

Autoreferat

1 Imię i nazwisko

Jakub Nowosad

2 Posiadane dyplomy, stopnie naukowe lub artystyczne - z podaniem podmiotu nadającego stopień, roku ich uzyskania oraz tytułu rozprawy doktorskiej

1. **Licencjat geografii, specjalność geoinformacja**, Uniwersytet im. Adama Mickiewicza w Poznaniu, 2010
2. **Magister geografii, specjalność geoinformacja (Wyróżnienie)**, Uniwersytet im. Adama Mickiewicza w Poznaniu, 2012
3. **Doktor Nauk o Ziemi w zakresie geografii (Wyróżnienie)**, Uniwersytet im. Adama Mickiewicza w Poznaniu, 2016. Rozprawa doktorska: *Forecasting of Corylus, Alnus, and Betula pollen concentration in the air in Poland* (promotor: Alfred Stach)

3 Informacja o dotychczasowym zatrudnieniu w jednostkach naukowych lub artystycznych

1. 2016-2018 : **Postdoctoral Fellow**, University of Cincinnati, Department of Geography and GIS, Space Informatics Lab
2. 2018-teraz: **Adiunkt**, Uniwersytet im. Adama Mickiewicza w Poznaniu, Wydział Nauk Geograficznych i Geologicznych, Zakład Geoinformacji

4 Omówienie osiągnięć, o których mowa w art. 219 ust. 1 pkt. 2 Ustawy

4.1 Tytuł

Metody analizy struktur przestrzennych i ich zastosowanie w badaniach geograficznych

4.2 Lista publikacji

1. Nowosad, J. i T. F. Stepinski (2018). "Global inventory of landscape patterns and latent variables of landscape spatial configuration". *Ecological Indicators* 89, s.159-167. doi: 10.1016/j.ecolind.2018.02.007.
IF: 4,490, WoS: 8, Google Scholar: 12
2. Nowosad, J. i T. F. Stepinski (2019a). "Information theory as a consistent framework for quantification and classification of landscape patterns". *Landscape Ecology* 34.9, s.2091-2101. doi: 10.1007/s10980-019-00830-x.
IF: 3,385, WoS: 12, Google Scholar: 25
3. Nowosad, J., T. F. Stepinski i P. Netzel (2019b). "Global assessment and mapping of changes in mesoscale landscapes: 1992–2015". *International Journal of Applied Earth Observation and Geoinformation* 78, s.332-340. doi: 10.1016/j.jag.2018.09.013.
IF: 4,650, WoS: 12, Google Scholar: 18
4. Nowosad, J. i T. F. Stepinski (2019c). "Stochastic, empirically informed model of landscape dynamics and its application to deforestation scenarios". *Geophysical Research Letters* 46.23, s.13845-13852. doi: 10.1029/2019GL085952.
IF: 4,497, WoS: 4, Google Scholar: 5
5. Nowosad, J. i T. F. Stepinski (2021). "Pattern-based identification and mapping of landscape types using multi-thematic data". *International Journal of Geographical Information Science*. doi: 10.1080/13658816.2021.1893324.
IF: 3,733, WoS: 0, Google Scholar: 0
6. Nowosad, J. (2021). "Motif: an open-source R tool for pattern-based spatial analysis". *Landscape Ecology* 36, s.29-43. doi: 10.1007/s10980-020-01135-0.
IF: 3,385, WoS: 1, Google Scholar: 1

4.3 Opis osiągnięć

4.3.1 Wstęp

Globalne mapy pokrycia terenu (ang. *global land cover*, GLC) tworzone są poprzez klasyfikację oczek siatki z obrazów satelitarnych do kilku predefiniowanych kategorii. Rozdzielczość przestrzenna istniejących globalnych map pokrycia terenu wynosi od 30 m do 1 km, natomiast ich liczba kategorii (rozdzielczość tematyczna) waha się od 10 do 27 (Tsendbazar i in. 2015; Chen i in. 2015). Mapy pokrycia terenu są niezbędne w globalnych analizach środowiskowych ponieważ dostarczają informacji na temat przestrzennego zróżnicowania różnorodności biologicznej i procesów ekologicznych (Eyre i in. 2004; Heikkinen i in. 2004; Luoto i in. 2006). Globalne mapy pokrycia terenu wykorzystywane są także do określania jego aktualnego stanu i prognozowania zmian pokrycia terenu czy też do tworzenia klasyfikacji typów krajobrazu. W tego typu opracowaniach często oczko siatki traktowane jest jako jednostka analizy (Hansen i in. 2010; Hansen i in. 2013; Kim i in. 2014; Olmedo i in. 2018; Mùcher i in. 2010; Sayre i in. 2014).

W wielu przypadkach jednak to struktura przestrzenna¹ (ang. *spatial pattern*) kategorii pokrycia terenu, a nie sama kategoria, jest przedmiotem zainteresowania z punktu widzenia ochrony środowiska lub ekologii. Oczka siatki na mapach GLC są często zbyt małymi jednostkami obszaru, a informacje w skali oczka są same w sobie nieistotne dla analizy dużych obszarów. W takim przypadku "lokalny krajobraz" (ang. *local landscape*) jest bardziej odpowiednią jednostką analizy (Wickham i in. 1994; Riitters i in. 2000; Riitters 2011; Richling i in. 2011; Omernik i in. 2014). Dla kategoryzowanych danych rastrowych, takich jak GLC, lokalny krajobraz jest reprezentowany przez grupę oczek siatki zawierających lokalną strukturę badanej zmiennej. Przestrzenne struktury lokalnych krajobrazów, a zwłaszcza ich kompozycja (skład) i konfiguracja, są powiązane z bioróżnorodnością, możliwościami sekwestracji (akumulacji) dwutlenku węgla, jakością wody czy charakterystyką miejskich wysp ciepła (Häger i in. 2015; Brinck i in. 2017; Alberti i in. 2007; Connors i in. 2013).

Rycina 1 pokazuje przykłady sześciu lokalnych krajobrazów o takim samym kształcie i wielkości, ale o różnych kompozycjach (ułożone w rzędach) i konfiguracjach przestrzennych (ułożone w kolumnach). Pokrycie terenu obu obrazów rastrowych w pierwszym rzędzie zdominowane jest przez lasy z niewielkimi obszarami rolnymi. Różnią się one jednak konfiguracją - pierwszy krajobraz ma skupione/zagregowane kategorie pokrycia terenu, podczas gdy w drugim krajo-


¹W opisie osiągnięcia używam terminu "struktura przestrzenna" jako bezpośredniego tłumaczenia *spatial patterns* z języka angielskiego. Jest on, w przypadku badania jednej zmiennej, tożsamy z terminami struktura przestrzenna krajobrazu (Solon 2002; Richling 2009) czy wrzosec krajobrazu (Pietrzak 2010), stosowanymi w polskiej literaturze ekologii krajobrazu. Stosowanie terminu "struktura przestrzenna" ma podkreślać, że obejmuje ona także opis wielozmiennych (wielotematycznych) zbiorów danych oraz wskazywać możliwość używania jej w innych dziedzinach naukowych niż ekologia krajobrazu.

brazie małe płyty obszarów rolnych są rozproszone na całym obszarze. W środkowym rzędzie lasy i rolnictwo zajmują podobne powierzchnie, ale ich konfiguracje różnią się. W ostatnim rzędzie, krajobrazy mają najbardziej złożony i zróżnicowany skład z płatami lasów, rolnictwa, krzewów i terenów trawiastych. Krajobraz po lewej stronie ma więcej skupionych (zagregowanych) obszarów w porównaniu do tego po prawej stronie. Wszystkie powyższe krajobrazy reprezentują kategorie pokrycia terenu, jednak mogłyby one przedstawiać dowolne zmienne kategoryzowane, na przykład typy ukształtowania terenu, klasy gleb, a nawet informacje społeczne lub medyczne.

Opisanie tych krajobrazów jest możliwe słowami, jednak jakościowe opisy mają kilka ograniczeń. Po pierwsze, są subiektywne i całkowicie zależne od obserwatora. Tekstowa natura opisu daje nieskończoną liczbę możliwości, ograniczając jego użyteczność. Po drugie, to podejście nie jest odpowiednie w przypadku dużej liczby danych i o ile można stworzyć opisy kilkudziesięciu krajobrazów, o tyle opisywanie setek czy tysięcy krajobrazów jest praktycznie niewykonalne.

W celu numerycznego opisu różnych nieprzestrzennych i przestrzennych właściwości krajobrazów od lat 80-tych XX wieku opracowano dużą liczbę metryk krajobrazowych (ang. *landscape metrics*), zwanych również wskaźnikami krajobrazowymi (O'Neill i in. 1988; Turner i in. 1991; Li i in. 1993; He i in. 2000; Jaeger 2000; Kot i in. 2006; McGarigal 2014). Większość metryk krajobrazowych jest wyrażona za pomocą pojedynczej liczby, opisującej pojedyncze płyty, klasy płatów lub cały krajobraz.

Oprócz prostej numerycznej charakterystyki indywidualnych lokalnych krajobrazów, ich struktury przestrzenne mogą być analizowane za pomocą tzw. metod opartych na strukturach przestrzennych (ang. *pattern-based methods*) (Jasiewicz i in. 2013a; Jasiewicz i in. 2015). Metody oparte na strukturach przestrzennych bazują na dwóch podstawowych elementach: sygnaturze przestrzennej i funkcji niepodobieństwa. Sygnatura przestrzenna jest syntetycznym, statystycznym opisem struktury lokalnego krajobrazu. Zazwyczaj jest to wie-



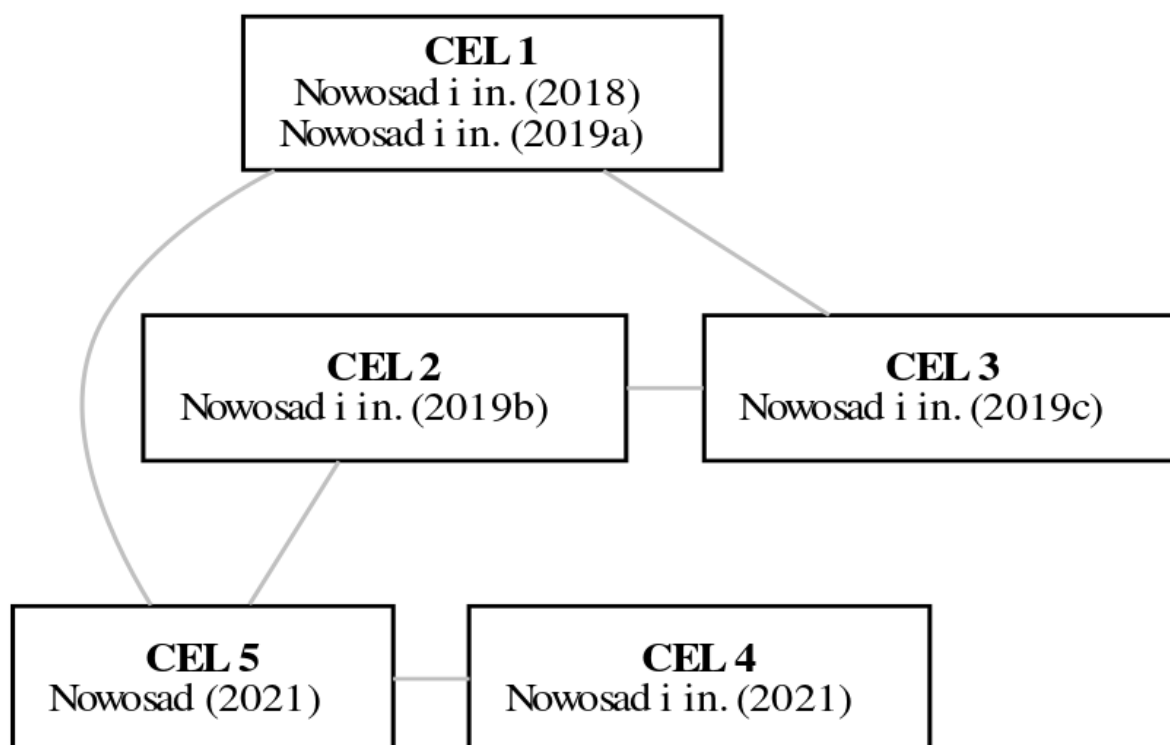
Rycina 1: Przykłady sześciu krajobrazów o zróżnicowanych kompozycjach (wiersze) i konfiguracjach przestrzennych (kolumny)

lowartościowa reprezentacja kompozycji i konfiguracji krajobrazu w formie, która może być wykorzystana do obliczenia podobieństwa pomiędzy różnymi strukturami przestrzennymi. Funkcja niepodobieństwa (zwana również odległością) jest miarą, która przyjmuje sygnatury dwóch struktur przestrzennych (dwóch krajobrazów) i zwraca pojedynczą liczbę, która kwantyfikuje uchylenie stopień niepodobieństwa. Umożliwia to analizę przestrzenną w kilku kontekstach, w tym "jeden do wielu", "jeden do jednego" i "wiele do wielu".

Relacja "jeden do wielu" jest stosowana w zapytaniach przestrzennych (wyszukiwanie oparte na treści, ang. *content-based search*). Wskazywany jest jeden lokalny krajobraz, zwykle reprezentujący stosunkowo mały obszar i na podstawie jego struktury przestrzennej jest obliczana sygnatura przestrzenna. Następnie, większy obszar jest dzielony na zestaw regularnych lub nieregularnych lokalnych krajobrazów, dla których określone są sygnatury przestrzenne. Dalej mierzony jest stopień niepodobieństwa pomiędzy sygnaturą dla pierwszego obszaru i każdego z pozostałych lokalnych krajobrazów, a następnie identyfikowane są te lokalne krajobrazy o najmniejszych wartościach niepodobieństwa. Drugi kontekst, relacja "jeden do jednego", służy do opisu stopnia niepodobieństwa/zmian pomiędzy dwoma zbiorami danych. W tym procesie, dla każdego lokalnego krajobrazu w obu zbiorach danych obliczana jest sygnatura przestrzenna. Następnie wykorzystywana jest jedna z istniejących miar podobieństwa, aby uzyskać wartość końcową reprezentującą jak bardzo różni się lokalna struktura przestrzenna pomiędzy dwoma zbiorami danych. Jednym z możliwych zastosowań w tym kontekście jest opisywanie globalnych zmian we strukturach przestrzennych pokrycia terenu. Relacja "wiele do wielu" może być wykorzystana do grupowania przestrzennego lub segmentacji (Jasiewicz i in. 2014). Obszar badań jest dzielony na zbiór regularnych lub nieregularnych lokalnych krajobrazów, a dla każdego z nich obliczana jest sygnatura przestrzenna. Następnie określa się niepodobieństwo pomiędzy wszystkimi parami lokalnych krajobrazów, a lokalne krajobrazy o niskich wartościach niepodobieństwa są grupowane razem. Ten kontekst może być zastosowany do tworzenia regionalizacji przestrzennych czy klasyfikacji typów krajobrazu.

Obie grupy analiz struktur przestrzennych, tj. (i) metryki krajobrazowe i (ii) metody oparte na strukturach przestrzennych, są powszechnie stosowane na wielu polach naukowych. Posiadają one jednak pewne ograniczenia, uniemożliwiające lub utrudniające ich użycie w kontekstach, takich jak monitorowanie zmian pokrycia terenu czy grupowanie typów krajobrazu. Te ograniczenia to, między innymi, brak uniwersalnych miar opisujących właściwości struktur przestrzennych, niemożliwość tworzenia długoterminowych predykcji zmian krajobrazowych, czy też brak rzetelnego sposobu reprezentowania wielozmiennych struktur przestrzennych. **Głównym celem pracy było zatem opracowanie nowych metod analizy struktur przestrzennych**

pozwalających na badanie zmian pokrycia terenu oraz określanie typów krajobrazów. Cel główny został podzielony na pięć celów szczegółowych opisanych poniżej, a wyniki osiągnięcia zostały przedstawione w sześciu publikacjach (rycina 2).



Rycina 2: Zależności pomiędzy celami szczegółowymi i publikacjami wchodzącymi w skład osiągnięcia

Metryki krajobrazowe, chociaż powszechnie stosowane, posiadają pewne ograniczenia (Kot i in. 2006; Kozak i in. 2014). Każda z metryk krajobrazowych skupia się na specyficznej właściwości danych przestrzennych, jednakże żadna z nich nie może być samodzielnie użyta do pełnego opisu badanego regionu. Dodatkowo, wiele metryk krajobrazowych jest silnie wzajemnie skorelowanych. W kilku badaniach, dla ułatwienia bardziej kompleksowego opisu struktur przestrzennych kategorizowanych danych rastrowych, zastosowano techniki statystyczne, takie jak analiza czynnikowa lub analiza głównych składowych (Riitters i in. 1995; Cushman i in. 2008). Wyniki tych prac jednak zostawiły pewne wątpliwości, szczególnie w kontekście ich uniwersalności. Inny, wskazywany w literaturze problem, to brak wszechstronnej miary różnorodności przestrzennej, która uwzględniałaby zarówno aspekty teoretyczne, jak i praktyczne (Richling i in. 2011). **Dlatego też pierwszym celem szczegółowym osiągnięcia było znalezienie skutecznej metody do uniwersalnego ilościowego opisu struktur przestrzennych.**

Monitorowanie globalnych zmian pokrycia terenu jest ważne ze względu na ich wpływ na środowisko. Zmiany pokrycia terenu są skutkami zmieniającego się klimatu i antropopresji (Balon i in. 1993; Klein Goldewijk i in. 2017), ale też bezpośrednio wpływają na zmiany klimatu

i inne warunki środowiskowe (Bonan 2008; Mahmood i in. 2014; Alkama i in. 2016) oraz mają ścisły związek ze stanem gospodarki i wynikającymi z niego często migracjami ludności (DeFries 2013). Dlatego też ocena zmian pokrycia terenu ma pierwszorzędne znaczenie dla efektywnego planowania i zarządzania zasobami.

