self.lon = lon # longitude

class Track:

    def __init__(self):
        self.points = [] # track points
        self.all_segments = []

    def gps_distance(self, p1, p2):
        # Haversine Formula
        lat1, lon1 = p1.lat, p1.lon
        lat2, lon2 = p2.lat, p2.lon
        Earth_radius = 6371 # km
        dlat = math.radians(lat2 - lat1)
        dlon = math.radians(lon2 - lon1)
        a = (math.sin(0.5 * dlat) * math.sin(0.5 * dlat) +
             math.cos(math.radians(lat1)) * math.cos(math.radians(lat2)) *
             math.sin(0.5 * dlon) * math.sin(0.5 * dlon))
        return 2 * Earth_radius * math.atan2(math.sqrt(a), math.sqrt(1 - a))

    @property
    def size(self):
        return len(self.points)

    @property
    def is_epmty(self):
        return self.size == 0

    @property
    def has_bad_timing(self):
        dt, dd, dv = self.segments
        bad_timing = False
        for t in dt:
            if t > 5 * 60:
                # GPS tracker didn't respond for more than 5 minutes
                bad_timing = True
                break
        return bad_timing

    @property
    def has_small_distance(self):
        # total distance is less than 10 m
        return self.travel_distance < 0.1

    @property
    def origin(self):
        return None if self.is_epmty else self.points[0]
```

```

@property
def destination(self):
    return None if self.is_epmty else self.points[-1]

@property
def idle_time(self):
    t = 0.0
    if not self.is_epmty:
        ts, ds, _ = self.segments
        n = len(ts)
        if n > 0:
            for i in range(n):
                if ds[i] == 0:
                    t += ts[i]
    return t

@property
def travel_time(self):
    return 0 if self.is_epmty else (self.destination.time - self.origin.time).seconds

@property
def travel_distance(self):
    td = 0.0
    if not self.is_epmty:
        _, dd, _ = self.segments
        td = sum(dd)
    return td

@property
def mean_speed(self):
    ms = 0.0
    if not self.is_epmty:
        _, _, vs = self.segments
        if len(vs) != 0:
            ms = 1.0 * sum(vs) / len(vs)
    return ms

@property
def aver_speed(self):
    return 0 if self.travel_time == 0 else 3600 * self.travel_distance / self.travel_time

@property
def pure_speed(self):
    return 0.0 if self.travel_time == 0 or self.travel_time == self.idle_time \
        else 3600.0 * self.travel_distance / (self.travel_time - self.idle_time)

@property
def irr_coef(self):
    return 0 if self.gps_distance(self.origin, self.destination) == 0 else 1.0 * self.travel_distance

@property
def segments(self):
    dt, dist, velocity = [], [], []
    if not self.is_epmty:
        for i in range(self.size - 1):
            dt.append((self.points[i + 1].time - self.points[i].time).seconds)
            dist.append(self.gps_distance(self.points[i], self.points[i + 1]))
            velocity.append(3600.0 * dist[-1] / dt[-1])
    return dt, dist, velocity

```

```

class GPX:

```

```

    def __init__(self, file_name):
        tree = ET.parse(file_name)
        self.tracks = self.get_tracks(tree)

    def get_tracks(self, tree):
        trks = []
        root = tree.getroot()
        for trk in root:
            # print trk.tag, trk.attrib
            for trkseg in trk:
                tr = Track()
                for trkpt in trkseg:

```

```

tstr = trkpt[0].text # 2017-05-31T22:03:41Z
year, month, day = tstr[:4], tstr[5:7], tstr[8:10]
hour, minute, sec = tstr[11:13], tstr[14:16], tstr[17:19]
time = datetime(int(year), int(month), int(day),
                int(hour), int(minute), int(sec))
if tr.is_epmty or time != tr.points[-1].time: # exclude repetitions
    tr.points.append(TrackPoint(time=time,
                                lat=float(trkpt.attrib.get('lat')),
                                lon=float(trkpt.attrib.get('lon'))))
    # print "Points in track:", len(tr.points)
    trks.append(tr)
return trks

```

Import surowych danych w formacie GPX

```

gpx = GPX('all_trips.gpx')
len(gpx.tracks)

```

In []:

Wyznaczenie parametrów każdej z podróży w próbce danych

```

f = open('all_trips_parameters.txt', 'w')
idx = 0
for track in gpx.tracks:
    idx += 1
    f.write(str(idx) + ',\t' + str(track.travel_time) + ',\t' +
           str(track.travel_distance) + ',\t' + str(track.aver_speed) + ',\t' + str(track.pure_speed) +
           str(track.irr_coef) + ',\t' + str(track.idle_time) + '\n')
f.close()

```

In []:

```

trips = []
with open('all_trips_parameters.txt', 'r') as csvfile:
    trips_reader = csv.reader(csvfile, delimiter=',', quotechar='.')
    for data in trips_reader:
        y = [round(int(data[0])),
             round(float(data[1])),
             round(float(data[2]), 2),
             round(float(data[3]), 2),
             round(float(data[4]), 2),
             round(float(data[5]), 2),
             round(float(data[6]))]
        trips.append(y)
len(trips)

```

In []:

Czyszczenie - krok 1: przerwy w sygnale GPS

```

bad_indices_1 = []
id1 = 1
for track in gpx.tracks:
    if track.has_bad_timing == True:
        bad_indices_1.append(id1)
        id1 += 1
print(len(bad_indices_1))
trips_1 = []
for i in range(len(trips)):
    if not (trips[i][0] in bad_indices_1):
        trips_1.append(trips[i])

```

In []:

In []:

```
print(len(trips_1))
```

Czyszczenie - krok 2: podróże z zerowym czasem trwania lub dystansem

```
trips_2 = []

dur_zero, dist_zero = 0, 0

for i in range(len(trips_1)):
    if trips_1[i][1] == 0:
        dur_zero += 1
    elif trips_1[i][2] == 0:
        dist_zero += 1
    else:
        trips_2.append(trips_1[i])

print(dur_zero, dist_zero, len(trips_2))
```

In []:

Czyszczenie - krok 3: podróże niezakończone

```
trips_3 = []

dist = 0

for i in range(len(trips_2)):
    if trips_2[i][2] > 0.1:
        trips_3.append(trips_2[i])
    else:
        dist += 1

print(dist, len(trips_3))
```

In []:

```
good_indices_3 = []

for i in range(len(trips_3)):
    good_indices_3.append(trips_3[i][0])

len(good_indices_3)
```

In []:

Eksport oczyszczonych danych

```
def tracks_to_file(source_file, target_file, indices):
    f1 = open(source_file, 'r')
    f2 = open(target_file, 'w')
    f2.write("<?xml version='1.0' encoding='UTF-8'?\>\n")
    f2.write("<gpx version='1.0' creator='ExpertGPS 1.1 - http://www.topografix.com' " + \
            "xmlns:xsi='http://www.w3.org/2001/XMLSchema-instance' " + \
            "xmlns='http://www.topografix.com/GPX/1/0' " + \
            "xsi:schemaLocation='http://www.topografix.com/GPX/1/0 " + \
            "http://www.topografix.com/GPX/1/0/gpx.xsd'\>\n")

    #
    track_idx = 0
    for line in f1:
        if line.strip() == "<trk>":
            track_idx += 1
            if track_idx in indices:
                f2.write(line)

    #
    f1.close()
    f2.write("</gpx>")
    f2.close()

tracks_to_file('all_trips.gpx', 'clean_trips_10m.gpx', good_indices_3)
```

In []:

In []:

```

gpx_clean = GPX('clean_trips_10m.gpx')

len(gpx_clean.tracks)

In [ ]:

f = open('clean_trips_parameters_10m.txt', 'w')

idx = 0

for track in gpx_clean.tracks:
    idx += 1
    f.write(str(idx) + ',\t' + str(track.travel_time) + ',\t' +
            str(track.travel_distance) + ',\t' + str(track.aver_speed) + ',\t' + str(track.pure_speed) +
            str(track.irr_coef) + ',\t' + str(track.idle_time) + '\n')

f.close()

```

```

trips_clean = []

In [ ]:

with open('clean_trips_parameters_10m.txt', 'r') as csvfile:
    trips_reader = csv.reader(csvfile, delimiter=',', quotechar='.')
    for data in trips_reader:
        y = [round(int(data[0])),
              round(float(data[1]) / 60, 2),
              round(float(data[2]), 2),
              round(float(data[3]), 2),
              round(float(data[4]), 2),
              round(float(data[5]), 2),
              round(float(data[6]) / 60, 2)]
        trips_clean.append(y)

len(trips_clean)

```

```

In [ ]:

trips_clean_df = pd.DataFrame(trips_clean, columns = ['ID', 'Czas podróży [min]',
                                                    'Dystans podróży [km]', 'Śr. prędkość podróży [km/h]',
                                                    'Śr. prędkość jazdy [km/h]', 'Wsp. wydł. trasy', 'C:

In [ ]:

trips_clean_df

In [ ]:

trips_clean_df.describe()

```

Wykresy podróży

```

In [ ]:

font1 = {'family':'sans-serif','color':'black','size':14}

In [ ]:

def plot_track(gpx_name, idx):
    tr = gpx_name.tracks[idx - 1]
    ts, ds, vs = [0], [0], [0]
    dt, dd, dv = tr.segments
    #
    track_time, track_dist = 0, 0
    cds = [0] # cumulative distance
    for (t, d) in zip(dt, dd):
        track_time += t / 60.0
        track_dist += d
        ts.append(track_time)
        cds.append(track_dist)
    ds.extend(dd)
    vs.extend(dv)

    plt.plot(ts, cds, color='darkblue')
    plt.xlabel('Czas podróży [min]', fontdict = font1)
    plt.ylabel('Dystans [km]', fontdict = font1)
    plt.xticks(fontsize = 12)
    plt.yticks(fontsize = 12)
    plt.savefig('dist.jpg', bbox_inches='tight', dpi = 150)
    plt.show()

    plt.plot(ts, vs, color='darkblue')
    plt.xlabel('Czas podróży [min]', fontdict = font1)

```

```

plt.ylabel('Prędkość [km/h]', fontdict = font1)
plt.xticks(fontsize = 12)
plt.yticks(fontsize = 12)
plt.savefig('speed.jpg', bbox_inches='tight', dpi = 150)
plt.show()

```

```
plot_track(gpx_clean, 12888)
```

Rozkłady

In []:

```
sturges = lambda sample: 1 + int(1.44 * math.log(len(sample)))
```

```

def bounds(sample):
    # define the bins number
    k = sturges(sample)
    # define the minimum value and the bins width
    x_min = min(sample)
    h = 1.0 * (max(sample) - x_min) / k
    return [(x_min + (i - 1) * h,
             x_min + i * h) for i in range(1, k + 1)]

```

```

def efreqs(sample):
    # define the list of bounds
    bs = bounds(sample)
    # take the bins number
    k = len(bs)
    # initialize the resulting variable
    res = [0 for _ in range(k)]
    for x in sample:
        for i in range(k - 1):
            if x >= bs[i][0] and x < bs[i][1]:
                res[i] += 1
        if x >= bs[k - 1][0]:
            res[k - 1] += 1
    return res

```

```

def tfreqs_normal(sample):
    n = len(sample)
    bs = bounds(sample)
    mean_x = 1.0 * sum(sample) / n
    sd_x = math.sqrt(1.0 * sum([(x - mean_x)**2 for x in sample]) / n)
    cdfs = [ (stats.norm.cdf(b[0], mean_x, sd_x), \
             stats.norm.cdf(b[1], mean_x, sd_x)) for b in bs]
    return [round(n * (cdf[1] - cdf[0]), 2) for cdf in cdfs]

```

```

def tfreqs_expon(sample):
    n = len(sample)
    bs = bounds(sample)
    mean_x = 1.0 * sum(sample) / n
    #sd_x = math.sqrt(1.0 * sum([(x - mean_x)**2 for x in sample]) / n)
    cdfs = [ (stats.expon.cdf(b[0], scale=mean_x), \
             stats.expon.cdf(b[1], scale=mean_x)) for b in bs]
    return [round(n * (cdf[1] - cdf[0]), 2) for cdf in cdfs]

```

```

def check_normal(sample, prob=0.05):
    efs = efreqs(sample)
    tfs = tfreqs_normal(sample)
    k = len(efs)
    print ("Sample size: ", len(sample))
    print ("Number of bins: ", k)
    chi2 = []
    for i in range(k):
        chi2.append((efs[i] - tfs[i]) ** 2 / tfs[i])
    chi2test = sum(chi2)
    print ("Normal chi2test:", chi2test, stats.chi2.ppf(1 - prob, k - 2 - 1), chi2test <= stats.chi2.ppf(1 - prob, k - 2 - 1))
    return chi2test <= stats.chi2.ppf(1 - prob, k - 2 - 1)

```

```

def check_expon(sample, prob=0.05):
    efs = efreqs(sample)
    tfs = tfreqs_expon(sample)
    k = len(efs)
    print ("Sample size: ", len(sample))
    print ("Number of bins: ", k)

```



```

chi2 = []
for i in range(k):
    chi2.append((efs[i] - tfs[i]) ** 2 / tfs[i])
chi2test = sum(chi2)
print ("Expon chi2test:", chi2test, stats.chi2.ppf(1 - prob, k - 1 - 1), chi2test <= stats.chi2.ppf(1
return chi2test <= stats.chi2.ppf(1 - prob, k - 1 - 1)

```

In []:

```

def chi2_test(xs, f=stats.norm, alpha=0.05):
    # define empirical frequencies and bounds of bins
    efs, bounds, _ = plt.hist(xs)
    # calculate cdf
    params = f.fit(xs)
    Fs = f.cdf(bounds, *params)
    # calculate theoretical frequencies
    N = len(xs)
    tfs = [N * (Fs[i + 1] - Fs[i])
            for i in range(len(Fs) - 1)]
    # calculate criterion
    chi2e = sum([(tfs[i] - efs[i]) ** 2 / tfs[i]
                 for i in range(len(efs))])
    return chi2e <= stats.chi2.ppf(1 - alpha, len(efs) - len(params) - 1), chi2e

```

In []:

```

def plot_normal(xs, bins=100):
    m, s = stats.norm.fit(xs)
    print ("Normal distribution parameters:", m, s)

    lnspace = np.linspace(xs.min(), xs.max(), len(xs))
    pdf_g = stats.norm.pdf(lnspace, m, s)

    plt.hist(xs, bins=bins, density=True, color='darkblue')
    plt.xlabel("Prędkość [km/h]", fontdict = font1)
    plt.ylabel("Gęstość", fontdict = font1)
    plt.xticks(fontsize = 12)
    plt.yticks(fontsize = 12)
    plt.plot(lnspace, pdf_g, color='red')
    plt.savefig('travel_distribution.jpg', bbox_inches='tight', dpi = 150)
    plt.show()

def plot_gamma(xs):
    a, b, c = stats.gamma.fit(xs)
    print (a, b, c)

    lnspace = np.linspace(xs.min(), xs.max(), len(xs))
    pdf_gamma = stats.gamma.pdf(lnspace, a, b, c)

    plt.hist(xs, bins=100, density=True, color='darkblue')
    plt.xlabel("Dystans [km]", fontdict = font1)
    plt.ylabel("Gęstość", fontdict = font1)
    plt.xticks(fontsize = 12)
    plt.yticks(fontsize = 12)
    plt.plot(lnspace, pdf_gamma, label="gamma", color='red')
    plt.show()

def plot_expon(xs):
    _, b = stats.expon.fit(xs, floc=0)
    print (b)

    lnspace = np.linspace(xs.min(), xs.max(), len(xs))
    pdf_expon = stats.expon.pdf(lnspace, scale=b)

    plt.hist(xs, bins=100, density=True, color='darkblue')
    plt.xlabel("Dystans [km]", fontdict = font1)
    plt.ylabel("Gęstość", fontdict = font1)
    plt.xticks(fontsize = 12)
    plt.yticks(fontsize = 12)
    plt.plot(lnspace, pdf_expon, label="expon", color='red')
    plt.show()

```

Rozkłady prędkości - surowe dane, po 1, 2 i 3 etapie czyszczenia

In []:

```

travel_speed_0 = []

for i in range(len(trips)):

```

```

travel_speed_0.append(trips[i][3])

travel_speed_0_arr = np.array(travel_speed_0)
len(travel_speed_0_arr)

travel_speed_1 = []

for i in range(len(trips_1)):
    travel_speed_1.append(trips_1[i][3])

travel_speed_1_arr = np.array(travel_speed_1)
len(travel_speed_1_arr)

travel_speed_2 = []

for i in range(len(trips_2)):
    travel_speed_2.append(trips_2[i][3])

travel_speed_2_arr = np.array(travel_speed_2)
len(travel_speed_2_arr)

travel_speed_3 = []

for i in range(len(trips_3)):
    travel_speed_3.append(trips_3[i][3])

travel_speed_3_arr = np.array(travel_speed_3)
len(travel_speed_3_arr)

check_normal(travel_speed_0_arr, prob=0.05)

check_normal(travel_speed_1_arr, prob=0.05)

check_normal(travel_speed_2_arr, prob=0.05)

check_normal(travel_speed_3_arr, prob=0.05)

print(chi2_test(travel_speed_3_arr, f=stats.expon))
print(chi2_test(travel_speed_3_arr, f=stats.norm))
print(chi2_test(travel_speed_3_arr, f=stats.lognorm))
print(chi2_test(travel_speed_3_arr, f=stats.gamma))
print(chi2_test(travel_speed_3_arr, f=stats.logistic))
print(chi2_test(travel_speed_3_arr, f=stats.chi2))

plot_normal(travel_speed_0_arr)

plot_normal(travel_speed_1_arr)

plot_normal(travel_speed_2_arr)

plot_normal(travel_speed_3_arr)

```

Rozkłady dystansu, czasu, wsp. wydłużenia - oczyszczone dane

```

travel_time_3 = []

for i in range(len(trips_3)):
    travel_time_3.append(trips_3[i][1])

travel_time_3_arr = np.array(travel_time_3)
len(travel_time_3_arr)

check_expon(travel_time_3, prob=0.05)

print(chi2_test(travel_time_3, f=stats.expon))
print(chi2_test(travel_time_3, f=stats.norm))

```

```
print(chi2_test(travel_time_3, f=stats.lognorm))
print(chi2_test(travel_time_3, f=stats.gamma))
print(chi2_test(travel_time_3, f=stats.logistic))
print(chi2_test(travel_time_3, f=stats.chi2))
```

In []:

```
plot_expon(travel_time_3_arr)
```

In []:

```
travel_dist_3 = []
```

```
for i in range(len(trips_3)):
    travel_dist_3.append(trips_3[i][2])
```

```
travel_dist_3_arr = np.array(travel_dist_3)
len(travel_dist_3)
```

In []:

```
check_expon(travel_dist_3, prob=0.05)
```

In []:

```
print(chi2_test(travel_dist_3, f=stats.expon))
print(chi2_test(travel_dist_3, f=stats.norm))
print(chi2_test(travel_dist_3, f=stats.lognorm))
print(chi2_test(travel_dist_3, f=stats.gamma))
print(chi2_test(travel_dist_3, f=stats.logistic))
print(chi2_test(travel_dist_3, f=stats.chi2))
```

In []:

```
plot_expon(travel_dist_3_arr)
```

In []:

```
travel_irr_3 = []
```

```
for i in range(len(trips_3)):
    travel_irr_3.append(trips_3[i][5])
```

```
travel_irr_3_arr = np.array(travel_irr_3)
len(travel_irr_3_arr)
```

In []:

```
check_expon(travel_irr_3, prob=0.05)
```

In []:

```
plot_expon(travel_irr_3_arr)
```

Skrypt #2

Import bibliotek

In []:

```
import math
import numpy as np
import pandas as pd
import csv
from pandas import DataFrame
import seaborn as sb
import matplotlib.pyplot as plt
import xml.etree.ElementTree as ET
from datetime import datetime, timedelta
import matplotlib as mpl
from matplotlib.colors import LinearSegmentedColormap
import folium
```

Zdefiniowanie klas

In []:

```
class TrackPoint:

    def __init__(self, time, lat, lon):
        self.time = time
        self.lat = lat # latitude
        self.lon = lon # longitude

class Track:

    def __init__(self):
        self.points = [] # track points
        self.all_segments = []

    def gps_distance(self, p1, p2):
        # Haversine Formula

        lat1, lon1 = p1.lat, p1.lon
        lat2, lon2 = p2.lat, p2.lon

        Earth_radius = 6371 # km
        dlat = math.radians(lat2 - lat1)
        dlon = math.radians(lon2 - lon1)
        a = (math.sin(0.5 * dlat) * math.sin(0.5 * dlat) +
             math.cos(math.radians(lat1)) * math.cos(math.radians(lat2)) *
             math.sin(0.5 * dlon) * math.sin(0.5 * dlon))

        return 2 * Earth_radius * math.atan2(math.sqrt(a), math.sqrt(1 - a))

    @property
    def start_lat(self, p1): #punkt początkowy odcinka - latitude

        lat1 = p1.lat

        return lat1

    @property
    def start_lon(self, p1): #punkt początkowy odcinka - logtitude

        lon1 = p1.lon

        return lon1

    @property
    def size(self):
        return len(self.points)

    @property
    def is_epmty(self):
```

```

    return self.size == 0

@property
def has_bad_timing(self):
    _, _, dt, dd, dv = self.segments
    bad_timing = False
    for t in dt:
        if t > 5 * 60:
            # GPS tracker didn't respond for more than 5 minutes
            bad_timing = True
            break
    return bad_timing

@property
def has_small_distance(self):
    # total distance is less than 100 m
    return self.travel_distance < 0.1

@property
def origin(self):
    return None if self.is_epmty else self.points[0]

@property
def destination(self):
    return None if self.is_epmty else self.points[-1]

@property
def idle_time(self):
    t = 0.0
    if not self.is_epmty:
        _, _, ts, ds, _ = self.segments
        n = len(ts)
        if n > 0:
            for i in range(n):
                if ds[i] == 0:
                    t += ts[i]
    return t

@property
def idle_time_place(self):
    lat_place, lon_place, idle_place = [], [], []

    if not self.is_epmty:
        stlat, stlon, ts, ds, _ = self.segments
        n = len(ts)
        if n > 0:
            i = 0
            while i < n:

                if ds[i] == 0:
                    t = 0.0
                    t += ts[i]
                    lat = stlat[i]
                    lon = stlon[i]
                    i += 1

                if i == n:
                    break

                while ds[i] == 0:
                    t += ts[i]
                    i += 1

                if i == n:
                    break

            lat_place.append(lat)
            lon_place.append(lon)
            idle_place.append(t)

        else:
            i += 1

    return lat_place, lon_place, idle_place

@property

```

```

def travel_time(self):
    return 0 if self.is_epmty else (self.destination.time - self.origin.time).seconds

@property
def travel_distance(self):
    td = 0.0
    if not self.is_epmty:
        _, _, _, dd, _ = self.segments
        td = sum(dd)
    return td

@property
def mean_speed(self):
    ms = 0.0
    if not self.is_epmty:
        _, _, vs = self.segments
        if len(vs) != 0:
            ms = 1.0 * sum(vs) / len(vs)
    return ms

@property
def aver_speed(self):
    return 0 if self.travel_time == 0 else 3600 * self.travel_distance / self.travel_time

@property
def segments(self):
    start_lat, start_lon, dt, dist, velocity = [], [], [], [], []
    if not self.is_epmty:
        for i in range(self.size - 1):
            start_lat.append(self.points[i].lat)
            start_lon.append(self.points[i].lon)
            dt.append((self.points[i + 1].time - self.points[i].time).seconds)
            dist.append(self.gps_distance(self.points[i], self.points[i + 1]))
            velocity.append(3600.0 * dist[-1] / dt[-1])
    return start_lat, start_lon, dt, dist, velocity

```

```
class GPX:
```

```

def __init__(self, file_name):
    tree = ET.parse(file_name)
    self.tracks = self.get_tracks(tree)

def get_tracks(self, tree):
    trks = []
    root = tree.getroot()
    for trk in root:
        # print trk.tag, trk.attrib
        for trkseg in trk:
            tr = Track()
            for trkpt in trkseg:
                tstr = trkpt[0].text # 2017-05-31T22:03:41Z
                year, month, day = tstr[:4], tstr[5:7], tstr[8:10]
                hour, minute, sec = tstr[11:13], tstr[14:16], tstr[17:19]
                time = datetime(int(year), int(month), int(day),
                                int(hour), int(minute), int(sec))
                if tr.is_epmty or time != tr.points[-1].time: # exclude repetitions
                    tr.points.append(TrackPoint(time=time,
                                                  lat=float(trkpt.attrib.get('lat')),
                                                  lon=float(trkpt.attrib.get('lon'))))
            # print "Points in track:", len(tr.points)
            trks.append(tr)
    return trks

```

Import oczyszczonych danych w formacie GPX

```
In []:
```

```
gpx_clean = GPX('C:/Users/Krystian/Dysk Google/_doktorat/09_obliczenia_final_scalone/00_dane/clean_trips_
```

Wyznaczenie siatki dla zasięgu Krakowa

```
In []:
```

```
#zasięg Krakowa
```

```

x_min = 19.789
x_max = 20.219
y_min = 49.962
y_max = 50.130

x_interval = round((x_max - x_min) / 100, 4)
y_interval = round((y_max - y_min) / 60, 4)

print(x_interval)
print(y_interval)

```

In []:

```

#wyznaczenie siatki
Lon = np.arange(x_min, x_max, x_interval)
Lat = np.arange(y_max, y_min, -y_interval)

```

In []:

```

Lon_labels = []

for i in range(1, len(Lon)):
    if i % 20 == 0:
        Lon_labels.append("{:.3f}".format(Lon[i]))
    else:
        Lon_labels.append('')

```

In []:

```

Lat_labels = []

for i in range(1, len(Lat)):
    if i % 20 == 0:
        Lat_labels.append("{:.3f}".format(Lat[i]))
    else:
        Lat_labels.append('')

```

In []:

```

krakow = pd.read_csv('dane/krakow.csv')

```

In []:

```

krakow_grid = np.zeros((60,100))

```

In []:

```

for b1 in range(60):
    for b2 in range(100):
        for a in range(len(krakow)):
            if Lat[b1] >= krakow['ycoord'].values[a] > Lat[b1] - y_interval:
                if Lon[b2] <= krakow['xcoord'].values[a] < Lon[b2] + x_interval:
                    krakow_grid[b1, b2] += 1
                    break

```

```

sum(sum(krakow_grid))

```

In []:

```

np.savetxt('dane/krakow_grid.csv', krakow_grid, delimiter=",")

```

Wczytanie danych o stacjach, skrzyżowaniach i przejazdach

In []:

```

#wczytanie stacji
stations = []

with open('dane/stacje_2017.csv', newline='') as csvfile:
    crd = csv.reader(csvfile, delimiter=';')

    for row in crd:
        Y = []
        Y.append(float(row[0]))
        Y.append(float(row[1]))
        stations.append(Y)

stations_df = pd.DataFrame(stations, columns = ['lat', 'lon'])

```

In []:

```

#wczytanie skrzyżowań
crossroads = []

with open('dane/skrzyzowania.csv', newline='') as csvfile:
    crd = csv.reader(csvfile, delimiter=';')

```



```

for row in crd:
    Y = []
    Y.append(float(row[0]))
    Y.append(float(row[1]))
    crossroads.append(Y)

crossroads_df = pd.DataFrame(crossroads, columns = ['lat', 'lon'])

#wczytanie przejazdów
railcrossings = []

with open('dane/przejazdy.csv', newline='') as csvfile2:
    przej = csv.reader(csvfile2, delimiter=';')

    for row in przej:
        Y = []
        Y.append(float(row[0]))
        Y.append(float(row[1]))
        railcrossings.append(Y)

railcrossings_df = pd.DataFrame(railcrossings, columns = ['lat', 'lon'])

```

In []:

Wyznaczenie miejsc postojów

```

tracks_clean = gpx_clean.tracks

postoje_0 = []

for track in tracks_clean:
    if track.idle_time > 0:

        for i in range(len(track.idle_time_place[0])):
            X = []

            X.append(track.idle_time_place[0][i])
            X.append(track.idle_time_place[1][i])
            X.append(track.idle_time_place[2][i])

            postoje_0.append(X)

postoje_0_df = pd.DataFrame(postoje_0, columns = ['lat', 'lon', 'idle_time'])
print(len(postoje_0))

postoje_0_df.to_csv('postoje_0.csv', index=False)

```

In []:

In []:

Czyszczenie - krok 1: postoje w Krakowie

```

postoje_1_krakow = []

for a in range(len(postoje_0)):
    for b1 in range(60):
        if Lat[b1] >= postoje_0[a][0] > Lat[b1] - y_interval:
            for b2 in range(100):
                if Lon[b2] <= postoje_0[a][1] < Lon[b2] + x_interval:

                    if krakow_grid[b1,b2] == 1:
                        X = []
                        X.append(postoje_0[a][0])
                        X.append(postoje_0[a][1])
                        X.append(postoje_0[a][2])

                        postoje_1_krakow.append(X)

postoje_1_krakow_df = pd.DataFrame(postoje_1_krakow, columns = ['lat', 'lon', 'idle_time'])
print(len(postoje_1_krakow), len(postoje_0) - len(postoje_1_krakow))

postoje_1_krakow_df.to_csv('postoje_1_krakow.csv', index=False)

```

In []:

In []:

Czyszczenie - krok 2: postoje bez stacji

In []:

```
def gps_dist(p1, p2):
    # Haversine Formula

    lat1, lon1 = p1[0], p1[1]
    lat2, lon2 = p2[0], p2[1]

    Earth_radius = 6371 # km
    dlat = math.radians(lat2 - lat1)
    dlon = math.radians(lon2 - lon1)
    a = (math.sin(0.5 * dlat) * math.sin(0.5 * dlat) +
         math.cos(math.radians(lat1)) * math.cos(math.radians(lat2)) *
         math.sin(0.5 * dlon) * math.sin(0.5 * dlon))

    return 2 * Earth_radius * math.atan2(math.sqrt(a), math.sqrt(1 - a))
```

In []:

```
postoje_2 = []

for i in range(len(postoje_1_krakow)): #idle_places
    for j in range(len(stations)): #stations
        if gps_dist(postoje_1_krakow[i], stations[j]) < 0.001 * 10:
            break
        elif j == (len(stations) - 1):
            X = []
            X.append(postoje_1_krakow[i][0])
            X.append(postoje_1_krakow[i][1])
            X.append(postoje_1_krakow[i][2])

            postoje_2.append(X)

        else:
            continue

postoje_2_df = pd.DataFrame(postoje_2, columns = ['lat', 'lon', 'idle_time'])
print(len(postoje_2), len(postoje_1_krakow) - len(postoje_2))
```

In []:

```
postoje_2_df.to_csv('postoje_2.csv', index=False)
```

Czyszczenie - krok 3: postoje dłuższe niż 30 s

In []:

```
postoje_3 = []

for i in range(len(postoje_2)): #idle places without stations
    if postoje_2[i][2] > 30:
        Y = []
        Y.append(postoje_2[i][0])
        Y.append(postoje_2[i][1])
        Y.append(postoje_2[i][2])

        postoje_3.append(Y)

    else:
        continue

postoje_3_df = pd.DataFrame(postoje_3, columns = ['lat', 'lon', 'idle_time'])
print(len(postoje_3), len(postoje_2) - len(postoje_3))
```

In []:

```
postoje_3_df.to_csv('postoje_3.csv', index=False)
```

Czyszczenie - krok 4: postoje bez postojów na skrzyżowaniach

In []:

```
postoje_4 = []

for i in range(len(postoje_3)): #idle_places
    for j in range(len(crossroads)): #crossroads
```

```

if gps_dist(postoje_3[i], crossroads[j]) < 0.001 * 50: #50 m
    break
elif j == (len(crossroads) - 1):
    X = []
    X.append(postoje_3[i][0])
    X.append(postoje_3[i][1])
    X.append(postoje_3[i][2])

    postoje_4.append(X)

else:
    continue

postoje_4_df = pd.DataFrame(postoje_4, columns = ['lat', 'lon', 'idle_time'])
print(len(postoje_4), len(postoje_3) - len(postoje_4))

postoje_4_df.to_csv('postoje_4.csv', index=False)

```

In []:

Czyszczenie - krok 5: postoje bez postojów na przejazdach kolejowych

In []:

```

postoje_5 = []

for i in range(len(postoje_4)): #idle_places
    for j in range(len(railcrossings)): #railway crossings
        if gps_dist(postoje_4[i], railcrossings[j]) < 0.001 * 50: # 50m
            break
        elif j == (len(railcrossings) - 1):
            X = []
            X.append(postoje_4[i][0])
            X.append(postoje_4[i][1])
            X.append(postoje_4[i][2])

            postoje_5.append(X)

        else:
            continue

postoje_5_df = pd.DataFrame(postoje_5, columns = ['lat', 'lon', 'idle_time'])
print(len(postoje_5), len(postoje_4) - len(postoje_5))

postoje_5_df.to_csv('postoje_5.csv', index=False)

```

In []:

In []:

```

postoje_5_multiply = []

for i in range(len(postoje_5_df)):
    for j in range(int(postoje_5_df.iat[i, 2])):
        X = []
        X.append(postoje_5_df.iat[i, 0])
        X.append(postoje_5_df.iat[i, 1])

        postoje_5_multiply.append(X)

postoje_5_multiply_df = pd.DataFrame(postoje_5_multiply, columns = ['lat', 'lon'])
print(len(postoje_5_multiply))

postoje_5_multiply_df.to_csv('postoje_5_multiply.csv', index=False)

```

In []:

Siatka postojów - liczba postojów

In []:

```

postoje_liczba = np.zeros((60,100))

for a in range(len(postoje_5_df)):
    for b1 in range(60):
        if Lat[b1] >= postoje_5_df['lat'].values[a] > Lat[b1] - y_interval:
            for b2 in range(100):
                if Lon[b2] <= postoje_5_df['lon'].values[a] < Lon[b2] + x_interval:

```

In []:

```

postoje_liczba[b1, b2] += 1

sum(sum(postoje_liczba))

plt.subplots(figsize=(22,10))
plt.xticks(fontsize=20)
plt.yticks(fontsize=20)
sb.set(font_scale=2)
myColors = ((0.99, 0.99, 0.99, 0.99), (0.95, 0.8, 0.0, 0.95))
cmap = LinearSegmentedColormap.from_list('Custom', myColors, 19)
value_heatmap = sb.heatmap(postoje_liczba, xticklabels = Lon_labels,
                           yticklabels = Lat_labels, cmap = cmap, cbar=True)
value_heatmap.set_yticklabels(value_heatmap.get_yticklabels(), rotation = 0)
value_heatmap.hlines([20, 40], *value_heatmap.get_xlim(), color = 'grey')
value_heatmap.vlines([20, 40, 60, 80], *value_heatmap.get_ylim(), color = 'grey')

plt.savefig('postoje_liczba.jpg', bbox_inches='tight', dpi = 150)

```

In []:

```

postoje_liczba_df = pd.DataFrame(postoje_liczba)
postoje_liczba_df.to_csv('postoje_liczba.csv', index=False)

```

In []:

Zmienna dychotomiczna

```

np.max(postoje_liczba)

```

In []:

```

postoje_liczba_no_zero = []

```

In []:

```

for b1 in range(60):
    for b2 in range(100):
        if postoje_liczba[b1,b2] > 0:
            postoje_liczba_no_zero.append(postoje_liczba[b1,b2])

```

```

sum(postoje_liczba_no_zero)

```

In []:

```

#percentyl 95%
q95 = np.percentile(postoje_liczba_no_zero, 95)
q95

```

In []:

```

postoje_liczba_0_1_q95 = np.zeros((60,100))

```

In []:

```

for b1 in range(60):
    for b2 in range(100):
        if postoje_liczba[b1,b2] >= q95:
            postoje_liczba_0_1_q95[b1,b2] = 1
        else:
            postoje_liczba_0_1_q95[b1,b2] = 0

```

```

sum(sum(postoje_liczba_0_1_q95))

```

In []:

```

plt.subplots(figsize=(22,10))
plt.xticks(fontsize=20)
plt.yticks(fontsize=20)
sb.set(font_scale=2)
myColors = ((0.99, 0.99, 0.99, 0.99), (0.95, 0.8, 0.0, 0.95))
cmap = LinearSegmentedColormap.from_list('Custom', myColors, 2)
value_heatmap = sb.heatmap(postoje_liczba_0_1_q95, xticklabels = Lon_labels,
                           yticklabels = Lat_labels, cmap = cmap, cbar=True)
value_heatmap.set_yticklabels(value_heatmap.get_yticklabels(), rotation = 0)
colorbar = value_heatmap.collections[0].colorbar
colorbar.set_ticks([0.25, 0.75])
colorbar.set_ticklabels(['0 (nie)', '1 (tak)'])
value_heatmap.hlines([20, 40], *value_heatmap.get_xlim(), color = 'grey')
value_heatmap.vlines([20, 40, 60, 80], *value_heatmap.get_ylim(), color = 'grey')

plt.savefig('postoje_liczba_0_1_q95.jpg', bbox_inches='tight', dpi = 150)

```

In []:

```

postoje_liczba_0_1_q95_df = pd.DataFrame(postoje_liczba_0_1_q95)
postoje_liczba_0_1_q95_df.to_csv('postoje_liczba_0_1_q95.csv', index=False)

```

Siatka postojów - łączny czas postojów

```
postoje_czas = np.zeros((60,100))

for a in range(len(postoje_5_multiply_df)):
    for b1 in range(60):
        if Lat[b1] >= postoje_5_multiply_df['lat'].values[a] > Lat[b1] - y_interval:
            for b2 in range(100):
                if Lon[b2] <= postoje_5_multiply_df['lon'].values[a] < Lon[b2] + x_interval:
                    postoje_czas[b1, b2] += 1

sum(sum(postoje_czas))

postoje_czas_min = np.zeros((60,100))

for b1 in range(60):
    for b2 in range(100):
        X = round(postoje_czas[b1,b2] / 60)
        postoje_czas_min[b1,b2] = X

sum(sum(postoje_czas_min))

postoje_czas_godz = np.zeros((60,100))

for b1 in range(60):
    for b2 in range(100):
        X = round(postoje_czas[b1,b2] / 3600, 2)
        postoje_czas_godz[b1,b2] = X

sum(sum(postoje_czas_godz))

plt.subplots(figsize=(22,10))
plt.xticks(fontsize=20)
plt.yticks(fontsize=20)
sb.set(font_scale=2)
myColors = ((0.99, 0.99, 0.99, 0.99), (0.95, 0.8, 0.0, 0.95))
cmap = LinearSegmentedColormap.from_list('Custom', myColors, 20)
value_heatmap = sb.heatmap(postoje_czas_godz, xticklabels = Lon_labels,
                            yticklabels = Lat_labels, cmap = cmap, cbar=True)
value_heatmap.set_yticklabels(value_heatmap.get_yticklabels(), rotation = 0)
value_heatmap.hlines([20, 40], *value_heatmap.get_xlim(), color = 'grey')
value_heatmap.vlines([20, 40, 60, 80], *value_heatmap.get_ylim(), color = 'grey')

plt.savefig('postoje_czas_godz.jpg', bbox_inches='tight', dpi = 150)

postoje_czas_df = pd.DataFrame(postoje_czas)
postoje_czas_df.to_csv('postoje_czas.csv', index=False)

postoje_czas_min_df = pd.DataFrame(postoje_czas_min)
postoje_czas_min_df.to_csv('postoje_czas_min.csv', index=False)

postoje_czas_godz_df = pd.DataFrame(postoje_czas_godz)
postoje_czas_godz_df.to_csv('postoje_czas_godz.csv', index=False)
```

Zmienna dychotomiczna

```
np.max(postoje_czas)

postoje_czas_no_zero = []

for b1 in range(60):
    for b2 in range(100):
        if postoje_czas[b1,b2] > 0:
            postoje_czas_no_zero.append(postoje_czas[b1,b2])

sum(postoje_czas_no_zero)
```

```

#percentyl 95%
q95a = np.percentile(postoje_czas_no_zero, 95)
q95a / 3600

postoje_czas_0_1_q95 = np.zeros((60,100))

for b1 in range(60):
    for b2 in range(100):
        if postoje_czas[b1,b2] >= q95a:
            postoje_czas_0_1_q95[b1,b2] = 1
        else:
            postoje_czas_0_1_q95[b1,b2] = 0

sum(sum(postoje_czas_0_1_q95))

plt.subplots(figsize=(22,10))
plt.xticks(fontsize=20)
plt.yticks(fontsize=20)
sb.set(font_scale=2)
myColors = ((0.99, 0.99, 0.99, 0.99), (0.95, 0.8, 0.0, 0.95))
cmap = LinearSegmentedColormap.from_list('Custom', myColors, 2)
value_heatmap = sb.heatmap(postoje_czas_0_1_q95, xticklabels = Lon_labels,
                           yticklabels = Lat_labels, cmap = cmap, cbar=True)
value_heatmap.set_yticklabels(value_heatmap.get_yticklabels(), rotation = 0)
colorbar = value_heatmap.collections[0].colorbar
colorbar.set_ticks([0.25, 0.75])
colorbar.set_ticklabels(['0 (nie)', '1 (tak)'])
value_heatmap.hlines([20, 40], *value_heatmap.get_xlim(), color = 'grey')
value_heatmap.vlines([20, 40, 60, 80], *value_heatmap.get_ylim(), color = 'grey')

plt.savefig('postoje_czas_0_1_q95.jpg', bbox_inches='tight', dpi = 150)

postoje_czas_0_1_q95_df = pd.DataFrame(postoje_czas_0_1_q95)
postoje_czas_0_1_q95_df.to_csv('postoje_czas_0_1_q95.csv', index=False)

```

Mapa folium - liczba postojów

```

def get_geojson_grid(upper_right, lower_left, n=6, m=6):
    """Returns a grid of geojson rectangles, and computes the exposure in each section of the grid based

    Parameters
    -----
    upper_right: array_like
        The upper right hand corner of "grid of grids" (the default is the upper right hand [lat, lon] o:

    lower_left: array_like
        The lower left hand corner of "grid of grids" (the default is the lower left hand [lat, lon] of

    n: integer
        The number of rows/columns in the (n,n) grid.

    Returns
    -----

    list
        List of "geojson style" dictionary objects
    """

    all_boxes = []

    lat_steps = np.linspace(lower_left[0], upper_right[0], n+1)
    lon_steps = np.linspace(lower_left[1], upper_right[1], m+1)

    lat_stride = lat_steps[1] - lat_steps[0]
    lon_stride = lon_steps[1] - lon_steps[0]

    for lat in lat_steps[:-1]:
        for lon in lon_steps[:-1]:
            # Define dimensions of box in grid
            upper_left = [lon, lat + lat_stride]

```

```

upper_right = [lon + lon_stride, lat + lat_stride]
lower_right = [lon + lon_stride, lat]
lower_left = [lon, lat]

# Define json coordinates for polygon
coordinates = [
    upper_left,
    upper_right,
    lower_right,
    lower_left,
    upper_left
]

geo_json = {"type": "FeatureCollection",
            "properties":{
                "lower_left": lower_left,
                "upper_right": upper_right
            },
            "features":[]}

grid_feature = {
    "type":"Feature",
    "geometry":{
        "type":"Polygon",
        "coordinates": [coordinates],
    }
}

geo_json["features"].append(grid_feature)

all_boxes.append(geo_json)

return all_boxes

```

In []:

```
postoje_liczba_list = []
```

```

for i in range(60):
    for j in range(100):
        postoje_liczba_list.append(postoje_liczba[i][j])

```

```
len(postoje_liczba_list)
```

In []:

```

myColors = ((0.99, 0.99, 0.99, 0.99), (0.95, 0.8, 0.0, 0.95))
cmap = LinearSegmentedColormap.from_list('Custom', myColors, 19)

```

```
color_values = cmap(range(19))
```

In []:

```
color_values_list = color_values.tolist()
```

In []:

```

def color_value(i):

    if postoje_liczba_list[i] < 15:
        color = color_values_list[0]
    elif postoje_liczba_list[i] < 30:
        color = color_values_list[1]
    elif postoje_liczba_list[i] < 45:
        color = color_values_list[2]
    elif postoje_liczba_list[i] < 60:
        color = color_values_list[3]
    elif postoje_liczba_list[i] < 75:
        color = color_values_list[4]
    elif postoje_liczba_list[i] < 90:
        color = color_values_list[5]
    elif postoje_liczba_list[i] < 105:
        color = color_values_list[6]
    elif postoje_liczba_list[i] < 120:
        color = color_values_list[7]
    elif postoje_liczba_list[i] < 135:
        color = color_values_list[8]
    elif postoje_liczba_list[i] < 150:
        color = color_values_list[9]
    elif postoje_liczba_list[i] < 165:
        color = color_values_list[10]
    elif postoje_liczba_list[i] < 180:

```



```

        color = color_values_list[11]
    elif postoje_liczba_list[i] < 195:
        color = color_values_list[12]
    elif postoje_liczba_list[i] < 210:
        color = color_values_list[13]
    elif postoje_liczba_list[i] < 225:
        color = color_values_list[14]
    elif postoje_liczba_list[i] < 240:
        color = color_values_list[15]
    elif postoje_liczba_list[i] < 255:
        color = color_values_list[16]
    elif postoje_liczba_list[i] < 270:
        color = color_values_list[17]
    else:
        color = color_values_list[18]

    return color

```

In []:

```

lower_left = [y_max, x_min]
upper_right = [y_min, x_max]
m = folium.Map(tiles="Stamen Toner", zoom_start = 12, location=[50.055, 19.97])
grid = get_geojson_grid(upper_right, lower_left , n=60, m=100)

```

```

for i, geo_json in enumerate(grid):

    color = color_value(i)
    color = mpl.colors.to_hex(color)

    gj = folium.GeoJson(geo_json,
                        style_function=lambda feature, color=color: {
                            'fillColor': color,
                            'color': "grey",
                            'weight': 0.3,
                            'fillOpacity': 0.7,
                        })

    popup = folium.Popup("example popup {}".format(i))
    gj.add_child(popup)

    m.add_child(gj)
m

```

In []:

```
m.save('postoje_liczba.html')
```

Mapa folium - czas postojów

In []:

```

postoje_czas_list = []

for i in range(60):
    for j in range(100):
        postoje_czas_list.append(postoje_czas[i][j])

len(postoje_czas_list)

```

In []:

```

def color_value_czas(i):

    if postoje_czas_list[i] < 3300:
        color = color_values_list[0]
    elif postoje_czas_list[i] < 6600:
        color = color_values_list[1]
    elif postoje_czas_list[i] < 9900:
        color = color_values_list[2]
    elif postoje_czas_list[i] < 13200:
        color = color_values_list[3]
    elif postoje_czas_list[i] < 16500:
        color = color_values_list[4]
    elif postoje_czas_list[i] < 19800:
        color = color_values_list[5]
    elif postoje_czas_list[i] < 23100:
        color = color_values_list[6]
    elif postoje_czas_list[i] < 26400:
        color = color_values_list[7]
    elif postoje_czas_list[i] < 29700:

```

```

    color = color_values_list[8]
elif postoje_czas_list[i] < 33000:
    color = color_values_list[9]
elif postoje_czas_list[i] < 36300:
    color = color_values_list[10]
elif postoje_czas_list[i] < 39600:
    color = color_values_list[11]
elif postoje_czas_list[i] < 42900:
    color = color_values_list[12]
elif postoje_czas_list[i] < 46200:
    color = color_values_list[13]
elif postoje_czas_list[i] < 49500:
    color = color_values_list[14]
elif postoje_czas_list[i] < 52800:
    color = color_values_list[15]
elif postoje_czas_list[i] < 56100:
    color = color_values_list[16]
elif postoje_czas_list[i] < 59400:
    color = color_values_list[17]
else:
    color = color_values_list[18]

return color

```

In []:

```

lower_left = [y_max, x_min]
upper_right = [y_min, x_max]
mm = folium.Map(tiles="Stamen Toner", zoom_start = 12, location=[50.055, 19.97])
grid = get_geojson_grid(upper_right, lower_left , n=60, m=100)

```