Istnieje obszerna literatura dotycząca oceny zmian pokrycia terenu na podstawie obrazów teledetekcyjnych. Najczęściej stosowana metoda wykorzystuje oczko siatki jako podstawową jednostkę analizy (Tewkesbury i in. 2015). Często oceny zmian w skali globalnej koncentrowały się na wykryciu konkretnej przemiany. Do najbardziej znaczących przykładów należy określanie zmian powierzchni zalesionych za pomocą metody bezpośredniego porównania charakterystyk spektralnych oczek siatki (Hansen i in. 2010; Hansen i in. 2013; Kim i in. 2014). Alternatywne, oparte na strukturach przestrzennych, podejście, głównie z powodu braku odpowiednich map pokrycia terenu, było rzadko stosowane. Jednakże to podejście może być z powodzeniem wykorzystane do oceny i wizualizacji zmian terenu dla potrzeb ekologii krajobrazu i badań środowiskowych. Do niedawna globalne produkty pokrycia terenu były wykonywane tylko dla jednego momentu w czasie, a porównanie różnych globalnych produktów pokrycia terenu na przestrzeni wielu lat było niemożliwe z powodu braku jednolitości metodyki ich opracowywania. Sytuacja ta zmieniła się w 2017 roku, kiedy to ESA Climate Change Initiative wydała spójne czasowo globalne produkty pokrycia terenu dla każdego roku od 1992 do 2015 (European Space Agency 2017). W tym kontekście, **drugim celem szczegółowym osiągnięcia było zastosowanie podejścia opartego na strukturach przestrzennych do oceny globalnych zmian pokrycia terenu w okresie podanych wyżej 23 lat (1992-2015).**

Wiedza o zachodzących zmianach pokrycia terenu może być również wykorzystana do przewidywania przyszłych zmian. Jak już wcześniej stwierdziłem, zmiany te są spowodowane w dużej mierze przez antropopresję i dlatego zrozumienie ich dynamiki pomaga w określeniu działań mających na celu złagodzenie szkód dla środowiska (Chhabra i in. 2006). Obecnie dynamika krajobrazu jest rozpatrywana głównie w dwóch kontekstach: teledetekcji i ekologii krajobrazu. Ogólnie rzecz biorąc, w kontekście teledetekcji wykorzystuje się modele pokrycia i użytkowania terenu (ang. *land use/cover change*, LUCC), aby uzyskać krótkoterminowe prognozy zmian pokrycia lub użytkowania terenu (Olmedo i in. 2018). Głównym celem modeli LUCC jest przewidywanie zmian terenu na zasadzie przemian wartości oczek siatki i istnieje wiele wariantów tego typu modeli. Z drugiej strony ekologia krajobrazu stosuje modele krajobrazu (ang. *landscape models*, LM), aby przewidzieć jak zmiana struktury przestrzennej wpływa na procesy ekologiczne (Gaucherel i in. 2009). LM są zaprojektowane tak, aby albo symulować konkretny proces, który powoduje zmianę struktury przestrzennej krajobrazu, albo wykorzystywać

prosty zestaw arbitralnych reguł do symulacji zmian sztucznych krajobrazów, które mają struktury i właściwości statystyczne podobne do już obserwowanych krajobrazów (Gaucherel i in. 2014). Co ważne, istniejące modele zmian pokrycia i użytkowania terenu (LUCC) czy modele krajobrazu (LM), ze względu na konieczność jednoznacznej identyfikacji i liczenia wszystkich sił powodujących zmiany oraz interakcji między nimi, nie są w stanie śledzić ewolucji prawdziwego krajobrazu w dłuższym okresie. Połączenie wyników pierwszego celu, to jest ilościowego opisu struktur przestrzennych, z wynikami drugiego celu, oceny przeszłych globalnych zmian struktur przestrzennych pokrycia terenu, otworzyło nowe możliwości badania dynamiki zmian. **Dlatego też trzecim celem szczegółowym było opracowanie modelu dynamiki krajobrazu, który byłby w stanie przewidywać zmiany w dłuższym okresie.**

Ważne jest aby zauważyć, że do tej pory większość badań opartych na strukturach przestrzennych koncentrowała się na analizie tylko jednej zmiennej w lokalnym krajobrazie (np. pokrycia terenu), co wynikało często z braku ustalonego i nie budzącego wątpliwości sposobu reprezentowania wielozmiennych struktur przestrzennych. Jednakże w przypadku licznych badań geograficznych, wielozmienne struktury przestrzenne mogą być bardziej odpowiednie niż struktury jednej zmiennej.

Wielozmienne struktury mogą być, na przykład, grupowane w celu identyfikacji i klasyfikacji typów krajobrazu (ang. *landscape types*). Typy krajobrazu są podstawą planowania i zarządzania w celu opracowania optymalnych strategii zrównoważonego wykorzystania zasobów (Wascher 2005; Solon 2008; Múcher i in. 2010) i dostarczają informacji o geograficznym zróżnicowaniu bioróżnorodności i procesów ekologicznych (Heikkinen i in. 2004). Jednakże, ze względu na ich złożoność, identyfikacja i mapowanie typów krajobrazu przy użyciu dostępnych danych jest wyzwaniem. Niektóre badania poświęcone identyfikacji i klasyfikacji krajobrazów (Múcher i in. 2010; Sayre i in. 2014) obejmowały kartowania krajobrazów w dużej skali przestrzennej przy użyciu wielozmiennych zbiorów danych, ale były oparte na oczkach siatki zamiast na strukturach przestrzennych. Podejście oparte na pojedynczych oczkach siatki ma w tym kontekście pewne istotne wady. Identyfikuje ono bowiem typy krajobrazów w skali oczka siatki, dlatego jednostki przestrzenne uzyskane z tych metod są jednorodne pod względem kategorii zmiennych wejściowych. Jednakże, wiele rzeczywistych typów krajobrazu, szczególnie tych zdefiniowanych w skali kilku kilometrów lub większej, jest heterogenicznych.

Jak wspomniano wcześniej, metody oparte na strukturach są zbudowane z dwóch podstawowych elementów: sygnatury przestrzennej i funkcji niepodobieństwa. Dlatego też znalezienie efektywnego sposobu reprezentacji danych wielozmiennych za pomocą sygnatury przestrzennej może otworzyć nowe możliwości badawcze, w tym wyszukiwanie podobnych wielozmien-

nych krajobrazów, wykrywanie zmian wielozmiennych i grupowanie wielozmiennych struktur przestrzennych. Zgrupowania struktur wielozmiennych mogą być następnie wykorzystane do określania typów krajobrazu. **Czwartym celem szczegółowym osiągnięcia było opracowanie sygnatury przestrzennej zdolnej do przechowywania informacji o wielozmiennych strukturach przestrzennych i sprawdzenie jej praktycznej przydatności.**

Ponadto, wiele pomysłów przedstawionych powyżej może być użytecznych w badaniach globalnych zmian środowiskowych, zarządzaniu zasobami lądowymi, zrównoważonym rozwoju, ochronie środowiska, zmianach lesistości, monitorowaniu urbanizacji, badaniach ekspansji rolnictwa i innych. Jednak ich zastosowanie byłoby praktycznie niemożliwe bez dedykowanego oprogramowania komputerowego, jako że oprogramowanie do zarządzania, przetwarzania i analizowania danych jest podstawą współczesnych badań naukowych (Wilson i in. 2014). Szczególnie oprogramowanie z licencjami otwartoźródłowymi (ang. *open-source*), które pozwalają na używanie, modyfikowanie i rozpowszechnianie oprogramowania, okazało się być dobrze dopasowane do potrzeb badań naukowych. Oprogramowanie typu open-source ułatwia odtwarzalność badań i pozwala innym naukowcom na ponowne wykorzystanie kodu, czy też rozwój istniejącego oprogramowania. **Ostatnim celem szczegółowym przedstawianego osiągnięcia było opracowanie systemu analitycznego, który umożliwiłoby innym naukowcom zastosowanie analizy opartej na strukturach przestrzennych, oraz wdrożenie go w postaci narzędzia typu open-source.**

4.3.2 Ilościowy opis struktur przestrzennych

Nowosad, J. i T. F. Stepinski (2018). "Global inventory of landscape patterns and latent variables of landscape spatial configuration". Ecological Indicators 89, s.159-167. doi: 10.1016/j.ecolind.2018.02.007

Wyniki badań z prac Riitters i in. (1995) czy Cushman i in. (2008) pokazały kombinacje metryk zdolnych do opisanego różnych atrybutów struktury krajobrazu, ale wykorzystywały jedynie dane o pokryciu terenu dla prostokątnych obszarów położonych w różnych częściach Stanów Zjednoczonych. Pozostawiło to kilka pytań bez odpowiedzi, w tym, na ile uniwersalne są przedstawione kombinacje i ich interpretacje? Próba odpowiedzi na te pytania doprowadziła mnie to do obliczenia i analizy zestawu 39 metryk krajobrazowych dla około 240 tys. obszarów reprezentowanych przez pokrycie terenu w skali globalnej (Nowosad i in. 2018)². W tym celu wykorzystałem produkt ESA Climate Change Initiative Land Cover (CCI-LC) dla roku 2010 z rozdzielczością ~300 metrów na równiku. Zamiast jednak dzielić powierzchnię lądową na

²Odwolania do literatury wchodzącej w skład osiągnięcia przedstawiane są w autoreferacie pogrubioną czcionką.

regularne prostokąty, dane zostały wstępnie przetworzone w inny sposób, przy użyciu metod automatycznej regionalizacji.

W pierwszym kroku globalne dane o pokryciu terenu zostały zregionalizowane na jednostki lądowe o jednorodnych strukturach dla kilku skal przestrzennych (30, 15, 9, 6 km) przy użyciu nowatorskiej techniki segmentacji (Jasiewicz i in. 2018). Rozmiary i kształty powstałych regionów były bardzo zróżnicowane - od małych, bardzo zróżnicowanych krajobrazów o powierzchni 36 km² do dziewięciu regionów o powierzchni ponad 1 mln km², w tym, sześć regionów pustynnych w Afryce, Azji i Australii, łądolodu na Grenlandii, obszarów roślinności krzewiastej w Ameryce Północnej i lasu amazońskiego. Największy procent powierzchni kontynentów, około 1/3, zajmowały regiony o wielkości rzędu 1000 km².

Dla każdego z nowo utworzonych regionów obliczono zestaw 39 metryk krajobrazowych. Powstała w ten sposób baza danych została udostępniona na stronie <https://osf.io/q8dx7/> w celu wsparcia badań związanych z ochroną środowiska, planowaniem przestrzennym i ekologią. Dwadzieścia dwie z otrzymanych metryk reprezentowały udział procentowy powierzchni pokrytej przez poszczególne kategorie pokrycia terenu, podczas gdy pozostałe (17) charakteryzowały właściwości przestrzenno-tematyczne krajobrazów. Teoretycznie możliwe jest obliczenie większej liczby metryk, jednak otrzymane regiony mają różne rozmiary i kształty, dlatego metryki powierzchni (ang. *area metrics*) i niektóre metryki kształtów (ang. *shape metrics*) nie zostały tutaj użyte, bo mogą utrudniać porównanie tych krajobrazów. Następnie na podstawie 17 metryk krajobrazu dla wszystkich otrzymanych regionów obliczono macierz korelacji, którą użyto ją jako dane wejściowe do analizy głównych składowych (PCA) z rotacją VARIMAX.

Główny wynik tego badania pokazał, że pierwsze dwie rotowane składowe główne (ang. *rotated components*, RC) wyjaśniają znaczną część (do ~71%) wariancji danych. Tak duże obciążenia tych dwóch RC umożliwiły interpretację ich wyników. RC1 była pozytywnie skorelowana z wszystkimi wskaźnikami różnorodności i negatywnie skorelowana z wskaźnikiem największego płatu (LPI) i wskaźnikiem zwartości (CONTAG). Tak więc wartość RC1 wzrasta, gdy region ma więcej płatów różnych kategorii i spada, gdy dana jednostka przestrzenna ma mniej płatów różnych kategorii. Z kolei RC2 jest dodatnio skorelowany z miarami agregacji lub łączności, a ujemnie z gęstością płatów (PD). Wartość RC2 wzrasta, gdy komórki tych samych kategorii są bardziej zagregowane w danym regionie. Pierwszy wymiar został zinterpretowany jako miara "złożoności", a drugi jako miara "agregacji".

Globalne regiony były różnorodne, od prostych do złożonych w wymiarze "złożoności" i od zdezagregowanych do zagregowanych w wymiarze "agregacji". Pod względem "złożoności" regiony proste mają zazwyczaj jedną dominującą kategorię, podczas gdy regiony złożone

zawierają kilka głównych kategorii. Pod względem "agregacji" regiony zdezagregowane miały różne kategorie rozłożone na obszarze regionu, a regiony zagregowane miały te same kategorie blisko siebie. To odkrycie pozwala na przyporządkowanie wartości "złożoności" i "agregacji" do każdego regionu na świecie.

Na podstawie uzyskanych wyników można stwierdzić, że 56% powierzchni kontynentów ma struktury przestrzenne pokrycia terenu o niskiej złożoności. Należą do nich lasy, tereny naturalne pozbawione roślinności, obszary ze sporadycznie występującą roślinnością, tereny otwarte, obszary roślinności krzewiastej i tereny trawiaste. Wszystkie one charakteryzują się dużymi areałami przeważnie jednorodnego pokrycia terenu. Ponadto 2/3 z nich pokryte jest zagregowanymi strukturami przestrzennymi. Z drugiej strony, tylko 4,8% powierzchni Ziemi jest pokryte złożonymi strukturami, a złożone, zdezagregowane struktury przestrzenne pokrywają tylko 0,1% powierzchni Ziemi. W ten sposób około 40% powierzchni ładu pokrywają struktury o średniej złożoności, z których zdecydowana większość to również struktury o średniej lub wysokiej agregacji - obszary z przewagą jednej lub dwóch klas pokrycia terenu.

Stworzona metodyka i uzyskane wyniki zostały sprawdzone na dwa różne sposoby. Po pierwsze, wyniki zostały porównane z wcześniejszą pracą Cushman i in. (2008). Pomimo różnic w obu metodykach, stwierdzono zgodność między wynikami obu analiz. Zmienna "złożoność" była związana ze zmiennymi "zwartość/różnorodność" i "dominacja dużych płatów", a zmienna "agregacja" zawierała zmienne "zróżnicowanie granic" i "zmiennność kształtu płatów" z pracy Cushman i in. (2008). W związku z czym wyniki tego badania zgadzały się w dużym stopniu z wynikami Cushman i in. (2008) i wskazywały na to, że mogą one być stosowane w odniesieniu do całego obszaru Ziemi i w wielu skalach przestrzennych. Po drugie, te same kroki (regionalizacja, obliczenia metryki krajobrazu i analiza głównych składowych) zostały powtórzone dla dwóch dodatkowych zbiorów danych: GLC2000 – globalnego pokrycia terenu dla roku 2000 z rozdzielczością 1 kilometra (Bartholomé i in. 2005), oraz NLCD2011 – danych o pokryciu terenu kontynentalnych Stanów Zjednoczonych dla roku 2011 z rozdzielczością 30 metrów (Homer i in. 2015). Wyniki analizy PCA dla GLC2000 i NLCD2011 były bardzo podobne do tych uzyskanych dla CCI-LC. Dwie najwyższe rotowane składowe główne wyjaśniały około 2/3 wariancji, a ich ładunki wskazują, że można je interpretować jako agregację i złożoność. To wskazuje, że wyniki tego badania są wiarygodne i tylko w niewielkim stopniu zależą od konkretnego zestawu danych.

Jednym z głównych, a opisanych powyżej, osiągnięć **Nowosad i in. (2018)** było stwierdzenie, że konfiguracja krajobrazu może być sparametryzowana przez dwie metryki interpretowane jako "złożoność" i "agregacja". Pomysł ten został wykorzystany w publikacji w **Nowosad i in.**

(2019c) jako część składowa nowego empirycznego modelu dynamiki krajobrazu. Jednocześnie jednak metoda określania "złożoności" i "agregacji" wykazała kilka niedogodności i ograniczeń praktycznych.