```

for i, geo_json in enumerate(grid):

```

```

    color = color_value_czas(i)
    color = mpl.colors.to_hex(color)

```

```

    gj = folium.GeoJson(geo_json,
                        style_function=lambda feature, color=color: {
                            'fillColor': color,
                            'color':"grey",
                            'weight': 0.3,
                            'fillOpacity': 0.7,
                        })

```

```

    popup = folium.Popup("example popup {}".format(i))
    gj.add_child(popup)

```

```

    mm.add_child(gj)

```

```

mm

```

In []:

```

mm.save('postoje_czas.html')

```

In []:

```

postoje_final = pd.read_csv('postoje_5.csv')
print(postoje_final)

```

In []:

```

postoje_final.describe()

```

Skrypt #3

Import bibliotek

```
import pandas as pd
import csv
import math
import numpy as np
from decimal import *
import seaborn as sb
import matplotlib as mpl
import matplotlib.pyplot as plt
from matplotlib.colors import LinearSegmentedColormap
import folium
```

In []:

Wyznaczenie siatki dla zasięgu Krakowa

```
#zasięg Krakowa

x_min = 19.789
x_max = 20.219
y_min = 49.962
y_max = 50.130

x_interval = round((x_max - x_min) / 100, 4)
y_interval = round((y_max - y_min) / 60, 4)

print(x_interval)
print(y_interval)
```

In []:

```
#wyznaczenie siatki
Lon = np.arange(x_min, x_max, x_interval)
Lat = np.arange(y_max, y_min, -y_interval)
```

In []:

```
Lon_labels = []

for i in range(1, len(Lon)):
    if i % 20 == 0:
        Lon_labels.append("{:.3f}".format(Lon[i]))
    else:
        Lon_labels.append('')
```

In []:

```
Lat_labels = []

for i in range(1, len(Lat)):
    if i % 20 == 0:
        Lat_labels.append("{:.3f}".format(Lat[i]))
    else:
        Lat_labels.append('')
```

In []:

Zabytki

01 architektoniczno-budowlane

```
zabytki_arch_bud = pd.read_csv('zabytki/01_zabytki_arch_simpl_centroids.csv')
print(zabytki_arch_bud)
```

In []:

```
zabytki_arch_bud_counts = np.zeros((60,100))
```

In []:

```
for a in range(len(zabytki_arch_bud)):
    for b1 in range(60):
```

In []:

```

    if Lat[b1] >= zabytki_arch_bud['ycoord'].values[a] > Lat[b1] - y_interval:
        for b2 in range(100):
            if Lon[b2] <= zabytki_arch_bud['xcoord'].values[a] < Lon[b2] + x_interval:
                zabytki_arch_bud_counts[b1, b2] += 1

sum(sum(zabytki_arch_bud_counts))

plt.subplots(figsize=(22,10))
plt.xticks(fontsize=20)
plt.yticks(fontsize=20)
sb.set(font_scale=2)
myColors = ((0.99, 0.99, 0.99, 0.99), (0.8, 0.0, 0.0, 1.0))
cmap = LinearSegmentedColormap.from_list('Custom', myColors, 22)
value_heatmap = sb.heatmap(zabytki_arch_bud_counts, xticklabels = Lon_labels, yticklabels = Lat_labels, c
value_heatmap.set_yticklabels(value_heatmap.get_yticklabels(), rotation = 0)
value_heatmap.hlines([20, 40], *value_heatmap.get_xlim(), color = 'grey')
value_heatmap.vlines([20, 40, 60, 80], *value_heatmap.get_ylim(), color = 'grey')

plt.savefig('z1.jpg', bbox_inches='tight', dpi = 150)

df_zabytki_arch_bud_counts = pd.DataFrame(zabytki_arch_bud_counts)
df_zabytki_arch_bud_counts.to_csv('zabytki/01_zabytki_arch_simpl_grid.csv', index=False)

zmienna dychotomiczna

np.max(zabytki_arch_bud_counts)

zabytki_arch_bud_no_zero = []

for b1 in range(60):
    for b2 in range(100):
        if zabytki_arch_bud_counts[b1,b2] > 0:
            zabytki_arch_bud_no_zero.append(zabytki_arch_bud_counts[b1,b2])

sum(zabytki_arch_bud_no_zero)

#percentyl 95%
q95 = np.percentile(zabytki_arch_bud_no_zero, 95)
q95

zabytki_arch_bud_counts_0_1_q95 = np.zeros((60,100))

for b1 in range(60):
    for b2 in range(100):
        if zabytki_arch_bud_counts[b1,b2] >= q95:
            zabytki_arch_bud_counts_0_1_q95[b1,b2] = 1
        else:
            zabytki_arch_bud_counts_0_1_q95[b1,b2] = 0

sum(sum(zabytki_arch_bud_counts_0_1_q95))

plt.subplots(figsize=(22,10))
plt.xticks(fontsize=20)
plt.yticks(fontsize=20)
sb.set(font_scale=2)
myColors = ((0.99, 0.99, 0.99, 0.99), (0.8, 0.0, 0.0, 1.0))
cmap = LinearSegmentedColormap.from_list('Custom', myColors, len(myColors))
value_heatmap = sb.heatmap(zabytki_arch_bud_counts_0_1_q95, xticklabels = Lon_labels,
yticklabels = Lat_labels, cmap = cmap, cbar=True)
value_heatmap.set_yticklabels(value_heatmap.get_yticklabels(), rotation = 0)
colorbar = value_heatmap.collections[0].colorbar
colorbar.set_ticks([0.25, 0.75])
colorbar.set_ticklabels(['0 (nie)', '1 (tak)'])
value_heatmap.hlines([20, 40], *value_heatmap.get_xlim(), color = 'grey')
value_heatmap.vlines([20, 40, 60, 80], *value_heatmap.get_ylim(), color = 'grey')

plt.savefig('z1a_95.jpg', bbox_inches='tight', dpi = 150)

df_zabytki_arch_bud_counts_0_1_q95 = pd.DataFrame(zabytki_arch_bud_counts_0_1_q95)

```

```

df_zabytki_arch_bud_counts_0_1_q95.to_csv('zabytki/01_zabytki_arch_simpl_0_1_q95_grid.csv', index=False)
In []:

#percentyl 90%
q90 = np.percentile(zabytki_arch_bud_no_zero, 90)
q90

zabytki_arch_bud_counts_0_1_q90 = np.zeros((60,100))
In []:

for b1 in range(60):
    for b2 in range(100):
        if zabytki_arch_bud_counts[b1,b2] >= q90:
            zabytki_arch_bud_counts_0_1_q90[b1,b2] = 1
        else:
            zabytki_arch_bud_counts_0_1_q90[b1,b2] = 0
In []:

sum(sum(zabytki_arch_bud_counts_0_1_q90))
In []:

plt.subplots(figsize=(22,10))
plt.xticks(fontsize=20)
plt.yticks(fontsize=20)
sb.set(font_scale=2)
myColors = ((0.99, 0.99, 0.99, 0.99), (0.8, 0.0, 0.0, 1.0))
cmap = LinearSegmentedColormap.from_list('Custom', myColors, len(myColors))
value_heatmap = sb.heatmap(zabytki_arch_bud_counts_0_1_q90, xticklabels = Lon_labels,
                           yticklabels = Lat_labels, cmap = cmap, cbar=True)
value_heatmap.set_yticklabels(value_heatmap.get_yticklabels(), rotation = 0)
colorbar = value_heatmap.collections[0].colorbar
colorbar.set_ticks([0.25, 0.75])
colorbar.set_ticklabels(['0 (nie)', '1 (tak)'])
value_heatmap.hlines([20, 40], *value_heatmap.get_xlim(), color = 'grey')
value_heatmap.vlines([20, 40, 60, 80], *value_heatmap.get_ylim(), color = 'grey')

plt.savefig('z1a_90.jpg', bbox_inches='tight', dpi = 150)

```

02 obiekty techniki

```

zabytki_urz_techniki = pd.read_csv('zabytki/02_zabytki_urz_techniki_simp_points.csv')
print(zabytki_urz_techniki)
In []:

zabytki_urz_techniki_counts = np.zeros((60,100))
In []:

for b1 in range(60):
    for b2 in range(100):
        for a in range(len(zabytki_urz_techniki)):
            if Lat[b1] >= zabytki_urz_techniki['ycoord'].values[a] > Lat[b1] - y_interval:
                if Lon[b2] <= zabytki_urz_techniki['xcoord'].values[a] < Lon[b2] + x_interval:
                    zabytki_urz_techniki_counts[b1, b2] += 1
                    break

sum(sum(zabytki_urz_techniki_counts))
In []:

plt.subplots(figsize=(22,10))
plt.xticks(fontsize=20)
plt.yticks(fontsize=20)
sb.set(font_scale=2)
myColors = ((0.99, 0.99, 0.99, 0.99), (0.8, 0.0, 0.0, 1.0))
cmap = LinearSegmentedColormap.from_list('Custom', myColors, len(myColors))
value_heatmap = sb.heatmap(zabytki_urz_techniki_counts, xticklabels = Lon_labels,
                           yticklabels = Lat_labels, cmap = cmap, cbar=True)
value_heatmap.set_yticklabels(value_heatmap.get_yticklabels(), rotation = 0)
colorbar = value_heatmap.collections[0].colorbar
colorbar.set_ticks([0.25, 0.75])
colorbar.set_ticklabels(['0 (nie)', '1 (tak)'])
value_heatmap.hlines([20, 40], *value_heatmap.get_xlim(), color = 'grey')
value_heatmap.vlines([20, 40, 60, 80], *value_heatmap.get_ylim(), color = 'grey')

plt.savefig('z2.jpg', bbox_inches='tight', dpi = 150)
In []:

df_zabytki_urz_techniki_counts = pd.DataFrame(zabytki_urz_techniki_counts)

```

```
df_zabytki_urz_techniki_counts.to_csv('zabytki/02_zabytki_urz_techniki_simp_grid.csv', index=False)
```

03 zieleń i obszary

```
In []:
zabytki_zielen_obszary = pd.read_csv('zabytki/03_zabytki_zielen_obszary_simpl_points.csv')
print(zabytki_zielen_obszary)

In []:
zabytki_zielen_obszary_counts = np.zeros((60,100))

In []:
for b1 in range(60):
    for b2 in range(100):
        for a in range(len(zabytki_zielen_obszary)):
            if Lat[b1] >= zabytki_zielen_obszary['ycoord'].values[a] > Lat[b1] - y_interval:
                if Lon[b2] <= zabytki_zielen_obszary['xcoord'].values[a] < Lon[b2] + x_interval:
                    zabytki_zielen_obszary_counts[b1, b2] += 1
                    break

sum(sum(zabytki_zielen_obszary_counts))

In []:
plt.subplots(figsize=(22,10))
plt.xticks(fontsize=20)
plt.yticks(fontsize=20)
sb.set(font_scale=2)
myColors = ((0.99, 0.99, 0.99, 0.99), (0.8, 0.0, 0.0, 1.0))
cmap = LinearSegmentedColormap.from_list('Custom', myColors, len(myColors))
value_heatmap = sb.heatmap(zabytki_zielen_obszary_counts, xticklabels = Lon_labels,
                           yticklabels = Lat_labels, cmap = cmap, cbar=True)
value_heatmap.set_yticklabels(value_heatmap.get_yticklabels(), rotation = 0)
colorbar = value_heatmap.collections[0].colorbar
colorbar.set_ticks([0.25, 0.75])
colorbar.set_ticklabels(['0 (nie)', '1 (tak)'])
value_heatmap.hlines([20, 40], *value_heatmap.get_xlim(), color = 'grey')
value_heatmap.vlines([20, 40, 60, 80], *value_heatmap.get_ylim(), color = 'grey')

plt.savefig('z3.jpg', bbox_inches='tight', dpi = 150)

In []:
df_zabytki_zielen_obszary_counts = pd.DataFrame(zabytki_zielen_obszary_counts)
df_zabytki_zielen_obszary_counts.to_csv('zabytki/03_zabytki_zielen_obszary_simpl_grid.csv', index=False)
```

04 obszary urbanistyczne

```
In []:
zabytki_obszary_urb = pd.read_csv('zabytki/04_zabytki_obszary_urb_simpl_points.csv')
print(zabytki_obszary_urb)

In []:
zabytki_obszary_urb_counts = np.zeros((60,100))

In []:
for b1 in range(60):
    for b2 in range(100):
        for a in range(len(zabytki_obszary_urb)):
            if Lat[b1] >= zabytki_obszary_urb['ycoord'].values[a] > Lat[b1] - y_interval:
                if Lon[b2] <= zabytki_obszary_urb['xcoord'].values[a] < Lon[b2] + x_interval:
                    zabytki_obszary_urb_counts[b1, b2] += 1
                    break

sum(sum(zabytki_obszary_urb_counts))

In []:
plt.subplots(figsize=(22,10))
plt.xticks(fontsize=20)
plt.yticks(fontsize=20)
sb.set(font_scale=2)
myColors = ((0.99, 0.99, 0.99, 0.99), (0.8, 0.0, 0.0, 1.0))
cmap = LinearSegmentedColormap.from_list('Custom', myColors, len(myColors))
value_heatmap = sb.heatmap(zabytki_obszary_urb_counts, xticklabels = Lon_labels,
                           yticklabels = Lat_labels, cmap = cmap, cbar=True)
value_heatmap.set_yticklabels(value_heatmap.get_yticklabels(), rotation = 0)
colorbar = value_heatmap.collections[0].colorbar
colorbar.set_ticks([0.25, 0.75])
colorbar.set_ticklabels(['0 (nie)', '1 (tak)'])
```

```
value_heatmap.hlines([20, 40], *value_heatmap.get_xlim(), color = 'grey')
value_heatmap.vlines([20, 40, 60, 80], *value_heatmap.get_ylim(), color = 'grey')

plt.savefig('z4.jpg', bbox_inches='tight', dpi = 150)
```

In []:

```
df_zabytki_obszary_urb_counts = pd.DataFrame(zabytki_obszary_urb_counts)
df_zabytki_obszary_urb_counts.to_csv('zabytki/04_zabytki_obszary_urb_simpl_grid.csv', index=False)
```

Przyroda

01 Parki

In []:

```
przyroda_parki = pd.read_csv('parki/01_przyroda_parki_simpl_points.csv')
print(przyroda_parki)
```

In []:

```
przyroda_parki_counts = np.zeros((60,100))
```

In []:

```
for b1 in range(60):
    for b2 in range(100):
        for a in range(len(przyroda_parki)):
            if Lat[b1] >= przyroda_parki['ycoord'].values[a] > Lat[b1] - y_interval:
                if Lon[b2] <= przyroda_parki['xcoord'].values[a] < Lon[b2] + x_interval:
                    przyroda_parki_counts[b1, b2] += 1
                    break
```

```
sum(sum(przyroda_parki_counts))
```

In []:

```
plt.subplots(figsize=(22,10))
plt.xticks(fontsize=20)
plt.yticks(fontsize=20)
sb.set(font_scale=2)
myColors = ((0.99, 0.99, 0.99, 0.99), (0.2, 0.8, 0.3, 1.0))
cmap = LinearSegmentedColormap.from_list('Custom', myColors, len(myColors))
value_heatmap = sb.heatmap(przyroda_parki_counts, xticklabels = Lon_labels,
                           yticklabels = Lat_labels, cmap = cmap, cbar=True)
value_heatmap.set_yticklabels(value_heatmap.get_yticklabels(), rotation = 0)
colorbar = value_heatmap.collections[0].colorbar
colorbar.set_ticks([0.25, 0.75])
colorbar.set_ticklabels(['0 (nie)', '1 (tak)'])
value_heatmap.hlines([20, 40], *value_heatmap.get_xlim(), color = 'grey')
value_heatmap.vlines([20, 40, 60, 80], *value_heatmap.get_ylim(), color = 'grey')

plt.savefig('p1.jpg', bbox_inches='tight', dpi = 150)
```

In []:

```
df_przyroda_parki_counts = pd.DataFrame(przyroda_parki_counts)
df_przyroda_parki_counts.to_csv('parki/01_przyroda_parki_simpl_grid.csv', index=False)
```

02 Parki leśne

In []:

```
przyroda_parki_lesne = pd.read_csv('parki/02_przyroda_parki_lesne_simpl_points.csv')
print(przyroda_parki_lesne)
```

In []:

```
przyroda_parki_lesne_counts = np.zeros((60,100))
```

In []:

```
for b1 in range(60):
    for b2 in range(100):
        for a in range(len(przyroda_parki_lesne)):
            if Lat[b1] >= przyroda_parki_lesne['ycoord'].values[a] > Lat[b1] - y_interval:
                if Lon[b2] <= przyroda_parki_lesne['xcoord'].values[a] < Lon[b2] + x_interval:
                    przyroda_parki_lesne_counts[b1, b2] += 1
                    break
```

```
sum(sum(przyroda_parki_lesne_counts))
```

In []:

```
plt.subplots(figsize=(22,10))
plt.xticks(fontsize=20)
```



```

plt.yticks(fontsize=20)
sb.set(font_scale=2)
myColors = ((0.99, 0.99, 0.99, 0.99), (0.2, 0.8, 0.3, 1.0))
cmap = LinearSegmentedColormap.from_list('Custom', myColors, len(myColors))
value_heatmap = sb.heatmap(przyroda_parki_lesne_counts, xticklabels = Lon_labels,
                           yticklabels = Lat_labels, cmap = cmap, cbar=True)
value_heatmap.set_yticklabels(value_heatmap.get_yticklabels(), rotation = 0)
colorbar = value_heatmap.collections[0].colorbar
colorbar.set_ticks([0.25, 0.75])
colorbar.set_ticklabels(['0 (nie)', '1 (tak)'])
value_heatmap.hlines([20, 40], *value_heatmap.get_xlim(), color = 'grey')
value_heatmap.vlines([20, 40, 60, 80], *value_heatmap.get_ylim(), color = 'grey')

plt.savefig('p2.jpg', bbox_inches='tight', dpi = 150)

```

In []:

```

df_przyroda_parki_lesne_counts = pd.DataFrame(przyroda_parki_lesne_counts)
df_przyroda_parki_lesne_counts.to_csv('parki/02_przyroda_parki_lesne_simpl_grid.csv', index=False)

```

03 Cieki wodne

In []:

```

przyroda_cieki = pd.read_csv('parki/03_przyroda_cieki_wodne_1_2_klasa_points.csv')
print(przyroda_cieki)

```

In []:

```

przyroda_cieki_counts = np.zeros((60,100))

```

In []:

```

for b1 in range(60):
    for b2 in range(100):
        for a in range(len(przyroda_cieki)):
            if Lat[b1] >= przyroda_cieki['ycoord'].values[a] > Lat[b1] - y_interval:
                if Lon[b2] <= przyroda_cieki['xcoord'].values[a] < Lon[b2] + x_interval:
                    przyroda_cieki_counts[b1, b2] += 1
                    break

```

```

sum(sum(przyroda_cieki_counts))

```

In []:

```

plt.subplots(figsize=(22,10))
plt.xticks(fontsize=20)
plt.yticks(fontsize=20)
sb.set(font_scale=2)
myColors = ((0.99, 0.99, 0.99, 0.99), (0.1, 0.2, 0.8, 1.0))
cmap = LinearSegmentedColormap.from_list('Custom', myColors, len(myColors))
value_heatmap = sb.heatmap(przyroda_cieki_counts, xticklabels = Lon_labels,
                           yticklabels = Lat_labels, cmap = cmap, cbar=True)
value_heatmap.set_yticklabels(value_heatmap.get_yticklabels(), rotation = 0)
colorbar = value_heatmap.collections[0].colorbar
colorbar.set_ticks([0.25, 0.75])
colorbar.set_ticklabels(['0 (nie)', '1 (tak)'])
value_heatmap.hlines([20, 40], *value_heatmap.get_xlim(), color = 'grey')
value_heatmap.vlines([20, 40, 60, 80], *value_heatmap.get_ylim(), color = 'grey')

plt.savefig('p3.jpg', bbox_inches='tight', dpi = 150)

```

In []:

```

df_przyroda_cieki_counts = pd.DataFrame(przyroda_cieki_counts)
df_przyroda_cieki_counts.to_csv('parki/03_przyroda_cieki_wodne_1_2_klasa_grid.csv', index=False)

```

04 Zbiorniki wodne

In []:

```

przyroda_zbiorniki = pd.read_csv('parki/04_przyroda_zbiorniki_wodne_points.csv')
print(przyroda_zbiorniki)

```

In []:

```

przyroda_zbiorniki_counts = np.zeros((60,100))

```

In []:

```

for b1 in range(60):
    for b2 in range(100):
        for a in range(len(przyroda_zbiorniki)):
            if Lat[b1] >= przyroda_zbiorniki['ycoord'].values[a] > Lat[b1] - y_interval:
                if Lon[b2] <= przyroda_zbiorniki['xcoord'].values[a] < Lon[b2] + x_interval:
                    przyroda_zbiorniki_counts[b1, b2] += 1

```

```
break
```

```
sum(sum(przyroda_zbiorniki_counts))
```

In []:

```
plt.subplots(figsize=(22,10))
plt.xticks(fontsize=20)
plt.yticks(fontsize=20)
sb.set(font_scale=2)
myColors = ((0.99, 0.99, 0.99, 0.99), (0.1, 0.2, 0.8, 1.0))
cmap = LinearSegmentedColormap.from_list('Custom', myColors, len(myColors))
value_heatmap = sb.heatmap(przyroda_zbiorniki_counts, xticklabels = Lon_labels,
                           yticklabels = Lat_labels, cmap = cmap, cbar=True)
value_heatmap.set_yticklabels(value_heatmap.get_yticklabels(), rotation = 0)
colorbar = value_heatmap.collections[0].colorbar
colorbar.set_ticks([0.25, 0.75])
colorbar.set_ticklabels(['0 (nie)', '1 (tak)'])
value_heatmap.hlines([20, 40], *value_heatmap.get_xlim(), color = 'grey')
value_heatmap.vlines([20, 40, 60, 80], *value_heatmap.get_ylim(), color = 'grey')

plt.savefig('p4.jpg', bbox_inches='tight', dpi = 150)
```

In []:

```
df_przyroda_zbiorniki_counts = pd.DataFrame(przyroda_zbiorniki_counts)
df_przyroda_zbiorniki_counts.to_csv('parki/04_przyroda_zbiorniki_wodne_grid.csv', index=False)
```

Korelacja zmiennych

In []:

```
z1 = []

for b1 in range(60):
    for b2 in range(100):
        z1.append(zabytki_arch_bud_counts[b1, b2])
```

```
z1a = np.array(z1).reshape((-1, 1))
```

```
len(z1a)
```

In []:

```
z2 = []

for b1 in range(60):
    for b2 in range(100):
        z2.append(zabytki_urz_techniki_counts[b1, b2])
```

```
z2a = np.array(z2).reshape((-1, 1))
```

```
len(z2a)
```

In []:

```
z3 = []

for b1 in range(60):
    for b2 in range(100):
        z3.append(zabytki_zielen_obszary_counts[b1, b2])
```

```
z3a = np.array(z3).reshape((-1, 1))
```

```
len(z3a)
```

In []:

```
z4 = []

for b1 in range(60):
    for b2 in range(100):
        z4.append(zabytki_obszary_urb_counts[b1, b2])
```

```
z4a = np.array(z4).reshape((-1, 1))
```

```
len(z4a)
```

In []:

```
p1 = []

for b1 in range(60):
    for b2 in range(100):
```

```

        p1.append(przyroda_parki_counts[b1, b2])

p1a = np.array(p1).reshape((-1, 1))

len(p1a)

p2 = []

for b1 in range(60):
    for b2 in range(100):
        p2.append(przyroda_parki_lesne_counts[b1, b2])

p2a = np.array(p2).reshape((-1, 1))

len(p2a)

p3 = []

for b1 in range(60):
    for b2 in range(100):
        p3.append(przyroda_cieki_counts[b1, b2])

p3a = np.array(p3).reshape((-1, 1))

len(p3a)

p4 = []

for b1 in range(60):
    for b2 in range(100):
        p4.append(przyroda_zbiorniki_counts[b1, b2])

p4a = np.array(p4).reshape((-1, 1))

len(p4a)

zmienne = np.concatenate((z1a, z2a, z3a, z4a, p1a, p2a, p3a, p4a), axis=1)

zmienne_df = pd.DataFrame(zmienne, columns = ['z1', 'z2', 'z3', 'z4', 'p1', 'p2', 'p3', 'p4'])
zmienne_df

corrMatrix = zmienne_df.corr()
corrMatrix

plt.figure(figsize=(16,5))
plt.xticks(fontsize=14)
plt.yticks(fontsize=14)
myColors = ((0.99, 0.99, 0.99, 0.99), (0.95, 0.8, 0.0, 0.95))
cmap = LinearSegmentedColormap.from_list('Custom', myColors, 110)
s = sb.heatmap(corrMatrix, annot=True, annot_kws={'size':16}, cmap=cmap)
colorbar = s.collections[0].colorbar
colorbar.set_ticks([0.1, 0.3, 0.55, 0.8, 0.95])
colorbar.set_ticklabels(['[0,0; 0,2] - brak zaleznosci', '(0,2; 0,4] - slaba zaleznosc', '(0,4; 0,7] - s
plt.savefig('macierz_korelacji.jpg', bbox_inches='tight', dpi = 150)
plt.show()

```

Waloryzacja otoczenia

```

zp_counts = np.zeros((60,100)) #z1-3 + p1-4

for b1 in range(60):
    for b2 in range(100):
        zp_counts[b1,b2] = zabytki_arch_bud_counts_0_1_q95[b1,b2] + zabytki_urz_techniki_counts[b1,b2] +
sum(sum(zp_counts))

licznik = [0, 0, 0, 0, 0]

```

```

for b1 in range(60):
    for b2 in range(100):
        if zp_counts[b1,b2] == 0:
            licznik[0] += 1
        elif zp_counts[b1,b2] == 1:
            licznik[1] += 1
        elif zp_counts[b1,b2] == 2:
            licznik[2] += 1
        elif zp_counts[b1,b2] == 3:
            licznik[3] += 1
        else:
            licznik[4] += 1

print(licznik)

```

In []:

```

plt.subplots(figsize=(20,10))
plt.xticks(fontsize=20)
plt.yticks(fontsize=20)
sb.set(font_scale=2)
myColors = ((0.99, 0.99, 0.99, 0.99), (0.95, 0.8, 0.0, 0.95))
cmap = LinearSegmentedColormap.from_list('Custom', myColors, 5)
value_heatmap = sb.heatmap(zp_counts, xticklabels = Lon_labels,
                           yticklabels = Lat_labels, cmap = cmap, cbar=True)
value_heatmap.set_yticklabels(value_heatmap.get_yticklabels(), rotation = 0)
colorbar = value_heatmap.collections[0].colorbar
colorbar.set_ticks([0.4, 1.2, 2, 2.8, 3.6])
colorbar.set_ticklabels(['0 - otoczenie nieatrakcyjne', '1 - otoczenie słabo atrakcyjne', '2 - otoczenie
value_heatmap.hlines([20, 40], *value_heatmap.get_xlim(), color = 'grey')
value_heatmap.vlines([20, 40, 60, 80], *value_heatmap.get_ylim(), color = 'grey')

plt.savefig('waloryzacja.jpg', bbox_inches='tight', dpi = 150)

```

In []:

```

df_zp_counts = pd.DataFrame(zp_counts)
df_zp_counts.to_csv('waloryzacja/waloryzacja.csv', index=False)

```

In []:

```

zp_counts_90 = np.zeros((60,100)) #z1-3 + p1-4

```

In []:

```

for b1 in range(60):
    for b2 in range(100):
        zp_counts_90[b1,b2] = zabytki_arch_bud_counts_0_1_q90[b1,b2] + zabytki_urz_techniki_counts[b1,b2]

sum(sum(zp_counts_90))

```

In []:

```

plt.subplots(figsize=(20,10))
plt.xticks(fontsize=20)
plt.yticks(fontsize=20)
sb.set(font_scale=2)
myColors = ((0.99, 0.99, 0.99, 0.99), (0.95, 0.8, 0.0, 0.95))
cmap = LinearSegmentedColormap.from_list('Custom', myColors, 6)
value_heatmap = sb.heatmap(zp_counts_90, xticklabels = Lon_labels,
                           yticklabels = Lat_labels, cmap = cmap, cbar=True)
value_heatmap.set_yticklabels(value_heatmap.get_yticklabels(), rotation = 0)
colorbar = value_heatmap.collections[0].colorbar
colorbar.set_ticks([0.415, 1.245, 2.075, 2.905, 3.735, 4.565])
colorbar.set_ticklabels(['0 - otoczenie nieatrakcyjne', '1 - otoczenie słabo atrakcyjne', '2 - otoczenie
value_heatmap.hlines([20, 40], *value_heatmap.get_xlim(), color = 'grey')
value_heatmap.vlines([20, 40, 60, 80], *value_heatmap.get_ylim(), color = 'grey')

plt.savefig('waloryzacja_90.jpg', bbox_inches='tight', dpi = 150)

```

In []:

```

df_zp_counts_90 = pd.DataFrame(zp_counts_90)
df_zp_counts_90.to_csv('waloryzacja/waloryzacja_90.csv', index=False)

```

Mapa folium

```

def get_geojson_grid(upper_right, lower_left, n=6, m=6):
    """Returns a grid of geojson rectangles, and computes the exposure in each section of the grid based

```

In []:

Parameters

```

upper_right: array_like
    The upper right hand corner of "grid of grids" (the default is the upper right hand [lat, lon] o:

lower_left: array_like
    The lower left hand corner of "grid of grids" (the default is the lower left hand [lat, lon] of

n: integer
    The number of rows/columns in the (n,n) grid.

```

```

Returns
-----

```

```

list
    List of "geojson style" dictionary objects
"""

```

```

all_boxes = []

lat_steps = np.linspace(lower_left[0], upper_right[0], n+1)
lon_steps = np.linspace(lower_left[1], upper_right[1], m+1)

lat_stride = lat_steps[1] - lat_steps[0]
lon_stride = lon_steps[1] - lon_steps[0]

for lat in lat_steps[:-1]:
    for lon in lon_steps[:-1]:
        # Define dimensions of box in grid
        upper_left = [lon, lat + lat_stride]
        upper_right = [lon + lon_stride, lat + lat_stride]
        lower_right = [lon + lon_stride, lat]
        lower_left = [lon, lat]

        # Define json coordinates for polygon
        coordinates = [
            upper_left,
            upper_right,
            lower_right,
            lower_left,
            upper_left
        ]

        geo_json = {"type": "FeatureCollection",
                    "properties":{
                        "lower_left": lower_left,
                        "upper_right": upper_right
                    },
                    "features":[]}

        grid_feature = {
            "type":"Feature",
            "geometry":{
                "type":"Polygon",
                "coordinates": [coordinates],
            }
        }

        geo_json["features"].append(grid_feature)

        all_boxes.append(geo_json)

return all_boxes

```

In []:

```

zp_counts_list = []

```

```

for i in range(60):
    for j in range(100):
        zp_counts_list.append(zp_counts[i][j])

```

```

len(zp_counts_list)

```

In []:

```

myColors = ((0.99, 0.99, 0.99, 0.99), (0.95, 0.8, 0.0, 0.95))
cmap = LinearSegmentedColormap.from_list('Custom', myColors, 5)

```

```

color_values = cmap(range(5))

```

In []:

```
color_values_list = color_values.tolist()
```

In []:

```
def color_value(i):  
  
    if zp_counts_list[i] == 0:  
        color = color_values_list[0]  
    elif zp_counts_list[i] == 1:  
        color = color_values_list[1]  
    elif zp_counts_list[i] == 2:  
        color = color_values_list[2]  
    elif zp_counts_list[i] == 3:  
        color = color_values_list[3]  
    else:  
        color = color_values_list[4]  
  
    return color
```

In []:

```
lower_left = [y_max, x_min]  
upper_right = [y_min, x_max]  
m = folium.Map(tiles="Stamen Toner", zoom_start = 12, location=[50.055, 19.97])  
grid = get_geojson_grid(upper_right, lower_left, n=60, m=100)
```

```
for i, geo_json in enumerate(grid):  
  
    color = color_value(i)  
    color = mpl.colors.to_hex(color)  
  
    gj = folium.GeoJson(geo_json,  
                       style_function=lambda feature, color=color: {  
                           'fillColor': color,  
                           'color': "grey",  
                           'weight': 0.3,  
                           'fillOpacity': 0.7,  
                           })  
  
    popup = folium.Popup("example popup {}".format(i))  
    gj.add_child(popup)  
  
    m.add_child(gj)
```

m

In []:

```
m.save('waloryzacja/waloryzacja.html')
```

In []:

```
zp_counts_90_list = []  
  
for i in range(60):  
    for j in range(100):  
        zp_counts_90_list.append(zp_counts_90[i][j])  
  
len(zp_counts_90_list)
```

In []:

```
myColors_90 = ((0.99, 0.99, 0.99, 0.99), (0.95, 0.8, 0.0, 0.95))  
cmap_90 = LinearSegmentedColormap.from_list('Custom', myColors_90, 6)
```

```
color_values_90 = cmap_90(range(6))
```

In []:

```
color_values_90_list = color_values_90.tolist()
```

In []:

```
def color_value_90(i):  
  
    if zp_counts_90_list[i] == 0:  
        color = color_values_90_list[0]  
    elif zp_counts_90_list[i] == 1:  
        color = color_values_90_list[1]  
    elif zp_counts_90_list[i] == 2:  
        color = color_values_90_list[2]  
    elif zp_counts_90_list[i] == 3:  
        color = color_values_90_list[3]  
    elif zp_counts_90_list[i] == 4:  
        color = color_values_90_list[4]  
    else:  
        color = color_values_90_list[5]
```

```

    return color

lower_left = [y_max, x_min]
upper_right = [y_min, x_max]
m_90 = folium.Map(tiles="Stamen Toner", zoom_start = 12, location=[50.055, 19.97])
grid = get_geojson_grid(upper_right, lower_left , n=60, m=100)

for i, geo_json in enumerate(grid):

    color = color_value_90(i)
    color = mpl.colors.to_hex(color)

    gj = folium.GeoJson(geo_json,
                        style_function=lambda feature, color=color: {
                            'fillColor': color,
                            'color':"grey",
                            'weight': 0.3,
                            'fillOpacity': 0.7,
                        })

    popup = folium.Popup("example popup {}".format(i))
    gj.add_child(popup)

    m_90.add_child(gj)
m_90

m_90.save('waloryzacja/waloryzacja_90.html')

```

In []:

In []:

Skrypt #4

Import bibliotek

In []:

```
import math
import xml.etree.ElementTree as ET
from datetime import datetime, timedelta
import numpy as np
import pandas as pd
import seaborn as sb
from scipy import stats
import scipy.stats
import csv
from pandas import DataFrame
from decimal import *
import random
from sklearn import metrics
from sklearn import *
import matplotlib.pyplot as plt
from sklearn.linear_model import LinearRegression
from sklearn.preprocessing import PolynomialFeatures
from sklearn.linear_model import LogisticRegression
from matplotlib.colors import LinearSegmentedColormap
```

Zdefiniowanie klas

In []:

```
class TrackPoint:

    def __init__(self, time, lat, lon):
        self.time = time
        self.lat = lat # latitude
        self.lon = lon # longitude

class Track:

    def __init__(self):
        self.points = [] # track points
        self.all_segments = []

    def gps_distance(self, p1, p2):
        # Haversine Formula

        lat1, lon1 = p1.lat, p1.lon
        lat2, lon2 = p2.lat, p2.lon

        Earth_radius = 6371 # km
        dlat = math.radians(lat2 - lat1)
        dlon = math.radians(lon2 - lon1)
        a = (math.sin(0.5 * dlat) * math.sin(0.5 * dlat) +
             math.cos(math.radians(lat1)) * math.cos(math.radians(lat2)) *
             math.sin(0.5 * dlon) * math.sin(0.5 * dlon))

        d = 2 * Earth_radius * math.atan2(math.sqrt(a), math.sqrt(1 - a))

        return d

    @property
    def start_lat(self, p1): #punkt początkowy odcinka - latitude

        lat1 = p1.lat

        return lat1

    @property
    def start_lon(self, p1): #punkt początkowy odcinka - logtitude

        lon1 = p1.lon
```

```

    return lon1

@property
def size(self):
    return len(self.points)

@property
def is_epmty(self):
    return self.size == 0

@property
def has_bad_timing(self):
    _, _, dt, dd, dv = self.segments
    bad_timing = False
    for t in dt:
        if t > 5 * 60:
            # GPS tracker didn't respond for more than 5 minutes
            bad_timing = True
            break
    return bad_timing

@property
def has_small_distance(self):
    # total distance is less than 100 m
    return self.travel_distance < 0.1

@property
def origin(self):
    return None if self.is_epmty else self.points[0]

@property
def destination(self):
    return None if self.is_epmty else self.points[-1]

@property
def idle_time(self):
    t = 0.0
    if not self.is_epmty:
        _, _, ts, ds, _ = self.segments
        n = len(ts)
        if n > 0:
            for i in range(n):
                if ds[i] == 0:
                    t += ts[i]
    return t

@property
def idle_time_place(self):
    lat_place, lon_place, idle_place = [], [], []

    if not self.is_epmty:
        stlat, stlon, ts, ds, _ = self.segments
        n = len(ts)
        if n > 0:
            i = 0
            while i < n:

                if ds[i] == 0:
                    t = 0.0
                    t += ts[i]
                    lat = stlat[i]
                    lon = stlon[i]
                    i += 1

                if i == n:
                    break

                while ds[i] == 0:
                    t += ts[i]
                    i += 1

                if i == n:
                    break

            lat_place.append(lat)

```

```

        lon_place.append(lon)
        idle_place.append(t)

    else:
        i += 1

    return lat_place, lon_place, idle_place

@property
def lats_and_lons_of_points(self):
    lats_and_lots = []

    if not self.is_epmty:
        stlat, stlon, _, _, _ = self.segments

        for i in range(self.size - 1):

            lat = stlat[i]
            lon = stlon[i]

            lats_and_lots.append([lat, lon])

    return lats_and_lots

@property
def travel_time(self):
    return 0 if self.is_epmty else (self.destination.time - self.origin.time).seconds

@property
def travel_distance(self):
    td = 0.0
    if not self.is_epmty:
        _, _, _, dd, _ = self.segments
        td = sum(dd)
    return td

@property
def mean_speed(self):
    ms = 0.0
    if not self.is_epmty:
        _, _, vs = self.segments
        if len(vs) != 0:
            ms = 1.0 * sum(vs) / len(vs)
    return ms

@property
def aver_speed(self):
    return 0 if self.travel_time == 0 else 3600 * self.travel_distance / self.travel_time

@property
def irr_coef(self):
    return 0 if self.gps_distance(self.origin, self.destination) == 0 else 1.0 * self.travel_distance

@property
def segments(self):
    start_lat, start_lon, dt, dist, velocity = [], [], [], [], []
    if not self.is_epmty:
        for i in range(self.size - 1):
            start_lat.append(self.points[i].lat)
            start_lon.append(self.points[i].lon)
            dt.append((self.points[i + 1].time - self.points[i].time).seconds)
            dist.append(self.gps_distance(self.points[i], self.points[i + 1]))
            velocity.append(3600.0 * dist[-1] / dt[-1])
    return start_lat, start_lon, dt, dist, velocity

class GPX:

    def __init__(self, file_name):
        tree = ET.parse(file_name)
        self.tracks = self.get_tracks(tree)

    def get_tracks(self, tree):
        trks = []
        root = tree.getroot()
        for trk in root:

```

```

# print trk.tag, trk.attrib
for trkseg in trk:
    tr = Track()
    for trkpt in trkseg:
        tstr = trkpt[0].text # 2017-05-31T22:03:41Z
        year, month, day = tstr[:4], tstr[5:7], tstr[8:10]
        hour, minute, sec = tstr[11:13], tstr[14:16], tstr[17:19]
        time = datetime(int(year), int(month), int(day),
                        int(hour), int(minute), int(sec))
        if tr.is_epmty or time != tr.points[-1].time: # exclude repetitions
            tr.points.append(TrackPoint(time=time,
                                        lat=float(trkpt.attrib.get('lat')),
                                        lon=float(trkpt.attrib.get('lon'))))

    # print "Points in track:", len(tr.points)
    trks.append(tr)
return trks

```

Import oczyszczonych danych w formacie GPX

```

In []:
gpx_clean = GPX('C:/Users/Krystian/Dysk Google/_doktorat/09_obliczenia_final_scalone/00_dane/clean_trips_

```

Wyznaczenie siatki dla zasięgu Krakowa

```

In []:
#zasięg Krakowa

x_min = 19.789
x_max = 20.219
y_min = 49.962
y_max = 50.130

x_interval = round((x_max - x_min) / 100, 4)
y_interval = round((y_max - y_min) / 60, 4)

print(x_interval)
print(y_interval)

In []:
#make the grid
Lon = np.arange(x_min, x_max, x_interval)
Lat = np.arange(y_max, y_min, -y_interval)

In []:
Lon_labels = []

for i in range(1, len(Lon)):
    if i % 20 == 0:
        Lon_labels.append("{:.3f}".format(Lon[i]))
    else:
        Lon_labels.append('')

In []:
Lat_labels = []

for i in range(1, len(Lat)):
    if i % 20 == 0:
        Lat_labels.append("{:.3f}".format(Lat[i]))
    else:
        Lat_labels.append('')

In []:
#wczytanie gridu Krakowa
krakow = np.genfromtxt('dane/krakow_grid.csv', delimiter=',')

```

Wyznaczenie podróży wewnątrz granic Krakowa

```

In []:
tracks_clean = gpx_clean.tracks
len(tracks_clean)

In []:
tracks = []

```

```

for track in tracks_clean:
    tracks.append(track.lats_and_lons_of_points)

df_tracks = pd.DataFrame(tracks)
df_tracks.to_csv('tracks_clean.csv', index=False)

len(tracks)

#tylko podróże wewnątrz Krakowa

tracks_krakow = []
if_krakow = []

for a in range(len(tracks)):
    value_a = 0

    for punkt in range(len(tracks[a])):
        for b1 in range(60):
            if Lat[b1] >= tracks[a][punkt][0] > Lat[b1] - y_interval:
                for b2 in range(100):
                    if Lon[b2] <= tracks[a][punkt][1] < Lon[b2] + x_interval:
                        if krakow[b1,b2] == 1:
                            value_a = value_a + 1
                        else:
                            continue

    if value_a == len(tracks[a]):
        tracks_krakow.append(tracks[a])

    if value_a == len(tracks[a]):
        if_krakow.append(1)
    else:
        if_krakow.append(0)

df_tracks_krakow = pd.DataFrame(tracks_krakow)
df_tracks_krakow.to_csv('tracks_clean_in_krakow.csv', index=False)

print(len(tracks_krakow), len(if_krakow))

```

In []:

Przygotowanie ID rekordów zbioru treningowego i testowego

```

random_list = []

i = 0

for _ in range(len(tracks_krakow)):
    random_list.append(i)
    i = i + 1

len(random_list)

def unique(list1):

    unique_list = []

    for x in list1:
        if x not in unique_list:
            unique_list.append(x)

    print (len(unique_list))

train_elements = int(0.8 * len(random_list))

train_elements

#utworzenie listy ID rekordów zbioru treningowego

train_ids = random.sample(random_list, train_elements)
train_ids.sort()

```

In []:

In []:

In []:

In []:

In []:

```
unique(train_ids)
```

In []:

```
#utworzenie listy ID rekordów zbioru testowego
```

```
test_ids = []
```

```
for _ in random_list:  
    if _ not in train_ids:  
        test_ids.append(_)
```

```
len(test_ids)
```

Wyznaczenie parametrów podróży wewnątrz Krakowa

Czas podróży

In []:

```
time = []
```

```
for track in tracks_clean:  
    time.append(track.travel_time)
```

```
len(time)
```

In []:

```
time_krakow = []
```

```
for i in range(len(time)):  
    if if_krakow[i] == 1:  
        time_krakow.append(time[i] / 60)
```

```
len(time_krakow)
```

Długość podróży

In []:

```
distance = []
```

```
for track in tracks_clean:  
    distance.append(track.travel_distance)
```

```
len(distance)
```

In []:

```
distance_krakow = []
```

```
for i in range(len(distance)):  
    if if_krakow[i] == 1:  
        distance_krakow.append(distance[i])
```

```
len(distance_krakow)
```

Średnia prędkość

In []:

```
aver_speed = []
```

```
for track in tracks_clean:  
    aver_speed.append(track.aver_speed)
```

```
len(aver_speed)
```

In []:

```
aver_speed_krakow = []
```

```
for i in range(len(aver_speed)):  
    if if_krakow[i] == 1:  
        aver_speed_krakow.append(aver_speed[i])
```

```
len(aver_speed_krakow)
```

Współczynnik wydłużenia podróży

```
irr_coef = []

for track in tracks_clean:
    irr_coef.append(track.irr_coef)

len(irr_coef)

irr_coef_krakow = []

for i in range(len(irr_coef)):
    if if_krakow[i] == 1:
        irr_coef_krakow.append(irr_coef[i])

len(irr_coef_krakow)
```

Przypisanie trasie wartości z waloryzacji otoczenia trasy

```
classes = np.genfromtxt('dane/waloryzacja.csv', delimiter=',')

tracks_value = []

for track in tracks:

    points_value = [[], [], []]

    for point in range(len(track)):
        for b1 in range(60):
            if Lat[b1] >= track[point][0] > Lat[b1] - y_interval:
                for b2 in range(100):
                    if Lon[b2] <= track[point][1] < Lon[b2] + x_interval:

                        points_value[0].append(classes[b1, b2])
                        points_value[1].append(b1)
                        points_value[2].append(b2)

    for point in range(1, len(points_value[0])): #uniknięcie przypisania dwóm kolejnym punktom z tego san
        if points_value[1][point] == points_value[1][point - 1]:
            if points_value[2][point] == points_value[2][point - 1]:
                points_value[0][point] = 0
            else:
                continue

    tracks_value.append(sum(points_value[0]))

df_tracks_value = pd.DataFrame(tracks_value)
df_tracks_value.to_csv('waloryzacja_tras.csv', index=False)

len(tracks_value)

tracks_value_krakow = []

for i in range(len(tracks_value)):
    if if_krakow[i] == 1:
        tracks_value_krakow.append(tracks_value[i])

df_tracks_value_krakow = pd.DataFrame(tracks_value_krakow)
df_tracks_value_krakow.to_csv('waloryzacja_tras_krakow.csv', index=False)

len(tracks_value_krakow)

df_tracks_value_krakow.describe()

tracks_value_krakow_plot_ = []

for i in range(len(tracks_value_krakow)):
    tracks_value_krakow_plot_.append(tracks_value_krakow[i] + random.uniform(-0.4, 0.4))
```



```
tracks_value_krakow_plot = np.array(tracks_value_krakow_plot_)
```

Przypisanie najkrótszej trasie wartości z waloryzacji otoczenia trasy

In []:

```
tracks_krakow_lines_parameters = []

for track in range(len(tracks_krakow)):

    x_orig = tracks_krakow[track][0][1]
    y_orig = tracks_krakow[track][0][0]
    x_dest = tracks_krakow[track][-1][1]
    y_dest = tracks_krakow[track][-1][0]

    A = np.array([\
        [x_orig, 1],\
        [x_dest, 1]\
    ])
    b = np.array([y_orig, y_dest])

    Apinv = np.linalg.pinv(A)
    x = Apinv.dot(b)

    tracks_krakow_lines_parameters.append(x)

len(tracks_krakow_lines_parameters)
```

In []:

```
tracks_krakow_line = []

for track in range(len(tracks_krakow)):

    if tracks_krakow[track][0][1] <= tracks_krakow[track][-1][1]: #źródło na zachód od celu
        t = []
        t.append(tracks_krakow[track][0])

        x = tracks_krakow[track][0][1]

        while x < tracks_krakow[track][-1][1]:

            x = x + 0.001
            y = tracks_krakow_lines_parameters[track][0] * x + tracks_krakow_lines_parameters[track][1]
            t.append([y, x])

        t.append(tracks_krakow[track][-1])

        tracks_krakow_line.append(t)

    else: #cel na zachód od źródła
        t = []
        t.append(tracks_krakow[track][-1])

        x = tracks_krakow[track][-1][1]

        while x < tracks_krakow[track][0][1]:

            x = x + 0.001
            y = tracks_krakow_lines_parameters[track][0] * x + tracks_krakow_lines_parameters[track][1]
            t.append([y, x])

        t.append(tracks_krakow[track][0])

        tracks_krakow_line.append(t)

len(tracks_krakow_line)
```

In []:

```
tracks_value_krakow_line = []

for track in tracks_krakow_line:

    points_value = [[], [], []]
```

```

for point in range(len(track)):
    for b1 in range(60):
        if Lat[b1] >= track[point][0] > Lat[b1] - y_interval:
            for b2 in range(100):
                if Lon[b2] <= track[point][1] < Lon[b2] + x_interval:

                    points_value[0].append(classes[b1, b2])
                    points_value[1].append(b1)
                    points_value[2].append(b2)

for point in range(1, len(points_value[0])): #uniknięcie przypisania dwóm kolejnym punktom z tego san
    if points_value[1][point] == points_value[1][point - 1]:
        if points_value[2][point] == points_value[2][point - 1]:
            points_value[0][point] = 0
    else:
        continue

tracks_value_krakow_line.append(sum(points_value[0]))

df_tracks_value_krakow_line = pd.DataFrame(tracks_value_krakow_line)
df_tracks_value_krakow_line.to_csv('waloryzacja_tras_w_linii_prostej.csv', index=False)

len(tracks_value_krakow_line)

```

Współczynnik wzrostu atrakcyjności trasy

```

a_coef_krakow = []

for i in range(len(tracks_value_krakow)):
    if tracks_value_krakow_line[i] == 0:
        a_coef_krakow.append(round(tracks_value_krakow[i] / 1, 2))
    else:
        a_coef_krakow.append(round(tracks_value_krakow[i] / tracks_value_krakow_line[i], 2))

len(a_coef_krakow)

df_a_coef_krakow = pd.DataFrame(a_coef_krakow)
df_a_coef_krakow.describe()

a_coef_krakow_plot_ = []

for i in range(len(a_coef_krakow)):
    a_coef_krakow_plot_.append(a_coef_krakow[i] + random.uniform(-0.4, 0.4))

a_coef_krakow_plot = np.array(a_coef_krakow_plot_)

```

Model zależności atrakcyjności otoczenia i czasu podróży

```

font1 = {'family':'sans-serif','color':'black','size':20}

altr_ = []

for i in range(len(random_list)):
    if i in train_ids:
        altr_.append(tracks_value_krakow[i])

altr = np.array(altr_).reshape((-1, 1))

altest_ = []

for i in range(len(random_list)):
    if i in test_ids:
        altest_.append(tracks_value_krakow[i])

altest = np.array(altest_).reshape((-1, 1))

tltr_ = []

```

```

for i in range(len(random_list)):
    if i in train_ids:
        tltr_.append(time_krakow[i])

tltr = np.array(tltr_).reshape((-1, 1))

tltest_ = []

for i in range(len(random_list)):
    if i in test_ids:
        tltest_.append(time_krakow[i])

tltest = np.array(tltest_).reshape((-1, 1))

at = np.concatenate((altr, tltr), axis=1)
data_at = pd.DataFrame(at, columns = ['a', 't'])

corrMatrix_at = data_at.corr('pearson')

plt.figure(figsize=(16,5))
plt.xticks(fontsize=14)
plt.yticks(fontsize=14)
myColors = ((0.99, 0.99, 0.99, 0.99), (0.95, 0.8, 0.0, 0.95))
cmap = LinearSegmentedColormap.from_list('Custom', myColors, 10)
s = sb.heatmap(corrMatrix_at, vmin=0, annot=True, annot_kws={'size':16}, cmap=cmap, square=True)
colorbar = s.collections[0].colorbar
plt.savefig('macierz_korelacji_t-a_pearson.jpg', bbox_inches='tight', dpi = 150)
plt.show()

corrMatrix_at2 = data_at.corr('spearman')

plt.figure(figsize=(16,5))
plt.xticks(fontsize=14)
plt.yticks(fontsize=14)
myColors = ((0.99, 0.99, 0.99, 0.99), (0.95, 0.8, 0.0, 0.95))
cmap = LinearSegmentedColormap.from_list('Custom', myColors, 10)
s = sb.heatmap(corrMatrix_at2, vmin=0, annot=True, annot_kws={'size':16}, cmap=cmap, square=True)
colorbar = s.collections[0].colorbar
plt.savefig('macierz_korelacji_t-a_spearman.jpg', bbox_inches='tight', dpi = 150)
plt.show()

modelt = LinearRegression().fit(altr, tltr)
r_sqrt = modelt.score(altr, tltr)
print('coefficient of determination:', r_sqrt)
print('intercept:', modelt.intercept_)
print('slope:', modelt.coef_)

tlpred = modelt.predict(altest)

metrics.r2_score(tltest, tlpred)

plt.subplots(figsize=(22,10))
plt.scatter(tracks_value_krakow_plot, time_krakow, alpha=0.1, color='darkblue')

plt.plot([0, 60], [0.84495972 * 0 + 8.0727362, 0.84495972 * 60 + 8.0727362], 'b-', c='red')

plt.xlabel('Poziom atrakcyjności otoczenia trasy', fontdict = font1)
plt.ylabel('Czas podróży [min]', fontdict = font1)
plt.xticks(fontsize = 20)
plt.yticks(fontsize = 20)
plt.xlim(0, 60)
plt.ylim(0, 60)

plt.savefig('t-a.jpg', bbox_inches='tight', dpi = 150)

```

Model zależności atrakcyjności otoczenia i długości trasy

```

dltr_ = []

```

In []:

In []:

In []:

In []:

In []:

In []:

In []:

In []:

In []:

```

for i in range(len(random_list)):
    if i in train_ids:
        dltr_.append(distance_krakow[i])

dltr = np.array(dltr_).reshape((-1, 1))

dltest_ = []

for i in range(len(random_list)):
    if i in test_ids:
        dltest_.append(distance_krakow[i])

dltest = np.array(dltest_).reshape((-1, 1))

ad = np.concatenate((altr, dltr), axis=1)
data_ad = pd.DataFrame(ad, columns = ['a', 'd'])

corrMatrix_ad = data_ad.corr('pearson')

plt.figure(figsize=(16,5))
plt.xticks(fontsize=14)
plt.yticks(fontsize=14)
myColors = ((0.99, 0.99, 0.99, 0.99), (0.95, 0.8, 0.0, 0.95))
cmap = LinearSegmentedColormap.from_list('Custom', myColors, 10)
s = sb.heatmap(corrMatrix_ad, vmin=0, annot=True, annot_kws={'size':16}, cmap=cmap, square=True)
colorbar = s.collections[0].colorbar
plt.savefig('macierz_korelacji_d-a_pearson.jpg', bbox_inches='tight', dpi = 150)
plt.show()

corrMatrix_ad2 = data_ad.corr('spearman')

plt.figure(figsize=(16,5))
plt.xticks(fontsize=14)
plt.yticks(fontsize=14)
myColors = ((0.99, 0.99, 0.99, 0.99), (0.95, 0.8, 0.0, 0.95))
cmap = LinearSegmentedColormap.from_list('Custom', myColors, 10)
s = sb.heatmap(corrMatrix_ad2, vmin=0, annot=True, annot_kws={'size':16}, cmap=cmap, square=True)
colorbar = s.collections[0].colorbar
plt.savefig('macierz_korelacji_d-a_spearman.jpg', bbox_inches='tight', dpi = 150)
plt.show()

modeld = LinearRegression().fit(altr, dltr)
r_sqd = modeld.score(altr, dltr)
print('coefficient of determination:', r_sqd)
print('intercept:', modeld.intercept_)
print('slope:', modeld.coef_)

dlpred = modeld.predict(altest)

metrics.r2_score(dltest, dlpred)

plt.subplots(figsize=(22,10))
plt.scatter(tracks_value_krakow_plot, distance_krakow, alpha=0.1, color='darkblue')

plt.plot([0, 30], [0.12828544 * 0 + 1.6173797, 0.12828544 * 30 + 1.6173797], 'b-', c='red')

plt.xlabel('Poziom atrakcyjności otoczenia trasy', fontdict = font1)
plt.ylabel('Długość podróży [km]', fontdict = font1)
plt.xticks(fontsize = 20)
plt.yticks(fontsize = 20)
plt.xlim(0, 30)
plt.ylim(0, 10)

plt.savefig('d-a.jpg', bbox_inches='tight', dpi = 150)

```

Model zależności atrakcyjności otoczenia i współczynnika wydłużenia trasy

```

In []:
arltr_ = []

for i in range(len(random_list)):
    if i in train_ids:
        arltr_.append(a_coef_krakow[i])

arltr = np.array(arltr_).reshape((-1, 1))

In []:
arltest_ = []

for i in range(len(random_list)):
    if i in test_ids:
        arltest_.append(a_coef_krakow[i])

arltest = np.array(arltest_).reshape((-1, 1))

In []:
rltr_ = []

for i in range(len(random_list)):
    if i in train_ids:
        rltr_.append(irr_coef_krakow[i])

rltr = np.array(rltr_).reshape((-1, 1))

In []:
rltest_ = []

for i in range(len(random_list)):
    if i in test_ids:
        rltest_.append(irr_coef_krakow[i])

rltest = np.array(rltest_).reshape((-1, 1))

In []:
ar = np.concatenate((arltr, rltr), axis=1)
data_ar = pd.DataFrame(ar, columns = ['w', 'r'])

In []:
corrMatrix_ar = data_ar.corr('pearson')

plt.figure(figsize=(16,5))
plt.xticks(fontsize=14)
plt.yticks(fontsize=14)
myColors = ((0.99, 0.99, 0.99, 0.99), (0.95, 0.8, 0.0, 0.95))
cmap = LinearSegmentedColormap.from_list('Custom', myColors, 10)
s = sb.heatmap(corrMatrix_ar, vmin=0, annot=True, annot_kws={'size':16}, cmap=cmap, square=True)
colorbar = s.collections[0].colorbar
plt.savefig('macierz_korelacji_r-a_pearson.jpg', bbox_inches='tight', dpi = 150)
plt.show()

In []:
corrMatrix_ar2 = data_ar.corr('spearman')

plt.figure(figsize=(16,5))
plt.xticks(fontsize=14)
plt.yticks(fontsize=14)
myColors = ((0.99, 0.99, 0.99, 0.99), (0.95, 0.8, 0.0, 0.95))
cmap = LinearSegmentedColormap.from_list('Custom', myColors, 10)
s = sb.heatmap(corrMatrix_ar2, vmin=0, annot=True, annot_kws={'size':16}, cmap=cmap, square=True)
colorbar = s.collections[0].colorbar
plt.savefig('macierz_korelacji_r-a_spearman.jpg', bbox_inches='tight', dpi = 150)
plt.show()

In []:
modelr = LinearRegression().fit(arltr, rltr)
r_sqr = modelr.score(arltr, rltr)
print('coefficient of determination:', r_sqr)
print('intercept:', modelr.intercept_)
print('slope:', modelr.coef_)

In []:
rlpred = modelr.predict(arltest)

In []:
metrics.r2_score(rltest, rlpred)

In []:

```

```
plt.subplots(figsize=(22,10))
plt.scatter(a_coef_krakow_plot, irr_coef_krakow, alpha=0.1, color='darkblue')

#plt.plot([0, 5], [31.73008374 * 0 -27.78430287, 31.73008374 * 5 -27.78430287], 'b-', c='red')

plt.xlabel('Współczynnik zmiany poziomu atrakcyjności otoczenia trasy', fontdict = font1)
plt.ylabel('Współczynnik wydłużenia trasy', fontdict = font1)
plt.xticks(fontsize = 20)
plt.yticks(fontsize = 20)
plt.xlim(0, 5)
plt.ylim(1, 2)

plt.savefig('r-a.jpg', bbox_inches='tight', dpi = 150)
```

Skrypt #5

Import bibliotek

```
import math
import numpy as np
import pandas as pd
import csv
from pandas import DataFrame
import seaborn as sb
import matplotlib.pyplot as plt
from sklearn.linear_model import LinearRegression
from sklearn.preprocessing import PolynomialFeatures
from sklearn.linear_model import LogisticRegression
from matplotlib.colors import LinearSegmentedColormap
from sklearn.metrics import classification_report, confusion_matrix
import random
from sklearn import metrics
from sklearn import *
```

In []:

Przygotowanie ID rekordów zbioru treningowego i testowego

```
random_6000 = []

i = 0

for _ in range(6000):
    random_6000.append(i)
    i = i + 1
```

In []:

```
len(random_6000)
```

In []:

```
def unique(list1):

    unique_list = []

    for x in list1:
        if x not in unique_list:
            unique_list.append(x)

    print (len(unique_list))
```

In []:

```
train_elements = int(0.8 * 6000)
```

In []:

```
#utworzenie listy ID rekordów zbioru treningowego
```

```
train_ids = random.sample(random_6000, train_elements)
train_ids.sort()
```

```
unique(train_ids)
```

In []:

```
#utworzenie listy ID rekordów zbioru testowego
```

```
test_ids = []
```

```
for _ in random_6000:
    if _ not in train_ids:
        test_ids.append(_)
```

```
len(test_ids)
```

Wczytanie danych o walorach kulturowych

In []:


```
#zabytki
zabytki_arch = pd.read_csv('dane/zabytki_arch_simpl_grid.csv')
zabytki_urz_techniki = pd.read_csv('dane/zabytki_urz_techniki_simpl_grid.csv')
zabytki_zielen_obszary = pd.read_csv('dane/zabytki_zielen_obszary_simpl_grid.csv')
```

In []:

```
x1 = np.array(zabytki_arch)
z1 = x1.astype(np.float)
print(sum(sum(z1)))
```

```
x2 = np.array(zabytki_urz_techniki)
z2 = x2.astype(np.float)
print(sum(sum(z2)))
```

```
x3 = np.array(zabytki_zielen_obszary)
z3 = x3.astype(np.float)
print(sum(sum(z3)))
```

In []:

```
z1a = []
```

```
for b1 in range(60):
    for b2 in range(100):
        z1a.append(z1[b1, b2])
```

```
z2a = []
```

```
for b1 in range(60):
    for b2 in range(100):
        z2a.append(z2[b1, b2])
```

```
z3a = []
```

```
for b1 in range(60):
    for b2 in range(100):
        z3a.append(z3[b1, b2])
```

Walory kulturowe - zbiór treningowy i testowy

In []:

```
z1tr_ = []
```

```
for i in range(6000):
    if i in train_ids:
        z1tr_.append(z1a[i])
```

```
z1tr = np.array(z1tr_).reshape((-1, 1))
```

```
z2tr_ = []
```

```
for i in range(6000):
    if i in train_ids:
        z2tr_.append(z2a[i])
```

```
z2tr = np.array(z2tr_).reshape((-1, 1))
```

```
z3tr_ = []
```

```
for i in range(6000):
    if i in train_ids:
        z3tr_.append(z3a[i])
```

```
z3tr = np.array(z3tr_).reshape((-1, 1))
```

In []:

```
z1test_ = []
```

```
for i in range(6000):
    if i in test_ids:
        z1test_.append(z1a[i])
```

```
z1test = np.array(z1test_).reshape((-1, 1))
```

```
z2test_ = []
```

```

for i in range(6000):
    if i in test_ids:
        z2test_.append(z2a[i])

z2test = np.array(z2test_).reshape((-1, 1))

z3test_ = []

for i in range(6000):
    if i in test_ids:
        z3test_.append(z3a[i])

z3test = np.array(z3test_).reshape((-1, 1))

```

Wczytanie danych o walorach przyrodniczych