W podejściu przedstawionym w **Nowosad i in. (2018)** wykorzystano zestaw wysoce skorelowanych metryk krajobrazowych, co wymuszało zastosowanie technik redukcji wymiarowości. W tym przypadku użyto analizę głównych składowych (PCA), jednak interpretacja uzyskanych wyników nie była jednoznaczna i wymagała znacznej znajomości dotyczącej użytych metryk. Mając to na uwadze, najbardziej znaczącym ograniczeniem przedstawionego podejścia jest jednakże konieczność ponownego obliczenia zarówno metryk krajobrazowych, jak i analizy składowych głównych dla każdego nowego zbioru danych. Dodatkowo, podejście to wymaga też, aby każdy nowy zbiór danych był reprezentatywny dla wszystkich możliwych konfiguracji krajobrazu. Na przykład, wyniki PCA oparte na metrykach krajobrazowych dla kilku obszarów w jednym regionie nie mogą być uogólnione na inne regiony, a zatem wartości "złożoności" i "agregacji" dla tych obszarów nie mogą być porównywane z uzyskanymi wartościami "złożoności" i "agregacji" dla innych regionów. Doprowadziło to do postawienia kolejnego pytania: czy można zidentyfikować ogólne miary "złożoności" i "agregacji", które nie wymagają skomplikowanych obliczeń i mogą być zastosowane do każdego krajobrazu, niezależnie od jego wielkości i lokalizacji? Innymi słowy, czy możliwe jest przejście od empirycznych do teoretycznych deskryptorów złożoności krajobrazu?

Nowosad, J. i T. F. Stepinski (2019a). "Information theory as a consistent framework for quantification and classification of landscape patterns". Landscape Ecology 34.9, s. 2091-2101.

doi: 10.1007/s10980-019-00830-x

Dążenie do odpowiedzi na te pytania zaowocowało opracowaniem **Nowosad i in. (2019a)**. Głównym celem tej pracy było wykazanie, że teoria informacji (ang. *information theory*, IT) (Shannon 1948), zastosowana do dwuwymiarowej zmiennej losowej reprezentującej krajobraz, stanowi spójną metodologię ilościową odnoszącą się do wszystkich aspektów analizy struktur przestrzennych.

Rozważmy lokalny krajobraz, w którym każde oczko siatki jest przypisane do jakiejś kategorii ze zbioru c_1, \dots, c_K , gdzie K jest liczbą klas krajobrazu. Podstawowymi jednostkami tej analizy nie są pojedyncze oczka siatki, lecz pary uporządkowanych sąsiednich oczek siatki - dwuwymiarowa zmienna losowa (x, y) przyjmująca wartości (c_i, c_j) , gdzie x jest klasą komórki centralnej, a y jest klasą komórki sąsiedniej. Wykorzystanie przyległych komórek jest najprostszym sposobem uwzględnienia relacji przestrzennych przy analizie struktury przestrzennej. Informacje o sąsiednich komórkach można kompaktowo zapisać w postaci macierzy współwystępowania

(ang. *co-occurrence matrix*) (Haralick i in. 1973). Jest to macierz K na K , która powstaje przez policzenie wszystkich par sąsiadujących komórek w danych. Macierz współwystępowania pozwala na obliczenie pięciu metryk: entropii brzegowej, entropii warunkowej, entropii łącznej, informacji wzajemnej i względnej informacji wzajemnej.

Pierwsza metryka, entropia brzegowa ($H(y)$), przedstawia różnorodność (złożoność tematyczną, kompozycję) kategorii przestrzennych. Oblicza się ją jako entropię rozkładu brzegowego. Krajobrazy z jedną dominującą kategorią mają niskie wartości entropii brzegowej, a wartości te zwiększają się wraz z istnieniem wielu kategorii o podobnych udziałach w powierzchni krajobrazu.

Druga metryka, entropia warunkowa ($H(y|x)$), przedstawia złożoność konfiguracyjną (geometryczną zawilóść) struktury przestrzennej. Jeżeli wartość entropii warunkowej jest mała, to komórki jednej kategorii w przeważającej mierze sąsiadują tylko z jedną kategorią komórek. Z drugiej strony, wysoka wartość entropii warunkowej pokazuje, że komórki jednej kategorii sąsiadują z komórkami wielu różnych kategorii. W szczególności wyniki pokazały, że różnorodność kategorii (entropia brzegowa) wymusza złożoność konfiguracyjną (entropia warunkowa).

Trzecia metryka, entropia łączna ($H(x, y)$), jest ogólną metryką złożoności przestrzenno-tematycznej. Przedstawia ona niepewność w określeniu kategorii komórki centralnej i kategorii komórki sąsiedniej. Innymi słowy, mierzy ona różnorodność wartości w macierzy współwystępowania - im mniejsza różnorodność, tym większa wartość entropii łącznej. Jednakże sama entropia wspólna nie jest w stanie wystarczająco zróżnicować sytuacji z przestrzennie zagregowanymi wartościami od sytuacji, które są przestrzennie zdezagregowane.

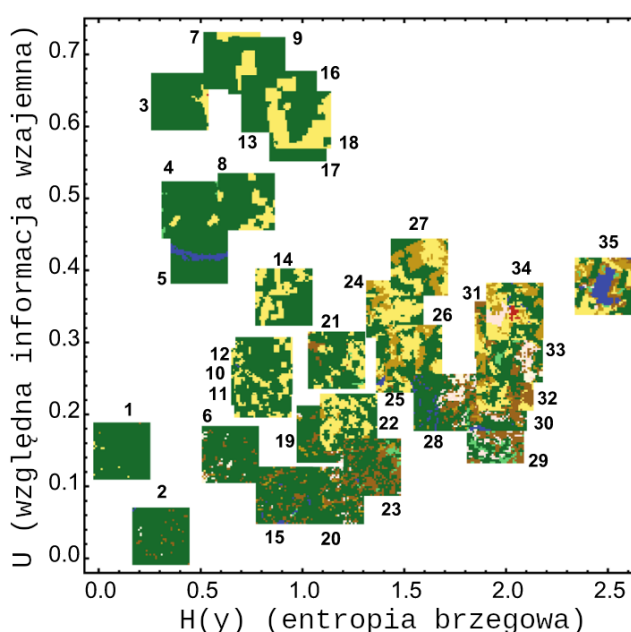
Czwarta metryka, informacja wzajemna ($I(y, x)$), określa ilościowo informację, którą jedna zmienna losowa dostarcza o innej zmiennej losowej. Mówi o tym, o ile łatwiej jest przewidzieć kategorię sąsiedniej komórki, jeżeli znana jest kategoria komórki centralnej. Informacja wzajemna rozróżnia struktury przestrzenne, które charakteryzują się tą samą wartością ogólnej złożoności. Większe wartości wskazują, że komórki tej samej kategorii są bardziej zagregowane, podczas gdy mniejsze wartości wskazują na dezagregację.

Ze względu na autokorelację przestrzenną, wartość informacji wzajemnej ma tendencję do wzrostu wraz z różnorodnością krajobrazu (entropia brzegowa). Aby skorygować tę tendencję, można obliczyć względną informację wzajemną (U) dzieląc informację wzajemną przez entropię brzegową. Względna informacja wzajemna ma zawsze zakres od 0 do 1 i może być wykorzystana do porównania danych przestrzennych o różnej liczbie i rozkładzie kategorii. Względna informacja wzajemna porządkuje krajobrazy od najmniej zagregowanego do najbardziej zagregowanego

bez względu na liczbę lub rozkład kategorii.

Wartości tych metryk, wraz z wcześniej wyprowadzonymi na podstawie PCA “złożonością” i “agregacją” (Nowosad i in. 2018), zostały obliczone dla ponad 1,7 mln rzeczywistych mezoskalowych krajobrazów (9x9km). Wykazano, że uporządkowanie wartości $H(y)$, $H(y|x)$ i $H(x, y)$ jest silnie skorelowane, potwierdzając tym samym, że w prawdziwych krajobrazach różnorodność wymusza złożoność. Z drugiej strony, dwie metryki informacji wzajemnej, $I(y, x)$ i szczególnie U były słabo skorelowane z metrykami $H(y)$, $H(y|x)$ i $H(x, y)$, co sugeruje, że informacja wzajemna dostarcza przeważnie niezależny, dodatkowy kanał informacji o strukturze przestrzennej.

“Złożoność” oparta na PCA okazała się być umiarkowanie skorelowana z $H(y)$, $H(y|x)$ i $H(x, y)$, podczas gdy “agregacja” oparta na PCA była umiarkowanie skorelowana z $I(y, x)$ i U . Wyniki zasugerowały, że $H(y)$ i U można wykorzystać do dwuwymiarowej klasyfikacji konfiguracji krajobrazów, ponieważ są one najmniej skorelowane ze wszystkich metryk opartych o teorię informacji. Ta klasyfikacja 2D grupuje podobne struktury w odrębne regiony przestrzeni parametrów i stanowi podstawę do podziału krajobrazów na typy konfiguracji struktur przestrzennych (rycina 3). Aby ułatwić obliczanie wyprowadzonych metryk i klasyfikację konfiguracji krajobrazów, wszystkie te metryki dodano do pakietu R *landscapemetrics* (Hesselbarth i in. 2019).



Rycina 3: Uporządkowanie przykładowych krajobrazów według entropii brzegowej ($H(y)$) i względnej informacji wzajemnej (U)

Badanie to wniosło kilka nowych elementów do teorii kwantyfikacji struktur przestrzennych. Po pierwsze, wykazało, że podstawowe właściwości struktur przestrzennych mogą być wyznaczone w ramach teorii informacji stosowanej do dwuwymiarowej zmiennej losowej. Po drugie, pokazało, że uporządkowanie krajobrazów według wartości pojedynczej metryki nie może dać sekwencji ciągle zmieniających się struktur przestrzennych. Po trzecie, potwierdzono obserwację, że w rzeczywistych krajobrazach różnorodność wymusza złożoność. Po czwarte, wykazano, że dwie słabo skorelowane metryki z teorii informacji pozwalają uporządkować

krajobrazy w taki sposób, że krajobrazy o podobnych konfiguracjach znajdują się w pobliskich miejscach na diagramie 2D, a tym samym stanowią podstawę do klasyfikacji krajobrazów na typy konfiguracji struktur przestrzennych.

4.3.3 Globalne zmiany pokrycia terenu

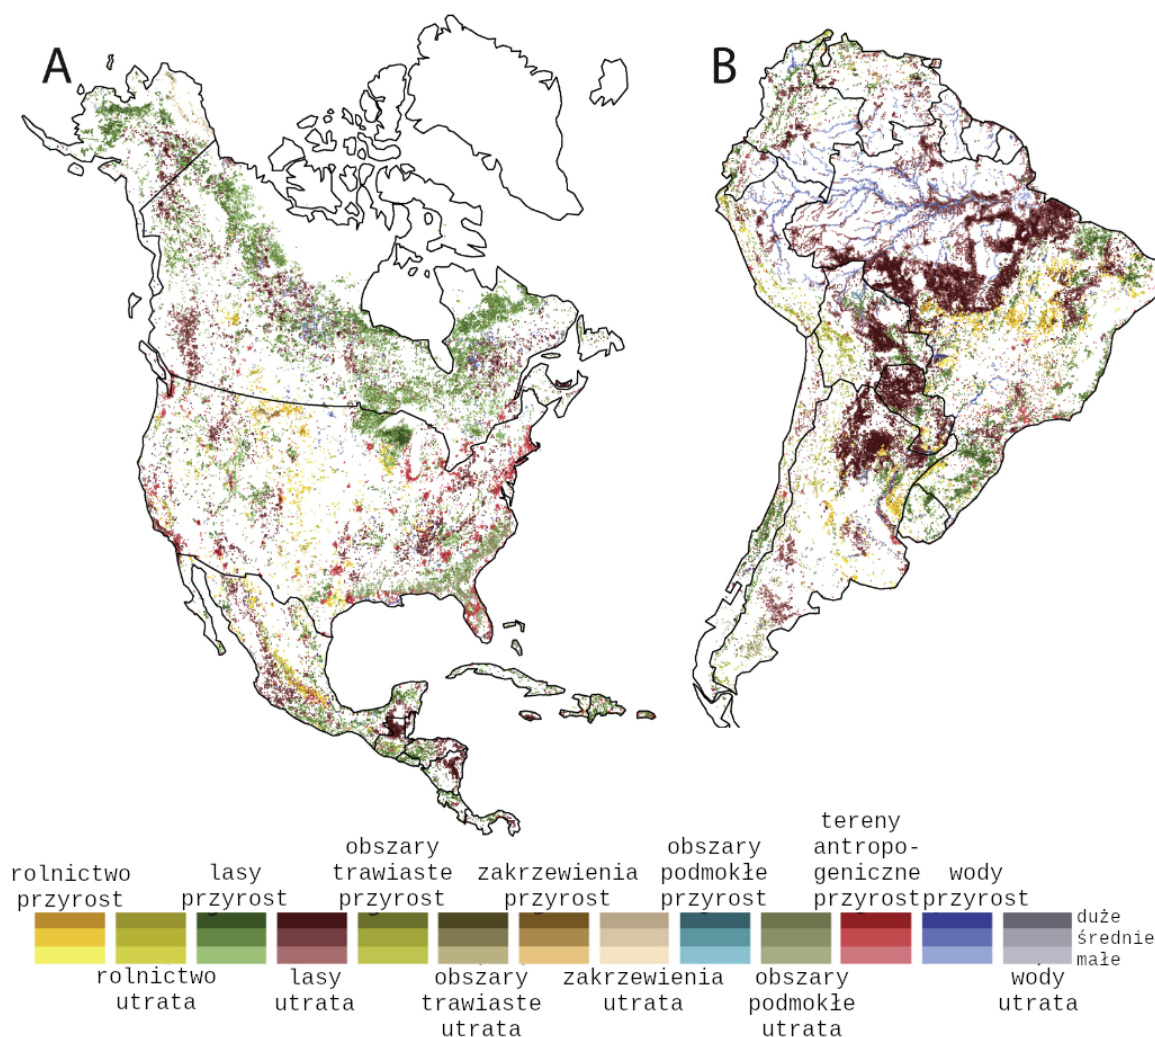
Nowosad, J., T. F. Stepinski i P. Netzel (2019b). "Global assessment and mapping of changes in mesoscale landscapes: 1992–2015". International Journal of Applied Earth Observation and Geoinformation 78, s. 332-340. doi: 10.1016/j.jag.2018.09.013

Udostępnienie spójnych czasowo produktów pokrycia terenu dla każdego roku od 1992 do 2015 przez ESA Climate Change Initiative umożliwiło ocenę globalnych zmian pokrycia terenu w okresie 23 lat (Nowosad i in. 2019b). Globalne zbiory danych o pokryciu terenu dla lat 1992 i 2015 zostały przez mnie uproszczone do dziewięciu kategorii IPCC (Intergovernmental Panel on Climate Change) i przekształcone do projekcji Fullera w celu zminimalizowania zniekształceń. Następnie obie mapy zostały podzielone na nienakładające się kwadratowe obszary o wielkości 9 na 9 kilometrów (30×30 pikseli), aby objąć znaczące mezoskalowe krajobrazy. Wyniki tego badania umożliwiły stworzenie trzech warstw informacji o zmianach globalnych, które różnią się poziomem szczegółowości. Cała baza danych GIS dotycząca zmian krajobrazów i utworzona mapa trendów jest dostępna do pobrania na stronie <https://osf.io/34g9c/>.

Pierwszą stworzoną warstwą informacji jest wielkość zmiany każdego krajobrazu w okresie 23 lat. Zmiana lokalnego krajobrazu została zmierzona jako różnica pomiędzy strukturami przestrzennymi kategorii pokrycia terenu w 1992 roku i strukturami tych kategorii w 2015 roku. Powstała mapa zwizualizowała obszary zmian w krajobrazie, nie precyzując charakteru tych zmian. Globalnie, zgodnie z przyjętą definicją, około 22% obszaru planety uległo znaczącej zmianie w tym okresie. W 62% zmienionych obszarów uległo zmianie mniej niż 10% powierzchni. W 26% zmienionych obszarów zmieniło się od 10% do 30% powierzchni. W zaledwie 12% zmienionych obszarów zmieniło się więcej niż 30% ich powierzchni.

Druga warstwa informacji przedstawia skład oraz macierz przejścia kategorii CCI-LC dla każdego ze zmienionych krajobrazów między 1992 a 2015 rokiem. Dla dziewięciu kategorii pokrycia terenu mogły istnieć potencjalnie 72 rodzaje przejść. W badanym okresie największe zyski netto stwierdzono dla terenów rolnych (+758 tys. km²) i antropogenicznych (+337 tys. km²), natomiast największe straty netto stwierdzono dla lasów (-436 tys. km²) i obszarów roślinności krzewiastej (-289 tys. km²).

Wreszcie, trzecia warstwa informacji podaje trendy zmian. Macierze przejść dostarczają dogłębnych informacji o zmianach terenu, ale nie nadają się do wizualizacji zmian globalnych.



Rycina 4: Mapa trendów zmian krajobrazowych w latach 1992-2015 dla Ameryki Północnej (A) i Ameryki Południowej (B). Krajobrazy lokalne są oznaczone kolorami w zależności od trajektorii zmian i procentu zmienionej powierzchni: małe (<10%), średnie (10-30%) i duże (>30%). Obszary dla których nie zaszły znaczące zmiany są oznaczone kolorem białym.

Trend zmian jest uogólnionym, pojedynczym deskryptorem charakteru zmian dla całego lokalnego krajobrazu. Każdemu krajobrazowi został przypisany jeden z kilku możliwych trendów zmian, dzięki czemu informacje te można przedstawić w skali globalnej. Celem takiej wizualizacji było stworzenie prostej, pojedynczej mapy przeglądowej pokazującej co i gdzie się zmieniło w okresie 1992-2015. Aby uzyskać przejrzystą wizualizację zmian, przejścia zostały arbitralnie sklasyfikowane do zaledwie 13 "trendów zmian": przyrost terenów rolnych, utrata terenów rolnych, przyrost lasów, utrata lasów, przyrost terenów trawiastych, utrata terenów trawiastych, przyrost zakrzaczeń, utrata zakrzaczeń, przyrost terenów podmokłych, utrata terenów podmokłych, przyrost terenów antropogenicznych, przyrost obszarów wodnych i utrata tych obszarów. W rezultacie powstała globalna mapa zmian, która reprezentuje rozkład przestrzenny różnych zmian terenu na jednej wizualizacji - kompaktowe podsumowanie tego,

co, gdzie i w jakim stopniu zmieniło się między 1992 a 2015 rokiem (rycina 4). Dla globalnej mapy zmian krajobrazu, każdemu z obszarów został przypisany kolor na podstawie trendu zmian i procentu zmienionych oczek siatki. Obszary, w których odsetek ten wyniósł >30% zostały zaklasyfikowane jako "duża zmiana", obszary, w których odsetek ten wyniósł od 10% do 30% zostały zaklasyfikowane jako "średnia zmiana", a obszary, w których odsetek ten wyniósł poniżej 10% zostały zaklasyfikowane jako "mała zmiana". W sumie na mapie przedstawiono 39 kategorii, z których każda była kombinacją trendu zmian opisującego rodzaj zmiany i procentu powierzchni obszaru, który uległ zmianie wskazującego na intensywność zmiany.

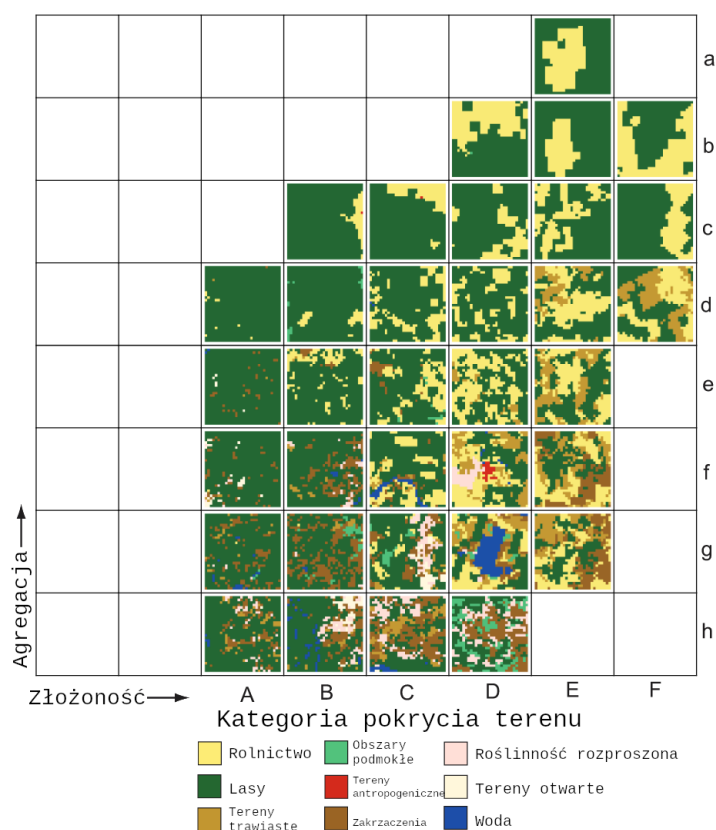
4.3.4 Model dynamiki zmian krajobrazowych

Nowosad, J. i T. F. Stepinski (2019c). "Stochastic, empirically informed model of landscape dynamics and its application to deforestation scenarios". Geophysical Research Letters 46.23, s. 13845-13852. doi: 10.1029/2019GL085952

Pomysły i wyniki z badań **Nowosad i in. (2019b)** i **Nowosad i in. (2018)** umożliwiły stworzenie stochastycznego, opartego na danych empirycznych modelu dynamiki zmian krajobrazowych (**Nowosad i in. 2019c**). Ten nowy model może pozwolić na lepsze zrozumienie np. ewolucji krajobrazu od całkowicie pokrytego lasem do całkowicie pokrytego rolnictwem - procesu, który prowadzi do deforestacji. Jakie są najbardziej prawdopodobne etapy pośrednie takiego przejścia? Czy niektóre ścieżki ewolucyjne są bardziej prawdopodobne niż inne?

Model powstał poprzez podzielenie całej powierzchni lądowej na ponad 1,7 mln mezoskalowych krajobrazów. Każdy mezoskalowy krajobraz miał rozmiar 9×9 km i zawierał strukturę przestrzenną utworzoną przez dziewięć klas pokrycia terenu. Następnie, każdy krajobraz został scharakteryzowany przez jego konfigurację i kompozycję w latach 1992 i 2015. Konfiguracja krajobrazu została sparametryzowana za pomocą dwóch metryk interpretowanych jako "złożoność" i "agregacja", jak określono w pracy **Nowosad i in. (2018)**. W celu uproszczenia stworzonego zbioru danych, wszystkie krajobrazy zostały sklasyfikowane do 36 typów krajobrazów (z 64 teoretycznie możliwych) w odniesieniu do ich konfiguracji (rycina 5). Ta dwuwymiarowa klasyfikacja bierze pod uwagę wartości "złożoności" i "agregacji", ale nie zawartość tematyczną (kompozycję) krajobrazu. W kolejnym kroku obliczono częstotliwość występowania każdego typu konfiguracji, co wykazało, że typ Bd (niska złożoność, umiarkowanie zagregowany) jest najczęstszy (42% wszystkich krajobrazów). Opracowane podejście pozwoliło na stworzenie różnych podzbiorów tematycznych wszystkich krajobrazów. W tych podzbiórach tematycznych archetypy są wybierane na podstawie tego, jaka klasa pokrycia terenu stanowi największy udział w powierzchni krajobrazu. Na przykład, rycina 5 pokazuje podzbiór tematyczny obszarów

leśnych.



Rycina 5: Przykłady typów krajobrazów wybranych z podzbioru wszystkich krajobrazów o tematyce leśnej dla możliwych grup 'złożoności' i 'agregacji'

zów podmokłych.

Szansa na każde przejście między poszczególnymi typami złożoności została zapisana w macierzy przejść. Zawierała ona wartości prawdopodobieństwa przejścia z jednego typu złożoności do drugiego w okresie 23 lat. Analiza macierzy przejść zasugerowała, że większość typów krajobrazów może ewoluować na wiele różnych sposobów (pod względem zmian wartości metryk złożoności i agregacji), ale z różnym prawdopodobieństwem. Pokazało to również, że krajobrazy typu Bd (które są prawie jednorodne) są długotrwałymi stabilnymi konfiguracjami, podczas gdy inne krajobrazy są relatywnie krócej żyjącymi, a więc mniej stabilnymi konfiguracjami.

Stworzony stochastyczny model ewolucji krajobrazu klasyfikuje interesujący nas krajobraz do określonego typu i dostarcza zestaw przejść oraz odpowiadających im prawdopodobieństw obliczonych na podstawie częstotliwości typów przejść. Następnie, wielokrotne zastosowanie

Porównanie typów konfiguracji dla każdego krajobrazu pomiędzy 1992 i 2015 rokiem pozwoliło określić, że niektóre typy są bardziej stabilne, a niektóre bardziej podatne na zmiany. Spośród 1,7 mln krajobrazów znajdujących się w bazie danych, tylko 257 tys. (15%) przeszło transformację (przekształciło się z jednego typu do drugiego) w ciągu badanego okresu 23 lat. Ogólnie rzecz biorąc, statystyki krajobrazów sugerują, że prawie jednorodna konfiguracja była najbardziej rozpowszechniona i jednocześnie najbardziej trwała dla sześciu z ośmiu rozpatrywanych podzbiorów tematycznych (podzbiór obszarów wodnych został pominięty). Wyjątkami były podzbiory tematyczne krajobrazów antropogenicznych i krajobra-

tej procedury przy użyciu metody Monte Carlo tworzy trajektorie ewolucji krajobrazu pod względem zmian typu konfiguracji krajobrazu. Na każdym etapie przejście z aktualnego etapu do następnego jest wybierane losowo zgodnie z rozkładem prawdopodobieństwa przejść, aż krajobraz rozwinie się do danego typu lub nastąpi określona liczba etapów. Powyższa idea może być przeprowadzona dla każdego z podzbiorów tematycznych.

W tym opracowaniu jako przykład działania modelu został wykorzystany proces wylesiania. Konkretnie skupiono się na zastąpieniu lasu przez rolnicze pokrycie terenu (przejście las -> rolnictwo; ang. *forest* -> *agriculture transit*, FAT). Model rozpoczynał się od krajobrazu w pełni zalesionego i kończył na krajobrazie w pełni rolniczym - ta sekwencja jest określana jako trajektoria. Każda trajektoria FAT może być podzielona na dwie fazy, fazę z przewagą lasu (FAT1) i fazę z przewagą rolnictwa (FAT2). Aby zbudować model dla FAT1, podzbiór wszystkich krajobrazów został poddany następującym warunkom: las i rolnictwo były odpowiednio podstawową i drugą dominującą klasą pokrycia terenu w 1992 i 2015 roku, a przejścia w latach 1992-2015 przebiegały w kierunku zmniejszającego się udziału lasu. W celu zbudowania modelu dla FAT2, podzbiór wszystkich krajobrazów podlegał następującym warunkom: rolnictwo i las były podstawową i drugą dominującą klasą pokrycia terenu w 1992 i 2015 roku, a w latach 1992-2015 następowały zmiany w kierunku rosnącego udziału rolnictwa.

W pierwszej części symulacja rozpoczynała się od prawie całkowicie zalesionego krajobrazu (typ Ad) i była przeprowadzana do momentu, kiedy krajobraz ewoluował do typu Fb lub Fc. W drugiej części, przejścia wykorzystywały część modelu FAT2, a symulacja kończyła się, gdy trajektoria osiągała jeden z krajobrazów przy lewej krawędzi diagramu "złożoność"- "agregacja". W sumie obliczono 20 tys. możliwych trajektorii FAT.

Trajektorie wykazały różne poziomy prawdopodobieństwa wystąpienia. Najbardziej możliwa trajektoria przebiegała przez serię pośrednich krajobrazów charakteryzujących się wysoce zagregowanymi mozaikami leśno-rolniczymi z malejącym udziałem lasów. Potrzeba było pięciu etapów (zmian typów złożoności), aby przejść z krajobrazu całkowicie zalesionego (Ad) do Fb, krajobrazu zajętego przez las tylko w około połowie. Następnie, gdy udział lasów spadł poniżej 50%, pozostała część przejścia była szybka - potrzeba było tylko trzech etapów, aby przejść z Fb do krajobrazu w pełni rolniczego. Sugeruje to, że możliwa polityka ochrony zasobów powinna polegać na ochronie mezoskalowej obszarów o wysokiej lesistości (>50%) aby nie dopuścić do gwałtownego wylesiania gdy udział lasów spadnie poniżej 50%.

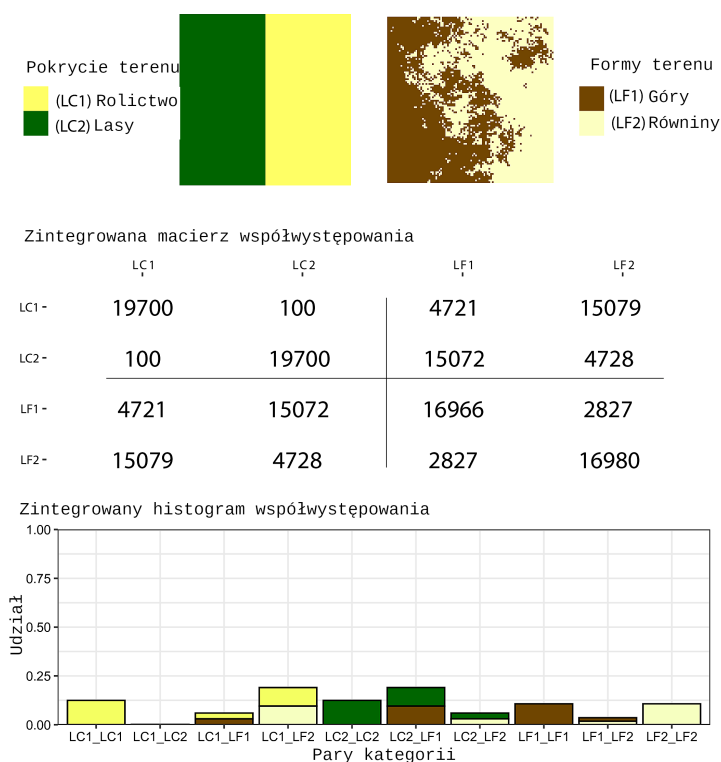
Stworzona metoda okazała się być najbardziej odpowiednia do badania scenariuszy ewolucyjnych dla konkretnych rodzajów zmian pokrycia terenu, takich jak wylesianie, pustyńnienie czy urbanizacja. Jej główną zaletą jest empiryczny charakter. Dzięki temu nie jest konieczne

jednoznaczne uwzględnienie wszystkich procesów odpowiedzialnych za zmianę terenu, ponieważ są one pośrednio uwzględnione przez dużą liczbę statystyk, przy użyciu metodologii, która przypomina uczenie maszynowe. Główną wadą modelu jest to, że wymaga on (w obecnej implementacji) pewnych silnych założeń: czasowej stacjonarności macierzy przejścia oraz zależności od uzyskanych globalnych statystyk. Rolą tego badania było wprowadzenie idei stochastycznego, opartego na empirycznych danych modelu wykorzystującego najdłuższy okres (23 lata) dostępny w bazie CCI-LC, aby zmaksymalizować liczbę przejść, na podstawie których można było zbudować model. Jednakże, przyszłe prace mogą analizować modele zbudowane na podstawie 1-5 letnich okresów przejściowych. Wreszcie, za pomocą tego modelu mogą być badane scenariusze zmian inne niż FAT. Jest to kwestia wyboru odpowiedniego podzbioru zbioru danych. Pustynnienie może być badane poprzez rozważenie przejść tereny trawiaste -> obszary ze sporadycznie występującą roślinnością, tereny trawiaste -> tereny pozbawione roślinności oraz obszary ze sporadycznie występującą roślinnością-> tereny pozbawione roślinności. Urbanizacja może być badana poprzez rozważenie przejść od rolnictwa, lasów, obszarów roślinności krzewiastej i obszarów ze sporadycznie występującą roślinnością do terenów antropogenicznych. Kurczenie się terenów podmokłych można badać na podstawie przejść tereny podmokłe->rolnictwo.

4.3.5 Sygnatura dla wielozmiennych struktur przestrzennych

Nowosad, J. i T. F. Stepinski (2021). "Pattern-based identification and mapping of landscape types using multi-thematic data". International Journal of Geographical Information Science. doi: 10.1080/13658816.2021.1893324

Opisana wcześniej macierz współwystępowania (ang. *co-occurrence matrix*, COMA) okazała się odpowiednia jako przestrzenna sygnatura jednozmiennych struktur przestrzennych. Celem pracy Nowosad i in. (2021) było rozszerzenie metody tworzenia macierzy współwystępowania, aby móc reprezentować wielozmienne struktury przestrzenne. Praca ta wprowadza rozszerzenie sygnatury macierzy współwystępowania do numerycznej reprezentacji wielozmiennych struktur przestrzennych danych kategoryzowanych zwane zintegrowaną macierzą współwystępowania (ang. *integrated co-occurrence matrix*, INCOMA) (rycina 6). INCOMA bazuje na pomysłach z dziedziny rozpoznawania obrazu (Vadivel i in. 2007) i tabelarycznie przedstawia powiązania wewnątrz zmiennych i pomiędzy zmiennymi w danych rastrowych. W ten sposób zawiera nie tylko informacje o strukturach przestrzennych wszystkich zmiennych, ale również informacje o względnych pozycjach różnych struktur.