```

przyroda_parki = pd.read_csv('dane/przyroda_parki_simpl_grid.csv')
przyroda_parki_lesne = pd.read_csv('dane/przyroda_parki_lesne_simpl_grid.csv')
przyroda_cieki = pd.read_csv('dane/przyroda_cieki_wodne_1_2_klasa_grid.csv')
przyroda_zbiorniki = pd.read_csv('dane/przyroda_zbiorniki_wodne_grid.csv')

```

In []:

```

x4 = np.array(przyroda_parki)
p1 = x4.astype(np.float)
print(sum(sum(p1)))

x5 = np.array(przyroda_parki_lesne)
p2 = x5.astype(np.float)
print(sum(sum(p2)))

x6 = np.array(przyroda_cieki)
p3 = x6.astype(np.float)
print(sum(sum(p3)))

x7 = np.array(przyroda_zbiorniki)
p4 = x7.astype(np.float)
print(sum(sum(p4)))

```

In []:

```

p1a = []

for b1 in range(60):
    for b2 in range(100):
        p1a.append(p1[b1, b2])

p2a = []

for b1 in range(60):
    for b2 in range(100):
        p2a.append(p2[b1, b2])

p3a = []

for b1 in range(60):
    for b2 in range(100):
        p3a.append(p3[b1, b2])

p4a = []

for b1 in range(60):
    for b2 in range(100):
        p4a.append(p4[b1, b2])

```

In []:

Walory przyrodnicze - zbiór treningowy i testowy

```

p1tr_ = []

for i in range(6000):
    if i in train_ids:
        p1tr_.append(p1a[i])

```

In []:

```

p1tr = np.array(p1tr_).reshape((-1, 1))

p2tr_ = []
for i in range(6000):
    if i in train_ids:
        p2tr_.append(p2a[i])
p2tr = np.array(p2tr_).reshape((-1, 1))

p3tr_ = []
for i in range(6000):
    if i in train_ids:
        p3tr_.append(p3a[i])
p3tr = np.array(p3tr_).reshape((-1, 1))

p4tr_ = []
for i in range(6000):
    if i in train_ids:
        p4tr_.append(p4a[i])
p4tr = np.array(p4tr_).reshape((-1, 1))

p1test_ = []
for i in range(6000):
    if i in test_ids:
        p1test_.append(p1a[i])
p1test = np.array(p1test_).reshape((-1, 1))

p2test_ = []
for i in range(6000):
    if i in test_ids:
        p2test_.append(p2a[i])
p2test = np.array(p2test_).reshape((-1, 1))

p3test_ = []
for i in range(6000):
    if i in test_ids:
        p3test_.append(p3a[i])
p3test = np.array(p3test_).reshape((-1, 1))

p4test_ = []
for i in range(6000):
    if i in test_ids:
        p4test_.append(p4a[i])
p4test = np.array(p4test_).reshape((-1, 1))

```

In []:

Walory kulturowe i przyrodnicze - połączone zbiory

```

z123p1234tr = np.concatenate((z1tr, z2tr, z3tr, p1tr, p2tr, p3tr, p4tr), axis=1)

z123p1234test = np.concatenate((z1test, z2test, z3test, p1test, p2test, p3test, p4test), axis=1)

```

In []:

In []:

Wczytanie danych o waloryzacji

```
waloryzacja = pd.read_csv('dane/waloryzacja.csv')
```

In []:

```
v = np.array(waloryzacja)
w = v.astype(np.float)
print(sum(sum(w)))
```

In []:

```
wa = []
```

In []:

```
for b1 in range(60):
    for b2 in range(100):
        wa.append(w[b1, b2])
```

Waloryzacja - zbiór treningowy i testowy

```
wtr_ = []
```

In []:

```
for i in range(6000):
    if i in train_ids:
        wtr_.append(wa[i])
```

```
wtr = np.array(wtr_).reshape((-1,1))
```

In []:

```
wtest_ = []
```

```
for i in range(6000):
    if i in test_ids:
        wtest_.append(wa[i])
```

```
wtest = np.array(wtest_).reshape((-1,1))
```

Wczytanie danych o postojach

```
postoje_liczba = pd.read_csv('dane/postoje_liczba.csv')
postoje_liczba_0_1_q95 = pd.read_csv('dane/postoje_liczba_0_1_q95.csv')
postoje_czas = pd.read_csv('dane/postoje_czas_min.csv')
postoje_czas_0_1_q95 = pd.read_csv('dane/postoje_czas_0_1_q95.csv')
```

In []:

```
y1 = np.array(postoje_liczba)
s1 = y1.astype(np.float)
print(sum(sum(s1)))
```

In []:

```
y2 = np.array(postoje_liczba_0_1_q95)
s2 = y2.astype(np.float)
print(sum(sum(s2)))
```

```
y3 = np.array(postoje_czas)
s3 = y3.astype(np.float)
print(sum(sum(s3)))
```

```
y4 = np.array(postoje_czas_0_1_q95)
s4 = y4.astype(np.float)
print(sum(sum(s4)))
```

In []:

```
s1a = []
```

```
for b1 in range(60):
    for b2 in range(100):
        s1a.append(s1[b1, b2])
```

```
s2a = []
```

```
for b1 in range(60):
    for b2 in range(100):
```

```

        s2a.append(s2[b1, b2])

s3a = []

for b1 in range(60):
    for b2 in range(100):
        s3a.append(s3[b1, b2])

s4a = []

for b1 in range(60):
    for b2 in range(100):
        s4a.append(s4[b1, b2])

```

Postoje - zbiór treningowy i testowy

```

s1tr_ = []

for i in range(6000):
    if i in train_ids:
        s1tr_.append(s1a[i])

s1tr = np.array(s1tr_)

s2tr_ = []

for i in range(6000):
    if i in train_ids:
        s2tr_.append(s2a[i])

s2tr = np.array(s2tr_)

s3tr_ = []

for i in range(6000):
    if i in train_ids:
        s3tr_.append(s3a[i])

s3tr = np.array(s3tr_)

s4tr_ = []

for i in range(6000):
    if i in train_ids:
        s4tr_.append(s4a[i])

s4tr = np.array(s4tr_)

```

```

s1test_ = []

for i in range(6000):
    if i in test_ids:
        s1test_.append(s1a[i])

s1test = np.array(s1test_)

s2test_ = []

for i in range(6000):
    if i in test_ids:
        s2test_.append(s2a[i])

s2test = np.array(s2test_)

s3test_ = []

for i in range(6000):
    if i in test_ids:
        s3test_.append(s3a[i])

s3test = np.array(s3test_)

s4test_ = []

```

In []:

In []:

```

for i in range(6000):
    if i in test_ids:
        s4test_.append(s4a[i])

s4test = np.array(s4test_)

```

Regresja liniowa

Dla zmiennej waloryzacji

```

s1tr2 = np.array(s1tr).reshape((-1,1))

```

In []:

```

ws1 = np.concatenate((wtr, s1tr2), axis=1)
data_ws1 = pd.DataFrame(ws1, columns = ['a', 'y'])

```

In []:

```

corrMatrix_ws1 = data_ws1.corr('pearson')

plt.figure(figsize=(16,5))
plt.xticks(fontsize=14)
plt.yticks(fontsize=14)
myColors = ((0.99, 0.99, 0.99, 0.99), (0.95, 0.8, 0.0, 0.95))
cmap = LinearSegmentedColormap.from_list('Custom', myColors, 10)
s = sb.heatmap(corrMatrix_ws1, vmin=0, annot=True, annot_kws={'size':16}, cmap=cmap, square=True)
colorbar = s.collections[0].colorbar
plt.savefig('macierz_korelacji_w-s_pearson.jpg', bbox_inches='tight', dpi = 150)
plt.show()

```

In []:

```

corrMatrix_ws2 = data_ws1.corr('spearman')

plt.figure(figsize=(16,5))
plt.xticks(fontsize=14)
plt.yticks(fontsize=14)
myColors = ((0.99, 0.99, 0.99, 0.99), (0.95, 0.8, 0.0, 0.95))
cmap = LinearSegmentedColormap.from_list('Custom', myColors, 10)
s = sb.heatmap(corrMatrix_ws2, vmin=0, annot=True, annot_kws={'size':16}, cmap=cmap, square=True)
colorbar = s.collections[0].colorbar
plt.savefig('macierz_korelacji_w-s_spearman.jpg', bbox_inches='tight', dpi = 150)
plt.show()

```

In []:

```

model0 = LinearRegression()
model0.fit(wtr, s1tr)
r_sq0 = model0.score(wtr, s1tr)
print('coefficient of determination:', r_sq0)
print('intercept:', model0.intercept_)
print('slope:', model0.coef_)

```

Dla zmiennych walorów

```

modell1 = LinearRegression()
modell1.fit(z123p1234tr, s1tr)
r_sq1 = modell1.score(z123p1234tr, s1tr)
print('coefficient of determination:', r_sq1)
print('intercept:', modell1.intercept_)
print('slope:', modell1.coef_)

```

In []:

```

s1pred = modell1.predict(z123p1234test)

```

In []:

```

s1pred_plot_ = []

```

In []:

```

for i in range(len(s1pred)):
    s1pred_plot_.append(s1pred[i] + random.uniform(-0.4, 0.4))

s1pred_plot = np.array(s1pred_plot_)

```

In []:

```

s1test_plot_ = []

```

```

for i in range(len(sltest)):
    sltest_plot_.append(sltest[i] + random.uniform(-0.4, 0.4))

sltest_plot = np.array(sltest_plot_)

metrics.r2_score(sltest, slpred)

font1 = {'family':'sans-serif','color':'black','size':20}

plt.figure(figsize=(10,10))
plt.scatter(sltest_plot, slpred_plot, alpha=0.5, c='darkblue')

p1 = max(max(slpred), max(sltest))
p2 = min(min(slpred), min(sltest))
plt.plot([p1, p2], [p1, p2], 'b-', c='red')

plt.xlabel('Wartości rzeczywiste', fontdict = font1)
plt.ylabel('Wartości predykowane', fontdict = font1)
plt.xticks(fontsize = 20)
plt.yticks(fontsize = 20)
plt.xlim(0, 15)
plt.ylim(0, 15)
plt.savefig('postoje_liczba_regrlin.jpg', bbox_inches='tight', dpi = 150)
plt.show()

model2 = LinearRegression().fit(z123p1234tr, s3tr)
r_sq2 = model2.score(z123p1234tr, s3tr)
print('coefficient of determination:', r_sq2)
print('intercept:', model2.intercept_)
print('slope:', model2.coef_)

s3pred = model2.predict(z123p1234test)

s3pred_plot_ = []

for i in range(len(s3pred)):
    s3pred_plot_.append(s3pred[i] + random.uniform(-0.4, 0.4))

s3pred_plot = np.array(s3pred_plot_)

s3test_plot_ = []

for i in range(len(s3test)):
    s3test_plot_.append(s3test[i] + random.uniform(-0.4, 0.4))

s3test_plot = np.array(s3test_plot_)

metrics.r2_score(s3test, s3pred)

plt.figure(figsize=(10,10))
plt.scatter(s3test_plot, s3pred_plot, alpha=0.5, c='darkblue')

p1 = max(max(s3pred), max(s3test))
p2 = min(min(s3pred), min(s3test))
plt.plot([p1, p2], [p1, p2], 'b-', c='red')
plt.xlabel('Wartości rzeczywiste', fontdict = font1)
plt.ylabel('Wartości predykowane', fontdict = font1)
plt.xticks(fontsize = 20)
plt.yticks(fontsize = 20)
plt.xlim(0, 60)
plt.ylim(0, 60)
plt.savefig('postoje_czas_regrlin.jpg', bbox_inches='tight', dpi = 150)
plt.show()

```

In []:

In []:

In []:

In []:

In []:

In []:

In []:

In []:

In []:

Regresja logistyczna

```

model_log1 = LogisticRegression(solver='liblinear', random_state=0)
model_log1.fit(wtr, s2tr)

```

In []:

```

r_sq_log1 = model_log1.score(wtr, s2tr)
print('coefficient of determination:', r_sq_log1)
print('intercept:', model_log1.intercept_)
print('slope:', model_log1.coef_)

model_log1.predict_proba(wtest)

s2pred = model_log1.predict(wtest)

cnf_matrix1 = metrics.confusion_matrix(s2test, s2pred)

cnf_matrix1

class_names=[0,1] # nazwy klas
fig, ax = plt.subplots()
tick_marks = np.arange(len(class_names))
plt.xticks(tick_marks, class_names, fontsize=14)
plt.yticks(tick_marks, class_names, fontsize=14)

# stworzenie mapy ciepła
myColors = ((0.99, 0.99, 0.99, 0.99), (0.95, 0.8, 0.0, 0.95))
cmap = LinearSegmentedColormap.from_list('Custom', myColors, 12)
sb.heatmap(pd.DataFrame(cnf_matrix1), annot=True, annot_kws={'size':16}, cmap=cmap, fmt='g')
ax.xaxis.set_label_position("top")
plt.tight_layout()
plt.ylabel('Klasa rzeczywista')
plt.xlabel('Klasa predykowana')
plt.savefig('postoje_liczba_regrlog.jpg', bbox_inches='tight', dpi = 150)
plt.show()

print("Accuracy:",metrics.accuracy_score(s2test, s2pred))
print("Precision:",metrics.precision_score(s2test, s2pred))
print("Recall:",metrics.recall_score(s2test, s2pred))

font2 = {'family':'sans-serif','color':'black','size':14}

y_pred_proba = model_log1.predict_proba(wtest)[::,1]
fpr, tpr, _ = metrics.roc_curve(s2test, y_pred_proba)
auc = metrics.roc_auc_score(s2test, y_pred_proba)
plt.plot(fpr,tpr,label="auc="+str(auc), color='red')
plt.xticks(fontsize = 12)
plt.yticks(fontsize = 12)
plt.xlabel('1-Specyficzność', fontdict = font2)
plt.ylabel('Czułość', fontdict = font2)
plt.legend(loc=4)
plt.savefig('postoje_liczba_regrlog_roc.jpg', bbox_inches='tight', dpi = 150)
plt.show()

model_log2 = LogisticRegression(solver='liblinear', random_state=0)
model_log2.fit(wtr, s4tr)
r_sq_log2 = model_log2.score(wtr, s4tr)
print('coefficient of determination:', r_sq_log2)
print('intercept:', model_log2.intercept_)
print('slope:', model_log2.coef_)

model_log2.predict_proba(wtest)

s4pred = model_log2.predict(wtest)

cnf_matrix2 = metrics.confusion_matrix(s4test, s4pred)

cnf_matrix2

class_names=[0,1] # nazwy klas
fig, ax = plt.subplots()
tick_marks = np.arange(len(class_names))
plt.xticks(tick_marks, class_names, fontsize=14)

```



```
plt.yticks(tick_marks, class_names, fontsize=14)

# stworzenie mapy ciepła
myColors = ((0.99, 0.99, 0.99, 0.99), (0.95, 0.8, 0.0, 0.95))
cmap = LinearSegmentedColormap.from_list('Custom', myColors, 12)
sb.heatmap(pd.DataFrame(cnf_matrix2), annot=True, annot_kws={'size':16}, cmap=cmap, fmt='g')
ax.xaxis.set_label_position("top")
plt.tight_layout()
plt.ylabel('Klasa rzeczywista')
plt.xlabel('Klasa predykowana')
plt.savefig('postoje_czas_regrlog.jpg', bbox_inches='tight', dpi = 150)
plt.show()
```

In []:

```
print("Accuracy:",metrics.accuracy_score(s4test, s4pred))
print("Precision:",metrics.precision_score(s4test, s4pred))
print("Recall:",metrics.recall_score(s4test, s4pred))
```

In []:

```
y_pred_proba2 = model_log2.predict_proba(wtest)[:,:1]
fpr, tpr, _ = metrics.roc_curve(s4test, y_pred_proba2)
auc = metrics.roc_auc_score(s4test, y_pred_proba2)
plt.plot(fpr,tpr,label="auc="+str(auc), color='red')
plt.xticks(fontsize = 12)
plt.yticks(fontsize = 12)
plt.xlabel('1-Specyficzność', fontdict = font2)
plt.ylabel('Czułość', fontdict = font2)
plt.legend(loc=4)
plt.savefig('postoje_czas_regrlog_roc.jpg', bbox_inches='tight', dpi = 150)
plt.show()
```