Rycina 6: Dwuzmienna struktura przestrzenna (góra) oraz dwie formy jej sygnatury, zintegrowana macierz współwystępowania - INCOMA (środek) i znormalizowany histogram (dół). W środkowym panelu narysowane są linie wskazujące na blokową strukturę INCOMA

INCOMA jest zbudowana z bloków, przy czym każdy blok sam w sobie stanowi macierz współwystępowania (COMA) (rycina 6). Bloki po przekątnej przedstawiają macierz współwystępowania (COMA) odpowiednio dla zmiennej 1 i zmiennej 2. Bloki poza przekątną są COMA obliczone z sąsiednich par komórek, gdzie komórka centralna używa swojej etykiety kategorii zmiennej 1, a komórka sąsiednia używa swojej etykiety kategorii zmiennej 2. Rozszerzenie INCOMA na więcej niż dwie zmienne jest możliwe, gdzie przy n zmiennych INCOMA ma n^2 bloków. Jeżeli zmienne mają różną liczbę klas, to

bloki diagonalne miałyby różne rozmiary, ale zachowałyby kwadratowe kształty, bloki poza diagonalne miałyby różne rozmiary i prostokątne kształty. Jednakże cała INCOMA nadal miałaby kształt kwadratu z wielkością równą sumie M klas kategorycznych we wszystkich zmiennych $M = m_1 + m_2 + m_n$. Znormalizowana INCOMA, tak że suma wszystkich składowych we wszystkich jej blokach jest równa 1, daje się sprowadzić do jednowymiarowego histogramu z $(M^2 + M)/2$ wartościami (rycina 6). Dzięki temu jest to dobrze zdefiniowany obiekt wejściowy dla wyszukiwania, porównywania i grupowania opartego na strukturach przestrzennych.

Wielozmienne struktury opisane za pomocą INCOMA mogą być, na przykład, wykorzystane do identyfikacji i klasyfikacji typów krajobrazu (ang. *landscape types*, LT), ponieważ wiele warstw (zmiennych), w tym topografia, pokrycie terenu, klimat i gleba/geologia, składają się na charakter krajobrazu. Aby zademonstrować przydatność INCOMA do identyfikacji i mapowania LT, metoda ta została zastosowana dla obszaru Europy przy użyciu dwóch zmiennych - pokrycia terenu (ang. *land cover*, LC) i ukształtowania terenu (ang. *landform*, LF).

W efekcie zidentyfikowano 12 typów krajobrazu, a jakość tej delimitacji oceniono obliczając średnie niepodobieństwo między wielozmiennymi strukturami przestrzennymi wewnątrz każ-

dej strefy (im mniejsza wartość, tym lepiej) oraz średnie niepodobieństwo między strukturami wielozmiennymi w różnych strefach (im większa wartość, tym lepiej). Mapa wynikowa została porównana z (a) mapą otrzymaną przez nałożenie map LC i LF, co skutkowało stworzeniem 130 LTs, oraz (b) metodą, która najpierw przeprowadza oddzielnie delimitację struktur przestrzennych LC i LF za pomocą COMA, a następnie nałożenie na siebie dwóch map struktur LC i LF. Porównanie wykazuje, że spośród trzech metod tylko INCOMA może bez nadzoru i bez dodatkowego opracowania stworzyć delineację, która obejmuje strefy charakteryzujące się prostymi wielozmiennymi strukturami przestrzennymi (np. zbiory lokalnych krajobrazów z przeważnie jednorodnym pokryciem terenu i formami ukształtowania terenu), jak również strefy charakteryzujące się złożonymi strukturami wielozmiennymi (np. zbiory lokalnych krajobrazów z przeważnie niejednorodnym pokryciem terenu i formami ukształtowania terenu).

4.3.6 System analityczny do analizy przestrzennej opartej na strukturach przestrzennych

Nowosad, J. (2021). "Motif: an open-source R tool for pattern-based spatial analysis".
Landscape Ecology 36, s.29-43. doi: 10.1007/s10980-020-01135-0

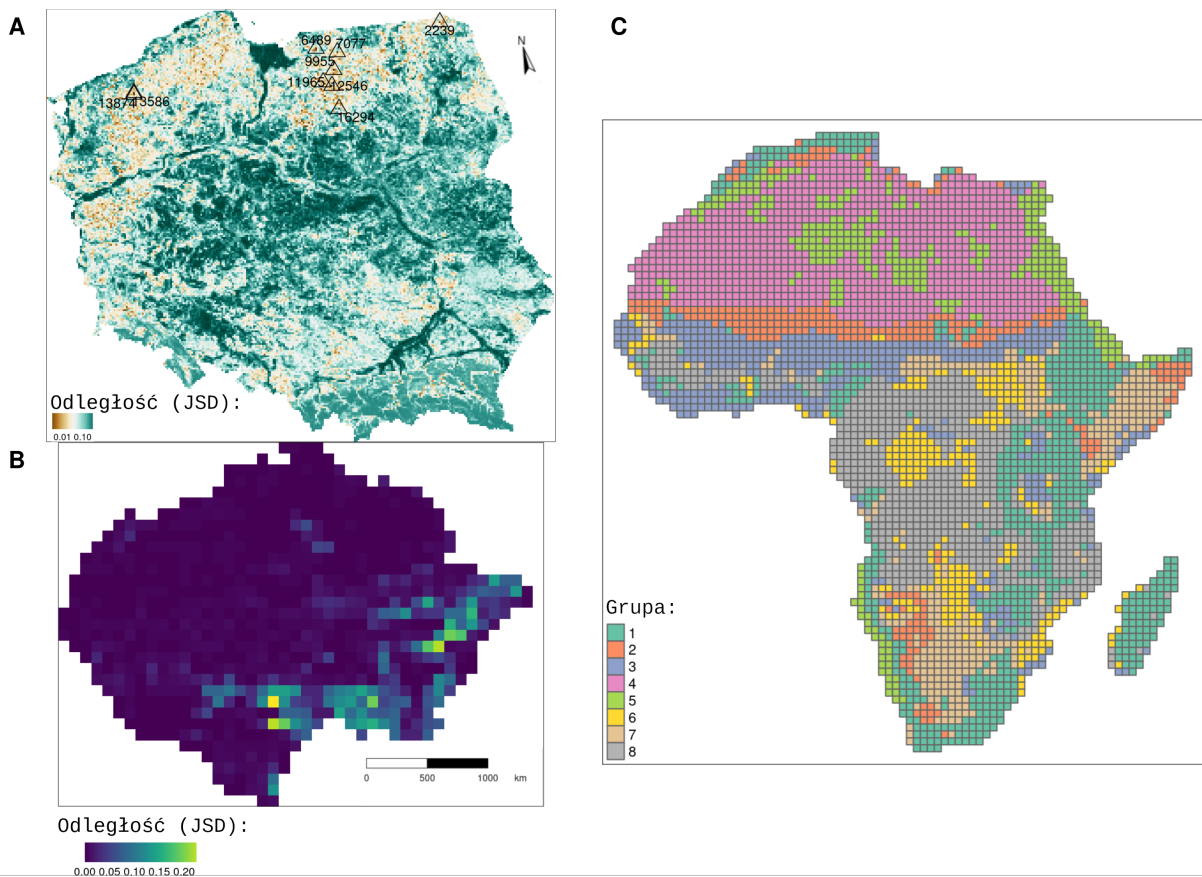
Wiele koncepcji wprowadzonych w powyższych badaniach można zastosować do rozwiązania innych problemów naukowych. Z tego powodu został zaprojektowany nowy system analityczny (Nowosad 2021), który opiera się na głównych ideach opracowanych w poprzednich badaniach niniejszego osiągnięcia naukowego i rozszerza metodologię stojącą za analizą opartą na strukturach przestrzennych (Jasiewicz i in. 2015; Netzel i in. 2018). Pozwala on, używając kategoryzowanych danych rastrowych, między innymi, na obliczanie różnorodnych sygnatur przestrzennych, na pracę ze strukturami wielozmiennymi, wykrywanie zmian w strukturach przestrzennych czy grupowanie obszarów o podobnych strukturach. Jednym z głównych założeń projektowania tego systemu była jego łatwa rozszerzalność, pozwalająca na dodawanie nowych sygnatur czy wybór wielu funkcji niepodobieństwa. Dodatkowo ważna była wydajność tego systemu, umożliwiająca obliczenia na wysokorodzielczych danych w skali kontynentalnej czy globalnej.

Zaprojektowany system analityczny został następnie zaimplementowany jako otwartoźródłowy pakiet R **motif** (<https://cran.r-project.org/package=motif>). Do realizacji tego zadania wykorzystano język programowania R (R Core Team 2020), ponieważ sprawdził się on jako podstawowe narzędzie w wielu dziedzinach nauki, które opierają się na danych przestrzennych i strukturach danych przestrzennych, w tym różnych poddziedzinach ekologii (Sciaini i in. 2018; Lai i in. 2019), statystyki przestrzennej i geoinformacji (Lovelace i in. 2019). Pakiet **motif** jest w pełni wieloplatformowy, działa na maszynach Windows, Linux i macOS. Duża liczba

istniejących pakietów R pozwala na wykorzystanie pakietu **motif** nie tylko jako samodzielnego narzędzia, ale również jako elementu bardziej złożonych analiz. Pakiet ten jest zbudowany przy wykorzystaniu popularnych klas obiektów przestrzennych R, takich jak **stars** i **sf** (Pebesma 2021; Pebesma 2018) i dlatego każde dane wejściowe do niego mogą być wcześniej przygotowane w R, jak również wszystkie wyniki obliczeń mogą być dalej wykorzystywane i modyfikowane przy użyciu istniejących narzędzi. Utrzymywanie znacznej większości lub wszystkich obliczeń w jednym zestawie narzędzi zapewnia większą powtarzalność i odtwarzalność oraz stanowi kluczowy element walidacji badań naukowych (Lovelace i in. 2019). Wymagające obliczeniowo fragmenty oprogramowania zostały napisane w języku C++ (Eddelbuettel i in. 2011), co wraz z obsługą danych większych niż dostępna pamięć operacyjna (RAM), pozwala na pracę na rastrach o wysokiej rozdzielczości lub danych w skali kontynentalnej lub globalnej. Oprogramowanie to zostało zaprojektowane do działania na współczesnych laptopach, jest w pełni operacyjne, a jego funkcjonalność została przetestowana na globalnych zestawach danych zawierających kilka miliardów komórek.

Pakiet **motif** posiada kilka wbudowanych sygnatur przestrzennych, w tym proporcje kategorii w lokalnym krajobrazie, macierz współwystępowania i histogram współwystępowania, ważoną macierz/histogram współwystępowania (Dmowska i in. 2020), oraz zintegrowaną macierz/histogram współwystępowania (Nowosad i in. 2021). Dodatkowo przyjmuje on funkcje zdefiniowane przez użytkownika, co pozwala na tworzenie nowych sygnatur przestrzennych. Sygnatury przestrzenne mogą być obliczane zarówno dla obszarów regularnych, jak i nieregularnych. W celu porównania struktur przestrzennych pomiędzy lokalnymi krajobrazami, pakiet pozwala na zastosowanie 46 miar niepodobieństwa, w tym Jensena-Shannona, Wave-Hedgessa lub odległości Jaccarda (Lin 1991; Cha 2007). Główne funkcje tego pakietu umożliwiają różnego rodzaju analizy przestrzenne oparte na strukturach przestrzennych, takie jak wyszukiwanie, porównywanie (wykrywanie zmian) i grupowanie. Pakiet **motif** posiada również kilka dodatkowych możliwości, które pozwalają na dalsze przetwarzanie wyników analizy opartej na strukturach czy obliczanie jakości grupowania opartego na strukturach przestrzennych.

Zaprojektowany system analityczny zastosowano do czterech studiów przypadku (Nowosad 2021). W pierwszym studium przypadku pokazano, jak na przykładzie danych o pokryciu terenu Nowej Gwinei można uzyskać sygnatury przestrzenne dla regularnych (kwadratowych) i nieregularnych lokalnych krajobrazów. Drugie studium przypadku miało na celu znalezienie obszarów o podobnej topografii do terenu Suwalskiego Parku Krajobrazowego. W tym celu stworzono raster geomorfonów (Jasiewicz i in. 2013b) Polski, klasyfikując każde oczko siatki do jednego z dziesięciu typów ukształtowania terenu. Obszar Polski został podzielony na kilka



Rycina 7: Wyniki studiów przypadków analiz opartych na strukturach przestrzennych: (A) wyszukiwanie obszarów o podobnej topografii do obszaru Suwalskiego Parku Krajobrazowego z najbardziej podobnymi obszarami pokolorowanymi na ciemnobrązowo; (B) wykrywanie zmian pokrycia terenu w regionie Amazonii z żółtymi obszarami wskazującymi na największe zmiany; (C) grupowanie regionów w Afryce o podobnych strukturach przestrzennych pokrycia terenu i form terenu

tysięcy lokalnych krajobrazów, a następnie obliczono sygnaturę przestrzenną (znormalizowany histogram współwystępowania) dla obszaru Suwalskiego Parku Krajobrazowego i każdego lokalnego krajobrazu. Dalej, sygnatura regionu zapytania została porównana z sygnaturami dla każdego z lokalnych krajobrazów przy użyciu miary odległości. Wyniki pokazały, że najbardziej podobne obszary znajdują się w północnej Polsce i tworzą pas o jednorodnej topografii (rycina 7:A). W trzecim studium przypadku porównano jak zmieniło się pokrycie terenu dla regionu Amazonii od 1992 do 2018 roku. W tym postępowaniu region ten został podzielony na dużą liczbę lokalnych krajobrazów i dla każdego lokalnego krajobrazu obliczono odległość pomiędzy przestrzennymi sygnaturami pokrycia terenu w 1992 i 2018 roku. Wyniki dostarczają ogólnego obrazu zmian pokrycia terenu dla regionu Amazonii, przy czym obszary najbardziej znaczących zmian znajdują się w południowej i wschodniej części regionu (rycina 7:B). Regiony pokryte w 1992 roku głównie lasami są obecnie w znacznym stopniu zastąpione przez rozległe obszary rolnicze. Ostatnie studium przypadku zidentyfikowało regiony w Afryce z podobnymi strukturami przestrzennymi pokrycia terenu i form terenu. Znormalizowany zintegrowany

histogram współwystępowania został pozyskany jako sygnatura dla około 4 tys. lokalnych krajobrazów, a pomiędzy każdą parą lokalnych krajobrazów obliczono odległość. Następnie zastosowano hierarchiczne grupowanie metodą Warda, aby wyodrębnić osiem głównych grup (rycina 7:C). Została także obliczona, pod względem wewnętrznej homogeniczności i izolacji międzygrupowej, jakość każdego zgrupowania, a każde zgrupowanie zostało zinterpretowane na podstawie przestrzennych struktur kategorii pokrycia terenu i ukształtowania terenu. Kompletny kod i dane do odtworzenia wszystkich studiów przypadku zostały udostępnione na stronie <https://github.com/Nowosad/motif-examples>.

4.3.7 Podsumowanie

Opisane powyżej badania zostały opublikowane jako cykl sześciu powiązanych tematycznie publikacji (Nowosad i in. 2018, Nowosad i in. 2019a, Nowosad i in. 2019b, Nowosad i in. 2019c Nowosad i in. 2021, Nowosad 2021), które są razem przedstawione jako osiągnięcie naukowe pod tytułem **“Metody analizy struktur przestrzennych i ich zastosowanie w badaniach geograficznych”**. Bazuje ono na istniejących badaniach struktur przestrzennych i rozszerza je w kierunku ilościowego opisu jedno- i wielozmiennych struktur, oceny i przewidywania globalnych zmian pokrycia terenu oraz dostarcza solidnych narzędzi komputerowych dla przyszłych badań. Osiągnięcie składa się z nowatorskich pomysłów i metod, praktycznych sugestii, empirycznie potwierdzonych modeli, nowych globalnych zbiorów danych oraz otwartoźródłowego oprogramowania. Najważniejsze, moim zdaniem, dokonania tego osiągnięcia to:

Dokonania metodyczne

- Opracowanie stochastycznego, opartego na danych empirycznych modelu dynamiki krajobrazu, pozwalającego na lepsze zrozumienie długotrwałych procesów zmian pokrycia terenu.
- Wprowadzenie nowej metody, zintegrowanej macierzy współwystępowania (INCOMA), zdolnej do reprezentowania wielozmiennych struktur przestrzennych i pozwalającej na analizę danych opartą na strukturach wielozmiennych.

Dokonania poznawcze

- Sformalizowanie, że konfiguracja krajobrazów na całym świecie może być sparametryzowana empirycznie przy użyciu dwóch metryk, interpretowanych jako “złożoność” i “agregacja”, pochodzących z analizy składowych głównych istniejących metryk krajobrazu.

- Wykazanie, że podstawowe właściwości struktur przestrzennych mogą być kwantyfikowane w ramach teorii informacji w zastosowaniu do dwuwymiarowej zmiennej losowej.
- Teoretyczne potwierdzenie, że w różnorodność krajobrazów determinuje ich złożoność.
- Pokazanie, że wartości jedynie jednej metryki nie są w stanie uporządkować krajobrazów do postaci serii o stale zmieniających się strukturach.
- Przedstawienie, że dwie słabo skorelowane metryki z teorii informacji pozwalają na uniwersalne przedstawienie złożoności i agregacji struktur przestrzennych.

Praktyczne sugestie

- Zastosowanie stworzonego modelu do zbadania możliwych scenariuszy wylesiania, co doprowadziło do wniosku, że ewentualna polityka ochrony przyrody powinna polegać na ochronie mezoskalowych połączy terenu, zanim udział lasów spadnie poniżej 50%.

Zbiory danych

- Stworzenie bazy danych regionów o spójnych strukturach przestrzennych pokrycia terenu wraz z powiązаныmi metrykami krajobrazu oraz scharakteryzowanie struktur pokrycia terenu na całym świecie.
- Wygenerowanie trzech warstw informacji o globalnych zmianach pokrycia terenu w latach 1992 - 2015: (a) wielkości zmian, (b) macierzy przejścia kategorii pokrycia terenu i (c) trendu zmian.

Oprogramowanie

- Opracowanie systemu analitycznego i zaimplementowanie go w postaci otwartoźródłowego narzędzia pozwalającego na zastosowanie analiz opartych na (jedno- i wielozmiennych) strukturach przestrzennych, takich jak wyszukiwanie, wykrywanie zmian i grupowanie.

Wiele z przedstawionych wyników i pomysłów znalazło już zainteresowanie w środowisku naukowym, o czym świadczą ich cytowania. Najczęściej okazały się one przydatne w ekologii krajobrazu, geografii, geoinformacji i badaniach zmian globalnych, ale również niektóre koncepcje okazały się odpowiednie w innych, bardziej odległych dyscyplinach, takich jak nauki medyczne (Kendall i in. 2020). Dodatkowo, niektóre wyniki okazały się przemawiać do szerszego grona odbiorców. Wyniki badania **Nowosad i in. (2019b)** zostały odnotowane przez różne media w kilku językach, w tym angielskim, hiszpańskim, niemieckim, włoskim i portugalskim. Także

rozmaite media przedstawiły wyniki pracy **Nowosad i in. (2019c)** w języku angielskim, hiszpańskim, włoskim, francuskim, szwedzkim i koreańskim. Mapa globalnych trendów pokrycia terenu została również włączona jako warstwa do portalu OpenLandMap, gdzie można ją znaleźć pod adresem https://openlandmap.org/#/?layer=ldg_landscape.degradation_sil.9km_c.

Literatura cytowana w opisie osiągnięcia naukowego

1. Alberti, M., D. Booth, K. Hill, B. Coburn, C. Avolio i in. (2007). "The Impact of Urban Patterns on Aquatic Ecosystems: An Empirical Analysis in Puget Lowland Sub-Basins". *Landscape and Urban Planning* 80.4, s. 345–361. doi: 10.1016/j.landurbplan.2006.08.001.
2. Alkama, R. i A. Cescatti (2016). "Biophysical Climate Impacts of Recent Changes in Global Forest Cover". *Science* 351.6273, s. 600–604. doi: 10/f8bjpz.
3. Balon, J. i H. Malara (1993). "Wpływ Człowieka Na Środowisko Przyrodnicze Ziemi Myślenickiej". *Monografia Ziemi Myślenickiej t. 3*. Kraków: Universitas, s. 117–128.
4. Bartholomé, E. i A. S. Belward (2005). "GLC2000: A New Approach to Global Land Cover Mapping from Earth Observation Data". *International Journal of Remote Sensing* 26.9, s. 1959–1977. doi: 10/cjcr8j.
5. Bonan, G. B. (2008). "Forests and Climate Change: Forcings, Feedbacks, and the Climate Benefits of Forests". *Science* 320.5882, s. 1444–1449. doi: 10/c87j3d.
6. Brinck, K., R. Fischer, J. Groeneveld, S. Lehmann, M. Dantas De Paula i in. (2017). "High Resolution Analysis of Tropical Forest Fragmentation and Its Impact on the Global Carbon Cycle". *Nature Communications* 8.1, s. 14855. doi: 10.1038/ncomms14855.
7. Cha, S.-H. (2007). "Comprehensive Survey on Distance/Similarity Measures between Probability Density Functions". *International Journal of Mathematical Models and Methods in Applied Sciences* 1.4, s. 300–307.
8. Chen, J., J. Chen, A. Liao, X. Cao, L. Chen i in. (2015). "Global Land Cover Mapping at 30m Resolution: A POK-Based Operational Approach". *ISPRS Journal of Photogrammetry and Remote Sensing* 103, s. 7–27. doi: 10/gddhbb.
9. Chhabra, A., H. Geist, R. A. Houghton, H. Haberl, A. K. Braimoh i in. (2006). "Multiple Impacts of Land-Use/Cover Change". *Land-Use and Land-Cover Change*. Red. E. F. Lambin i H. Geist. Berlin, Heidelberg: Springer Berlin Heidelberg, s. 71–116. doi: 10.1007/3-540-32202-7_4.
10. Connors, J. P., C. S. Galletti i W. T. L. Chow (2013). "Landscape Configuration and Urban Heat Island Effects: Assessing the Relationship between Landscape Characteristics and Land Surface Temperature in Phoenix, Arizona". *Landscape Ecology* 28.2, s. 271–283. doi: 10.1007/s10980-012-9833-1.
11. Cushman, S. A., K. McGarigal i M. C. Neel (2008). "Parsimony in Landscape Metrics: Strength, Universality, and Consistency". *Ecological Indicators* 8.5, s. 691–703. doi: 10.1016/j.ecolind.2007.12.002.
12. DeFries, R. S. (2013). "Why Forest Monitoring Matters for People and the Planet". *Global Forest Monitoring from Earth Observation*. Boca Raton: CRC Press, s. 1–14.
13. Dmowska, A., T. F. Stepinski i J. Nowosad (2020). "Racial landscapes – a pattern-based, zoneless method for analysis and visualization of racial topography". *Applied Geography* 122, s. 102239. doi: <https://doi.org/10.1016/j.apgeog.2020.102239>.

14. Eddelbuettel, D. i R. François (2011). "Rcpp: Seamless R and C++ Integration". *Journal of Statistical Software* 40.8, s. 1–18. doi: 10.18637/jss.v040.i08.
15. European Space Agency (2017). *Land Cover CCI Product User Guide Version 2*. Spraw. tech.
16. Eyre, M., S. Rushton, M. Luff i M. Telfer (2004). "Predicting the Distribution of Ground Beetle Species (Coleoptera, Carabidae) in Britain Using Land Cover Variables". *Journal of Environmental Management* 72.3, s. 163–174. doi: 10/czrftv.
17. Gaucherel, C. i T. Houet (2009). "Preface to the Selected Papers on Spatially Explicit Landscape Modelling: Current Practices and Challenges". *Ecological Modelling* 220.24, s. 3477–3480. doi: 10/bj35w9.
18. Gaucherel, C., F. Houllier, D. Auclair i T. Houet (2014). "Dynamic Landscape Modelling: The Quest for a Unifying Theory". *Living Reviews in Landscape Research* 8. doi: 10/ghb9j8.
19. Häger, A., M. Fernández Otárola, M. F. Stuhlmacher, R. Acuña Castillo i A. Contreras Arias (2015). "Effects of Management and Landscape Composition on the Diversity and Structure of Tree Species Assemblages in Coffee Agroforests". *Agriculture, Ecosystems & Environment* 199, s. 43–51. doi: 10.1016/j.agee.2014.08.022.
20. Hansen, M. C., P. V. Potapov, R. Moore, M. Hancher, S. A. Turubanova i in. (2013). "High-Resolution Global Maps of 21st-Century Forest Cover Change". *Science* 342.6160, s. 850–853. doi: 10/f5h5c2.
21. Hansen, M. C., S. V. Stehman i P. V. Potapov (2010). "Quantification of Global Gross Forest Cover Loss". *Proceedings of the National Academy of Sciences* 107.19, s. 8650–8655. doi: 10/fcps38.
22. Haralick, R. M., K. Shanmugam i I. Dinstein (1973). "Textural Features for Image Classification". *IEEE Transactions on Systems, Man, and Cybernetics* SMC-3.6, s. 610–621.
23. He, H. S., B. E. DeZonia i D. J. Mladenoff (2000). "An Aggregation Index (AI) to Quantify Spatial Patterns of Landscapes". *Landscape Ecology* 15, s. 591–601.
24. Heikkinen, R. K., M. Luoto, R. Virkkala i K. Rainio (2004). "Effects of Habitat Cover, Landscape Structure and Spatial Variables on the Abundance of Birds in an Agricultural-Forest Mosaic: Birds in an Agricultural-Forest Mosaic". *Journal of Applied Ecology* 41.5, s. 824–835. doi: 10/bkbmb9.
25. Hesselbarth, M. H. K., M. Sciaini, K. A. With, K. Wiegand i J. Nowosad (2019). "landscapemetrics : an open-source R tool to calculate landscape metrics". *Ecography* 42.10, s. 1648–1657. doi: 10.1111/ecog.04617.
26. Homer, C., J. Dewitz, L. Yang, S. Jin, P. Danielson i in. (2015). "Completion of the 2011 National Land Cover Database for the Conterminous United States—Representing a Decade of Land Cover Change Information". *Photogrammetric Engineering & Remote Sensing* 81.5, s. 345–354.
27. Jaeger, J. A. G. (2000). "Landscape Division, Splitting Index, and Effective Mesh Size: New Measures of Landscape Fragmentation". *Landscape Ecology* 15, s. 115–130.
28. Jasiewicz, J., P. Netzel i T. F. Stepinski (2014). "Landscape Similarity, Retrieval, and Machine Mapping of Physiographic Units". *Geomorphology* 221, s. 104–112. doi: 10.1016/j.geomorph.2014.06.011.
29. Jasiewicz, J. i T. F. Stepinski (2013a). "Example-Based Retrieval of Alike Land-Cover Scenes From NLCD2006 Database". *IEEE Geoscience and Remote Sensing Letters* 10.1, s. 155–159. doi: 10/gjnqqx.
30. Jasiewicz, J., P. Netzel i T. Stepinski (2015). "GeoPAT: A Toolbox for Pattern-Based Information Retrieval from Large Geospatial Databases". *Computers & Geosciences* 80, s. 62–73. doi: 10.1016/j.cageo.2015.04.002.
31. Jasiewicz, J., T. Stepinski i J. Niesterowicz (2018). "Multi-Scale Segmentation Algorithm for Pattern-Based Partitioning of Large Categorical Rasters". *Computers & Geosciences* 118, s. 122–130. doi: 10.1016/j.cageo.2018.06.003.

32. Jasiewicz, J. i T. F. Stepinski (2013b). "Geomorphons — a Pattern Recognition Approach to Classification and Mapping of Landforms". *Geomorphology* 182, s. 147–156. doi: 10.1016/j.geomorph.2012.11.005.
33. Kendall, T. J., C. M. Duff, A. M. Thomson i J. P. Iredale (2020). "Integration of geoscience frameworks into digital pathology analysis permits quantification of microarchitectural relationships in histological landscapes". *Scientific Reports* 10.1, s. 1–16.
34. Kim, D.-H., J. O. Sexton, P. Noojipady, C. Huang, A. Anand i in. (2014). "Global, Landsat-Based Forest-Cover Change from 1990 to 2000". *Remote Sensing of Environment* 155, s. 178–193. doi: 10/f6rt32.
35. Klein Goldewijk, K., A. Beusen, J. Doelman i E. Stehfest (2017). "Anthropogenic Land Use Estimates for the Holocene – HYDE 3.2". *Earth System Science Data* 9.2, s. 927–953. doi: 10/ggkp2j.
36. Kot, R. i K. Lesniak (2006). "Ocena georóżnorodności za pomocą miar krajobrazowych-podstawowe trudności metodyczne". *Przegląd Geograficzny. Polska Akademia Nauk* 78.1, s. 25–45.
37. Kozak, J., M. Luc, K. Ostapowicz i E. Ziółkowska (2014). "Pozyskiwanie i analiza danych o pokryciu terenu a badania struktury przestrzennej krajobrazu". *Struktura środowiska przyrodniczego a fizjonomia krajobrazu*. Red. W. Ziąja i M. Jodłowski. Kraków: Instytut Geografii i Gospodarki Przestrzennej Uniwersytetu Jagiellońskiego, s. 23.
38. Lai, J., C. J. Lortie, R. A. Muenchen, J. Yang i K. Ma (2019). "Evaluating the Popularity of R in Ecology". *Ecosphere* 10.1. doi: 10.1002/ecs2.2567.
39. Li, H. i J. F. Reynolds (1993). "A New Contagion Index to Quantify Spatial Patterns of Landscapes". *Landscape Ecology* 8.3, s. 155–162. doi: 10.1007/BF00125347.
40. Lin, J. (1991). "Divergence Measures Based on the Shannon Entropy". *IEEE Transactions on Information Theory* 37.1, s. 145–151.
41. Lovelace, R., J. Nowosad i J. Muenchow (2019). *Geocomputation with R*. CRC Press (Taylor & Francis Group).
42. Luoto, M., R. K. Heikkinen, J. Pöyry i K. Saarinen (2006). "Determinants of the Biogeographical Distribution of Butterflies in Boreal Regions". *Journal of Biogeography* 33.10, s. 1764–1778. doi: 10/fmh934.
43. Mahmood, R., R. A. Pielke, K. G. Hubbard, D. Niyogi, P. A. Dirmeyer i in. (2014). "Land Cover Changes and Their Biogeophysical Effects on Climate". *International Journal of Climatology* 34.4, s. 929–953. doi: 10/gfvc8f.
44. McGarigal, K. (2014). "Landscape Pattern Metrics". *Wiley StatsRef: Statistics Reference Online*, s. 13.
45. Múcher, C. A., J. A. Klijn, D. M. Wascher i J. H. Schaminée (2010). "A new European Landscape Classification (LANMAP): A transparent, flexible and user-oriented methodology to distinguish landscapes". *Ecological indicators* 10(1), s. 87–103.
46. Netzel, P., J. Nowosad, J. Jasiewicz, J. Niesterowicz i T. F. Stepinski (2018). *GeoPAT 2: User's Manual*. Spraw. tech.
47. Nowosad, J. i T. F. Stepinski (2019a). "Information theory as a consistent framework for quantification and classification of landscape patterns". *Landscape Ecology* 34.9, s. 2091–2101. doi: 10.1007/s10980-019-00830-x.
48. Nowosad, J., T. F. Stepinski i P. Netzel (2019b). "Global assessment and mapping of changes in mesoscale landscapes: 1992–2015". *International Journal of Applied Earth Observation and Geoinformation* 78, s. 332–340. doi: 10.1016/j.jag.2018.09.013.
49. Nowosad, J. i T. F. Stepinski (2019c). "Stochastic, empirically informed model of landscape dynamics and its application to deforestation scenarios". *Geophysical Research Letters* 46.23, s. 13845–13852. doi: 10.1029/2019GL085952.

50. Nowosad, J. (2021). "Motif: an open-source R tool for pattern-based spatial analysis". *Landscape Ecology* 36, s. 29–43. doi: 10.1007/s10980-020-01135-0.
51. Nowosad, J. i T. F. Stepinski (2021). "Pattern-based identification and mapping of landscape types using multi-thematic data". *International Journal of Geographical Information Science*. doi: 10.1080/13658816.2021.1893324.
52. Nowosad, J. i T. F. Stepinski (2018). "Global inventory of landscape patterns and latent variables of landscape spatial configuration". *Ecological Indicators* 89, s. 159–167. doi: 10.1016/j.ecolind.2018.02.007.
53. O'Neill, R. V., J. R. Krummel, R. H. Gardner, G. Sugihara, B. Jackson i in. (1988). "Indices of Landscape Pattern". *Landscape Ecology* 1.3, s. 153–162. doi: 10.1007/BF00162741.
54. Olmedo, M. T. C., M. Paegelow, J.-F. Mas i F. Escobar, red. (2018). *Geomatic Approaches for Modeling Land Change Scenarios*. Springer International Publishing. doi: 10.1007/978-3-319-60801-3.
55. Omernik, J. M. i G. E. Griffith (2014). "Ecoregions of the Conterminous United States: Evolution of a Hierarchical Spatial Framework". *Environmental Management* 54.6, s. 1249–1266. doi: 10.1007/s00267-014-0364-1.
56. Pebesma, E. (2018). "Simple Features for R: Standardized Support for Spatial Vector Data". *The R Journal* 10.1, s. 439–446. doi: 10.32614/RJ-2018-009.
57. Pebesma, E. (2021). *stars: Spatiotemporal Arrays, Raster and Vector Data Cubes*. R package version 0.5-1.
58. Pietrzak, M. (2010). *Podstawy i Zastosowania Ekologii Krajobrazu – Teoria i Metodologia*. Leszno: Państwowa Wyższa Szkoła Zawodowa im. J. A. Komeńskiego.
59. R Core Team (2020). *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing. Vienna, Austria.
60. Richling, A. (2009). "Perspektywy rozwoju ekologii krajobrazu". *Problemy ekologii krajobrazu* XXIII.
61. Richling, A. i J. Solon (2011). *Ekologia Krajobrazu*. Wydawnictwo Naukowe PWN.
62. Riitters, K. H., R. V. O'Neill, C. T. Hunsaker, J. D. Wickham, D. H. Yankee i in. (1995). "A Factor Analysis of Landscape Pattern and Structure Metrics". *Landscape Ecology* 10.1, s. 23–39. doi: 10.1007/BF00158551.
63. Riitters, K. (2011). *Spatial Patterns of Land Cover in the United States: A Technical Document Supporting the Forest Service 2010 RPA Assessment*. Spraw. tech. SRS-136. Asheville: NC: Department of Agriculture Forest Service, Southern Research Station, s. 1–64.
64. Riitters, K., J. Wickham, R. O. Neill, B. Jones i E. Smith (2000). "Global-Scale Patterns of Forest Fragmentation". *Conservation Ecology* 4.2, s. 3. doi: Artn3.
65. Sayre, R., J. Dangermond, C. Frye, R. Vaughan, P. Aniello i in. (2014). *A new map of global ecological land units – an ecophysiological stratification approach*. Spraw. tech. Washington, DC: Association of American Geographers.
66. Sciaini, M., M. Fritsch, C. Scherer i C. E. Simpkins (2018). "NLMR and Landscapetools: An Integrated Environment for Simulating and Modifying Neutral Landscape Models in R". *Methods in Ecology and Evolution* 9.11. Red. N. Golding, s. 2240–2248. doi: 10.1111/2041-210X.13076.
67. Shannon, C. E. (1948). "A Mathematical Theory of Communication". *The Bell System Technical Journal* 27.3, s. 379–423. doi: 10.1002/j.1538-7305.1948.tb01338.x.
68. Solon, J. (2002). *Ocena różnorodności krajobrazu na podstawie analizy struktury przestrzennej roślinności*. T. Prace Geograficzne = Geographical Studies / Polska Akademia Nauk. Instytut Geografii i Przestrzennego Zagospodarowania im. Stanisława Leszczyńskiego. IGiPZ PAN.

69. Solon, J. (2008). "Przegląd wybranych podejść do typologii krajobrazu". *Problemy Ekologii Krajobrazu*, s. 10.
70. Tewkesbury, A. P., A. J. Comber, N. J. Tate, A. Lamb i P. F. Fisher (2015). "A Critical Synthesis of Remotely Sensed Optical Image Change Detection Techniques". *Remote Sensing of Environment* 160, s. 1–14. doi: 10/f655gz.
71. Tsendbazar, N., S. de Bruin i M. Herold (2015). "Assessing Global Land Cover Reference Datasets for Different User Communities". *ISPRS Journal of Photogrammetry and Remote Sensing* 103, s. 93–114. doi: 10.1016/j.isprsjprs.2014.02.008.
72. Turner, M. G. i R. H. Gardner (1991). *Quantitative Methods in Landscape Ecology: the Analysis and Interpretation of Landscape Heterogeneity*. Springer-Verlag New York.
73. Vadivel, A., S. Sural i A. Majumdar (2007). "An Integrated Color and Intensity Co-Occurrence Matrix". *Pattern Recognition Letters* 28.8, s. 974–983. doi: 10.1016/j.patrec.2007.01.004.
74. Wascher, D. M. (2005). *European landscape character areas: typologies, cartography and indicators for the assessment of sustainable landscapes (No. 1254)*. Spraw. tech.
75. Wickham, J. D. i D. J. Norton (1994). "Mapping and Analyzing Landscape Patterns". *Landscape Ecology* 9.1, s. 7–23. doi: 10/fwz5bm.
76. Wilson, G., D. Aruliah, C. Brown, N. Chue Hong, M. Davis i in. (2014). "Best practices for scientific computing". *PLoS Biology* 12.1. Red. J. Eisen, e1001745. doi: 10.1371/journal.pbio.1001745.

5 Informacja o wykazywaniu się istotną aktywnością naukową albo artystyczną realizowaną w więcej niż jednej uczelni, instytucji naukowej lub instytucji kultury, w szczególności zagranicznej

Uzyskałem tytuł magistra i stopień doktora na Uniwersytecie im. Adama Mickiewicza, odpowiednio w 2012 i 2016 roku. Moja rozprawa doktorska koncentrowała się na czasoprzestrzennym przewidywaniu stężeń pyłku roślin wywołujących alergię przy użyciu metod uczenia maszynowego i GIS. Po ukończeniu doktoratu zostałem postdokiem (ang. *Postdoctoral Fellow*) w Space Informatics Lab na Uniwersytecie w Cincinnati, gdzie pracowałem nad opracowaniem i wdrażaniem metod automatycznej segmentacji i klastrowania globalnych ekoregionów. Od 2018 roku jestem adiunktem w Zakładzie Geoinformacji na Uniwersytecie im. Adama Mickiewicza, gdzie pracuję głównie na styku geoinformacji i nauk o środowisku. Z jednej strony, moje badania koncentrują się na rozwoju i stosowaniu metod analiz przestrzennych w celu poszerzenia zrozumienia procesów i prawidłowości zachodzących w środowisku. Z drugiej strony, tworzę, współpracuję i ulepszam metody oraz oprogramowanie geoinformacyjne. Dodatkowo, brałem udział w różnych interdyscyplinarnych projektach w zakresie protokołów poprawnego pozyskiwania danych o odbiciach spektralnych gleb, prognozowania fenologii, możliwości adaptacji algorytmów do oceny jakości wody czy określania segregacji i różnorodności rasowej.

Geoinformacja

Jednym z najważniejszych osiągnięć w mojej karierze naukowej jest publikacja książki **Geocomputation with R (Lovelace i in. 2019)**. Książka ta, będąca wynikiem współpracy z Robinem Lovelace z Uniwersytetu w Leeds i Jannesem Muenchowem z Uniwersytetu w Jenie, ma na celu zestawienie oraz opis narzędzi i sposobów pracy związanych z analizą danych przestrzennych. Nie tylko wyjaśnia przetwarzanie danych, wizualizację i możliwości geoinformacyjne języka R, ale również dostarcza trzy rozbudowane przykłady zastosowań: w planowaniu transportu, geomarketingu i ekologii. Książka została wydana w systemie hybrydowym - w twardej i miękkiej oprawie przez Taylor and Francis Group oraz w otwartym dostępie na stronie internetowej <https://geocompr.github.io/>. O przydatności książki świadczy zarejestrowanie ponad 400 tys. unikalnych czytelników wersji online książki. Książka została również wykorzystana w kilku kursach uniwersyteckich jako literatura obowiązkowa lub zalecana. Należy do nich "ESPM 288: Reproducible and Collaborative Data Science" na Uniwersytecie Kalifornijskim w Berkeley, "CRD 298: Spatial Methods in Community Research" na Uniwersytecie

Kalifornijskim w Davis, "GEOG5927M: Predictive Analytics" na Uniwersytecie w Leeds oraz "ECS530 Analysing spatial data" w NHH Norwegian School of Economics.

Prezentowałem swoje badania związane z geoinformacją na kilku krajowych i międzynarodowych konferencjach (tabela 1). **Zostałem również zaproszony do wygłoszenia wystąpienia (ang. *keynote speech*) pod tytułem "The landscape of spatial data analysis in R" na konferencji Why R? 2019.**

Tabela 1: Wystąpienia konferencyjne związane z geoinformacją

Data	Autorzy	Tytuł	Konferencja	Miejsce
2019-09-28	Jakub Nowosad	The landscape of spatial data analysis in R	Why R? 2019	Warszawa
2019-07-12	Jakub Nowosad, Robin Lovelace, Jannes Muenchow	How to win friends and write an open-source book	useR! 2019	Tuluza
2019-06-26	Jakub Nowosad	Integracja pomiędzy QGISem a R	II spotkanie użytkowników QGIS	Poznań
2019-03-21	Jakub Nowosad	Język programowania R jako wolne oprogramowanie geoinformacyjne	VII Forum BioGIS	Poznań
2018-05-14	Bartosz Czernecki, Jakub Nowosad	What is the best place to be? Location optimization with R and Google Maps	eRum 2018	Budapeszt
2014-10-16	Jakub Nowosad	Wizualizacja danych przestrzennych w R - od map statycznych do interaktywnych	Polski Akademicki Zlot Użytkowników R	Poznań

Automatyczne ekoregionalizacje

Moje umiejętności i wiedza związane z analizą danych przestrzennych znalazły zastosowanie w pracach nad metodami segmentacji przestrzennych w celu określenia ekoregionów w skali globalnej. **Byłem współautorem opartej na danych metody globalnej regionalizacji ekofizjograficznej używającej lokalnych struktur przestrzennych pokrycia terenu (Nowosad**

i in. 2018c). W tych badaniach stosowałem techniki zgłębiania danych (ang. *data mining*) i analizę opartą na strukturach przestrzennych do bardzo dużych globalnych zbiorów danych w celu regionalizacji kontynentów w jednostki przestrzenne charakteryzujące się jednorodnymi strukturami pokrycia terenu, gleb, stref klimatycznych i form terenu. Jednostki lądowe w nowej regionalizacji okazały się bardziej homogeniczne niż te w istniejących ekoregionalizacjach. Opracowanie tej pracy i jej wyniki zostały przedstawione na ICC w Waszyngtonie, Geocomputation 2007 w Leeds oraz na 2017 AGU Fall Meeting w Nowym Orleanie (tabela 2). W 2019 roku otrzymałem grant *MINIATURA* z Narodowego Centrum Nauki, aby kontynuować prace nad automatyczną regionalizacją opartą na strukturach przestrzennych.

Podczas prac nad globalnymi regionalizacjami konieczne było porównanie, jak automatycznie utworzone regiony są podobne do innych istniejących ekoregionalizacji. Ten problem rozwiązałem **adaptując metodę V-measure, stosowaną wcześniej do oceny podobieństwa między zgrupowaniami, do badania przestrzennego powiązania między mapami (Nowosad i in. 2018b).**

Tabela 2: Wystąpienia konferencyjne związane z automatycznymi ekoregionalizacjami

Data	Autorzy	Tytuł	Konferencja	Miejsce
2017-12-12	Jakub Nowosad, Tomasz F. Stepinski	A segmentation approach for a delineation of terrestrial ecoregions	The 2017 AGU Fall Meeting	Nowy Orlean
2017-09-05	Jakub Nowosad, Tomasz F. Stepinski	Worldwide inventory of landscapes through segmentation of global land cover dataset	GeoComputation 2017	Leeds
2017-07-06	Jakub Nowosad, Tomasz F. Stepinski	New global map of land cover pattern types based on the ESA CCI-LC data using a segmentation-classification	The 28th International Cartographic Conference	Waszyngton

Struktury przestrzenne

Badania nad ekoregionami zwróciły moją uwagę w kierunku ekologii krajobrazu, w ramach której pracowałem nad zrozumieniem struktur przestrzennych (patrz osiągnięcie). Zaowocowało to prezentacjami na konferencjach US-IALE 2018 Annual Meeting, 10th IALE World Congress, IALE-NA 2020 Annual Meeting, Rasters Revealed 2021 i GISRUK 2021 (tabela 3) oraz posterem

na 10th IALE World Congress.

Od pewnego czasu pracuję również na styku ekologii krajobrazu, informatyki i geoinformacji, gdzie staram się udoskonalać istniejące metody i tworzyć nowe. We współpracy z naukowcami z kilku ośrodków naukowych z Europy i Stanów Zjednoczonych, **opublikowałem artykuł opisujący otwartoźródłowe oprogramowanie R do obliczania metryk krajobrazowych i jego potencjalne zastosowania (Hesselbarth i in. 2019)**. Praca ta spotkała się z dużym zainteresowaniem: sam artykuł otrzymał nagrody Top Downloaded Paper 2018-2019 oraz Top Downloaded Paper 2019-2020 w czasopiśmie *Ecography*, a stworzone oprogramowanie zostało od momentu udostępnienia pobrane ponad 46 tys. razy. Ostatnio zainteresowałem się również zastosowaniem dla danych przestrzennych idei entropii Boltzmann. Zaowocowało to **opracowaniem pakietu R do obliczania entropii Boltzmann dla gradientów krajobrazowych**, ulepszeniem istniejących metod o możliwość używania danych z brakującymi wartościami, a w efekcie końcowym **opublikowaniem w *Entropy* artykułu na ten temat (Nowosad i in. 2020)**, który powstał we współpracy z Peichao Gao z Beijing Normal University.

Moja praca nad globalnymi zmianami pokrycia terenu spowodowała, że członkowie Yale Center for Environmental Law & Policy oraz Center for International Earth Science Information Network (CIESIN) przy Columbia University's Earth Institute zwrócili się o moją **pomoc przy projekcie Environmental Performance Index 2020 (EPI 2020)**. EPI 2020 (<https://epi.yale.edu/>) wykorzystuje podejście oparte na danych, aby podsumować stan zrównoważonego rozwoju dla 180 krajów na całym świecie. W oparciu o stan środowiska naturalnego i kondycję ekosystemów, EPI 2020 umożliwi identyfikację problemów, śledzenie istniejących trendów, wyznaczanie nowych celów i najlepszych praktyk. Moim zadaniem w tym projekcie było określenie czasoprzestrzennych zmian w powierzchni terenów trawiastych i zmian w powierzchni terenów podmokłych dla każdego kraju na świecie w ciągu ostatnich 25 lat.

W 2021 roku zostałem również **zaproszony do wygłoszenia wykładu na temat analizy opartej na strukturach przestrzennych na Royal Geographical Society with IBG GIScience Webinar Series** (tabela 3).

Tabela 3: Wystąpienia konferencyjne związane z strukturami przestrzennymi

Data	Autorzy	Tytuł	Konferencja	Miejsce
2021-04-16	Jakub Nowosad, Tomasz F. Stepinski	Describing multi-layer spatial patterns using an integrated co-occurrence matrix (INCOMA)	GISRUK 2021	Cardiff (konferen- cja zdalna)

2021-02-03	Jakub Nowosad	Pattern-based spatial analysis: an approach for discovering, describing and studying geographical patterns	The Royal Geographical Society with IBG GIScience Webinar Series	
2021-01-15	Jakub Nowosad	Describing composition and configuration of patterns in categorical rasters	Rasters Revealed 2021	Oxford (konferencja zdalna)
2020-05-13	Jakub Nowosad, Tomasz F. Stepinski	Current state and changes in the composition and configuration of landscapes worldwide	The IALE-NA 2020 Annual Meeting	Toronto (konferencja zdalna)
2019-07-04	Jakub Nowosad, Tomasz F. Stepinski	From empirical to theoretical descriptors of landscapes complexity	The 10th IALE World Congress	Mediolan
2018-04-08	Jakub Nowosad, Tomasz F. Stepinski	Describing Landscapes by Statistics of Local Pattern Features: Application to Landscape Regionalization, Change, and Search	The US-IALE 2018 Annual Meeting	Chicago

Aerobiologia

Podczas studiów doktoranckich podjąłem się tematu dyspersji pyłków w atmosferze i jego wpływu na życie osób cierpiących na alergię. **Moja praca doktorska składała się z trzech artykułów związanych z lepszym zrozumieniem czaso-przestrzennych zmian koncentracji pyłku drzew.** Celem pierwszego z nich było określenie charakterystyki czasowej i przestrzennej autokorelacji stężenia pyłku olchy, brzozy i leszczyny w powietrzu w Polsce (Nowosad i in. 2015). Dało to przegląd złożoności stężeń pyłku w powietrzu, określiło właściwości sezonów pyłkowych i skwantyfikowało czasowe i przestrzenne zmiany stężeń pyłku drzew. Wyniki te przyczyniły się do poszerzenia wiedzy na temat autokorelacji liczebności pyłku i zasugerowały kierunki przyszłych badań. Idee z pierwszego artykułu zostały następnie wykorzystane w badaniu, którego celem było stworzenie i ocena modeli do przewidywania wysokich poziomów dziennych stężeń pyłku leszczyny, olchy i brzozy (Nowosad i in. 2016). W tej pracy zbudowano modele predykcyjne pyłku drzew, wykorzystując właściwości czaso-przestrzennej autokorelacji ich stężeń. Wreszcie w trzecim artykule wstępnie przetworzone rastrowe dane meteorologiczne

zostały wykorzystane do przewidywania prawdopodobieństwa wysokich poziomów stężenia pyłku leszczyny, olchy i brzozy (Nowosad 2016). W tym artykule zaproponowałem nowe podejście do modelowania, które może być zastosowane w przewidywaniu wysokich stężeń pyłku różnych taksonów, jak również predykcji dla innych obszarów. Zidentyfikowałem również zmienne meteorologiczne, które mają największy wpływ na wartości stężeń pyłku. Na podstawie końcowych modeli można było przewidzieć wysoki poziom stężeń pyłku nie tylko w miejscach monitoringu aerobiologicznego, ale również w miejscach nieobjętych pomiarami. Wyniki końcowego artykułu zostały wykorzystane do zbudowania i wdrożenia operacyjnego modelu predykcyjnego wysokiego poziomu stężeń pyłku brzozy nad obszarem Polski na lata 2017 i 2018. Swoje prace związane z aerobiologią prezentowałem na kilku krajowych konferencjach (tabela 4).

Doświadczenie zebrane podczas moich badań nad rozprawą doktorską **wykorzystałem do porównania dziewięciu technik modelowania statystycznego stosowanych do przewidywania stężeń pyłku (Nowosad i in. 2018a)**. To badanie nie tylko pokazało, które metody są najdokładniejsze, ale również zasugerowało potencjalne ulepszenia w modelowaniu aerobiologicznym, takie jak stosowanie technik walidacji krzyżowej oraz wykorzystanie zastrawianych zmiennych niezależnych.

Kolejnym przykładem moich badań na styku geografii i aerobiologii była **współpraca z aerobiologami z kilku krajów europejskich (Grinn-Gofroń i in. 2019)**. Celem tych badań było modelowanie dziennych stężeń zarodników grzybów w powietrzu oraz ich poziomów alergicznych w skali kontynentu. Dodatkowe cele obejmowały ocenę poziomu uogólnienia modeli w przestrzeni oraz opis głównych czynników meteorologicznych wpływających na stężenia zarodników grzybów.

Tabela 4: Wystąpienia konferencyjne związane z aerobiologią

Data	Autorzy	Tytuł	Konferencja	Miejsce
2016-10-14	Jakub Nowosad, Alfred Stach	Czasoprzestrzenne modelowanie i prognozowanie w aeropalinologii	Zjazd palinologów polskich	Poznań
2016-04-15	Jakub Nowosad	Prognozowanie wysokich poziomów stężeń pyłku drzew za pomocą danych meteorologicznych w siatce	II Ogólnopolska Konferencja Klimatologiczna	Poznań

2015-06-01	Jakub Nowosad	Czasoprzestrzenne prognozowanie poziomów stężeń pyłku brzozy w oparciu o dane meteorologiczne	GIS w nauce	Poznań
------------	---------------	--	-------------	--------

Inne

Współpracuję również przy różnorodnych projektach z uczonymi z szergu instytucji naukowych. Na przykład, wspólnie z naukowcami z Uniwersytetu Adama Mickiewicza badaliśmy, jak protokoły pomiarowe oraz szorstkość powierzchni gleby wpływają na informacje pozyskane z pomiarów spektralnych. W wyniku tych badań **zapropowaliśmy kryterium, które powinno być spełnione, aby uzyskać stabilne, prawidłowe wartości charakterystyk spektralnych gleb (Każmierowski i in. 2019)**. Inna współpraca miała na celu **stworzenie i ocenę różnych modeli statystycznych do rekonstrukcji, przewidywania i poprawy jakości monitorowania faz fenologicznych z wykorzystaniem produktów satelitarnych i meteorologicznych (Czernecki i in. 2018)**. Uzyskane wyniki pokazały, że skuteczne przewidywanie wczesnych faz fenologicznych jest możliwe używając głównie wskaźników meteorologicznych, podczas gdy dla fenofaz jesiennych silniejszy sygnał informacyjny dostarczają satelitarne indeksy wegetacji.

W 2017 roku Polski Instytut Meteorologii i Gospodarki Wodnej - Państwowy Instytut Badawczy (IMGW-PIB) udostępnił swoje dane meteorologiczne i hydrologiczne dla zastosowań niekomercyjnych. Jednakże, od czasu pierwszego wydania, struktura tych danych uległa licznym zmianom, a ich pozyskanie wymaga pobrania i wstępnego przetworzenia wielu plików. Podobne problemy dotyczą również wielu innych źródeł danych meteorologicznych i hydrologicznych. Aby wesprzeć i przyspieszyć badania środowiskowe, **współtworzyłem pakiet R climate i przedstawiłem przykłady efektywnego wykorzystania dostępnych danych, m.in., do znalezienia trendów zmian temperatur powietrza dla stacji pomiarowych w Polsce (Czernecki i in. 2020)**.

Podczas mojego stażu podoktorskiego aktywnie uczestniczyłem we współpracy badawczej na Uniwersytecie w Cincinnati, która obejmowała badania teledetekcyjne toksycznych zakwitów sinic w jeziorach. Wraz z naukowcami z kilku uniwersytetów i organizacji rządowych **oceniliśmy uniwersalność dwudziestu dziewięciu algorytmów do wykrywania potencjalnych miejsc zakwitów sinic (Johansen i in. 2018)**. Stworzyliśmy również oprogramowanie o nazwie **waterquality** do wykrywania i ilościowego oznaczania sinicowych zakwitów oraz ogólnej oceny jakości wody. Opis funkcjonalności oprogramowania, oparty na studium przypadku dla jeziora Harsha w południowo-zachodnim Ohio w Stanach Zjednoczonych, został opublikowany jako

raport techniczny dla US Army Corps of Engineers (Johansen i in. 2019).

Ze względu na moje zainteresowanie i znajomość opartych na teorii informacji metryk dla struktur przestrzennych, **zaangażowałem się również w badanie różnorodności i segregacji rasowej (Dmowska i in. 2020)**. Ta praca wykorzystwała niektóre wcześniej opisane koncepcje analizy krajobrazu i przeniosła je do analizy przestrzenno-rasowej. W rezultacie przedstawiliśmy nową koncepcję krajobrazu rasowego i wprowadziliśmy dwie metryki oparte o teorię informacji, które są w stanie określić różnorodność i segregację krajobrazów rasowych.

Wyniki moich pozostałych badań były również prezentowane na konferencjach naukowych (tabela 5).

Tabela 5: Inne wystąpienia konferencyjne

Data	Autorzy	Tytuł	Konferencja	Miejsce
2016-06-23	Bartosz Czernecki, Jakub Nowosad, Katarzyna Jablonska	Statistical modeling of phenological phases in Poland based on coupling satellite derived products and gridded meteorological data	GeoMLA	Belgrad
2016-06-16	Cezary Kazmierowski, Karolina Herodowicz, Sławomir Krolewicz, Jakub Nowosad, Jerzy Cierniewski	The representativeness of soil spectra obtained from the sensor at different height above the ground	European Society for Soil Conservation Conference	Cluj
2015-06-22	Jarosław Jasiewicz, Alfred Stach, Jakub Nowosad	Terrain misclassification problem – analysis using pattern simulation approach	Geomorphometry	Poznań
2015-04-15	Jarosław Jasiewicz, Alfred Stach, Jakub Nowosad	Pattern simulation approach for elucidation of glacial relief misclassification	EGU General Assembly	Wiedeń

Nagrody

W rezultacie mojej pracy naukowej otrzymałem stypendium Ministra Nauki i Szkolnictwa Wyższego dla wybitnych młodych naukowców w 2020 roku. W tym samym roku otrzymałem również nagrodę rektora I stopnia za osiągnięcia naukowe, stypendium naukowe rektora UAM dla nauczycieli akademickich oraz wsparcie dla najbardziej produktywnej naukowo młodej kadry badawczej z projektu Inicjatywa doskonałości – Uczelnia badawcza.

Wykaz innych publikacji

1. Czernecki, B., A. Głogowski i J. Nowosad (2020). "Climate: an R package to access free in-situ meteorological and hydrological datasets for environmental assessment". *Sustainability* 12.1, s. 394. DOI: 10.3390/su12010394.
2. Dmowska, A., T. F. Stepinski i J. Nowosad (2020). "Racial landscapes – a pattern-based, zoneless method for analysis and visualization of racial topography". *Applied Geography* 122, s. 102239. DOI: <https://doi.org/10.1016/j.apgeog.2020.102239>.
3. Nowosad, J. i P. Gao (2020). "belg: a tool for calculating Boltzmann entropy of landscape gradients". *Entropy* 22.9. DOI: 10.3390/e22090937.
4. Grinn-Gofroń, A., J. Nowosad, B. Bosiacka, I. Camacho, C. Pashley i in. (2019). "Airborne Alternaria and Cladosporium fungal spores in Europe: Forecasting possibilities and relationships with meteorological parameters". *Science of the Total Environment* 653, s. 938–946.
5. Hesselbarth, M. H. K., M. Sciaini, K. A. With, K. Wiegand i J. Nowosad (2019). "landscapemetrics : an open-source R tool to calculate landscape metrics". *Ecography* 42.10, s. 1648–1657. DOI: 10.1111/ecog.04617.
6. Johansen, R. A., M. Reif, E. Emery, J. Nowosad, R. Beck i in. (2019). *waterquality: an open-source R package for the detection and quantification of cyanobacterial harmful algal blooms and water quality*. Spraw. tech. USACE ERDC/EL. DOI: 10.21079/11681/35053.
7. Kaźmierowski, C., K. Herodowicz, S. Królewicz, J. Nowosad i J. Piekarczyk (2019). "Representative elementary area issue in soil spectral measurements". *Soil and Tillage Research* 186, s. 259–269. DOI: 10.1016/j.still.2018.11.002.
8. Lovelace, R., J. Nowosad i J. Muenchow (2019). *Geocomputation with R*. CRC Press (Taylor & Francis Group).
9. Czernecki, B., J. Nowosad i K. Jabłońska (2018). "Machine learning modeling of plant phenology based on coupling satellite and gridded meteorological dataset". *International Journal of Biometeorology*. DOI: 10.1007/s00484-018-1534-2.
10. Johansen, R., R. Beck, J. Nowosad, C. Nietch, M. Xu i in. (2018). "Evaluating the portability of satellite derived chlorophyll-a algorithms for temperate inland lakes using airborne hyperspectral imagery and dense surface observations". *Harmful Algae* 76, s. 35–46. DOI: 10.1016/j.hal.2018.05.001.
11. Nowosad, J., A. Stach, I. Kasprzyk, K. Chłopek, K. Dąbrowska-Zapart i in. (2018a). "Statistical techniques for modeling of Corylus, Alnus, and Betula pollen concentration in the air". *Aerobiologia* 34.3, s. 301–313. DOI: 10.1007/s10453-018-9514-x.
12. Nowosad, J. i T. F. Stepinski (2018b). "Spatial association between regionalizations using the information-theoretical V-measure". *International Journal of Geographical Information Science* 32.12, s. 2386–2401.

13. Nowosad, J. i T. F. Stepinski (2018c). "Towards machine ecoregionalization of Earth's landmass using pattern segmentation method". *International Journal of Applied Earth Observation and Geoinformation* 69, s. 110–118. doi: 10.1016/j.jag.2018.03.004.
14. Nowosad, J. (2016). "Spatiotemporal models for predicting high pollen concentration level of *Corylus*, *Alnus*, and *Betula*". *International journal of biometeorology* 60.6, s. 843–855.
15. Nowosad, J., A. Stach, I. Kasprzyk, E. Weryszko-Chmielewska, K. Piotrowska-Weryszko i in. (2016). "Forecasting model of *Corylus*, *Alnus*, and *Betula* pollen concentration levels using spatiotemporal correlation properties of pollen count". *Aerobiologia* 32.3, s. 453–468.
16. Nowosad, J., A. Stach, I. Kasprzyk, M. Latałowa, M. Puc i in. (2015). "Temporal and spatiotemporal autocorrelation of daily concentrations of *Alnus*, *Betula*, and *Corylus* pollen in Poland". *Aerobiologia* 31.2, s. 159–177.

6 Informacja o osiągnięciach dydaktycznych, organizacyjnych oraz popularyzujących naukę lub sztukę

Osiągnięcia dydaktyczne

Posiadam doświadczenie dydaktyczne w zakresie analiz przestrzennych, geostatystyki, statystyki, uczenia maszynowego oraz informatyki. Od początku studiów doktoranckich miałem okazję pełnić rolę wykładowcy i prowadzącego laboratorium na kilku przedmiotach, takich jak Wstęp do programowania, Algorytmy heurystyczne, Optymalizacja dyskretna, Statystyka i rachunek prawdopodobieństwa oraz Geostatystyka. Pełniłem również funkcję prowadzącego laboratorium na kilku innych przedmiotach, takich jak Podstawy Geoinformacji, Systemy Informacji Geograficznej oraz Podstawy modelowania. Oprócz pełnienia powyższych funkcji, byłem również asystentem dydaktycznym na kursie Practical Data Mining, a także miałem okazję gościnnie prowadzić zajęcia z Geomarketingu oraz Wprowadzenia do programowania (Tabela 6).

Tabela 6: Lista prowadzonych przedmiotów

Typ	Nazwa przedmiotu
Wykład	Algorytmy Heurystyczne
Gościenny wykład	Geomarketing
Wykład	Geostatystyka
Laboratorium	Geostatystyka
Laboratorium	Kartografia i Przestrzenne Systemy Informacyjne
Laboratorium	Laboratorium magisterskie
Praktyki terenowe	Mobilny GIS
Laboratorium	Modelowanie systemów przyrodniczych
Wykład	Optymalizacja dyskretna
Laboratorium	Podstawy geoinformacji
Laboratorium	Pracownia projektowa
Asysta dydaktyczna	Practical data mining and visualization

Seminarium	Proseminarium
Seminarium	Seminarium inżynierskie
Seminarium	Seminarium magisterskie
Wykład	Systatystyka i rachunek prawdopodobieństwa
Laboratorium	Systatystyka i rachunek prawdopodobieństwa
Laboratorium	Systemy Informacji Geograficznej
Gościenny wykład	Wprowadzenie do programowania
Wykład	Wstęp do programowania
Laboratorium	Wstęp do programowania

Aby poprawić wyniki kształcenia moich studentów, **napisałem dwa podręczniki akademickie, Geostatystyka w R (<https://zenodo.org/record/3613591>) i Elementarz programisty: wstęp do programowania używając R (<https://zenodo.org/record/3929338>)**. Pierwszy podręcznik jest używany na laboratoriach z Geostatystyki, a drugi jest głównym źródłem wiedzy na zajęciach Wstęp do programowania. Obydwa podręczniki wydałem samodzielnie i udostępniłem online na licencji Creative Commons. Okazały się one przydatne również poza dwoma wyżej wymienionymi przedmiotami. Geostatystyka w R jest literaturą podstawową modułu Przetwarzanie danych środowiskowych na Akademii Górniczo-Hutniczej im. Stanisława Staszica w Krakowie oraz przedmiotu Systemy informacji przestrzennej na Uniwersytecie Zielonogórskim. Elementarz programisty jest literaturą obowiązkową dla przedmiotu Wprowadzenie do programowania oraz literaturą zalecaną dla przedmiotu Projekt - wykorzystanie metod ilościowych na Uniwersytecie Wrocławskim, a także literaturą zalecaną dla studiów podyplomowych Data Science w zastosowaniach biznesowych na Uniwersytecie Warszawskim. Wreszcie, oba podręczniki zostały przytoczone w szeregu prac inżynierskich, magisterskich i doktorskich.

Od rozpoczęcia pracy na stanowisku adiunkta w 2018 roku bezpośrednio sprawuję nadzór nad pracami dyplomowymi na kierunku studiów geoinformacja. **Byłem promotorem sześciu prac inżynierskich i jednej pracy magisterskiej**. Obecnie sprawuję merytoryczną opiekę nad pięcioma studentami przygotowującymi prace inżynierskie i jednym pracę magisterską. **Pełniłem również funkcję recenzenta trzech innych prac inżynierskich**.

Osiągnięcia organizacyjne

Zacząłem wykorzystywać zdolności organizacyjne podczas studiów licencjackich i magister-

skich. We wrześniu 2008 roku pomagałem przy organizacji 57 Zjazdu Polskiego Towarzystwa Geograficznego w Białowieży. Jako członek Koła Naukowego Studentów Geografii im. Stanisława Pawłowskiego współorganizowałem GIS DAY w latach 2008-2010 oraz coroczne Forum Studenckiego Koła Naukowego w latach 2010-2012. Jako doktorant **byłem członkiem komitetów organizacyjnych dwóch ogólnopolskich konferencji GIS w nauce oraz GIS w edukacji w czerwcu 2015 roku. W tym samym miesiącu byłem również zaangażowany w organizację międzynarodowej konferencji Geomorphometry 2015. Po uzyskaniu stopnia doktora współorganizowałem pierwsze europejskie spotkanie użytkowników R (ang. *European R User Meeting*) w 2016 roku. Obecnie należę do komitetu organizacyjnego konferencji GIScience 2021. Ponadto od 2020 roku jestem członkiem Rady Naukowej Dyscypliny Nauk o Ziemi i Środowisku oraz Rady Programowej kierunku studiów geoinformacja na Wydziale Nauk Geograficznych i Geologicznych.**

Regularnie prowadzę warsztaty podczas konferencji naukowych (tabela 7). Obejmuje to warsztaty na Polskim Akademickim Zlocie Użytkowników R (Poznań, 2014), GIS w nauce (Poznań, 2015), Geomorphometry 2015 (Poznań, 2015), GeoComputation (Leeds, 2017), VII Forum BioGIS (Poznań, 2019), Why R? 2019 (Warszawa, 2019), IALE-NA 2020 Annual Meeting (Toronto, 2020; zdalnie) oraz useR! 2020 (Saint Louis, 2020; zdalnie). Większość moich warsztatów koncentruje się na połączeniu wiedzy dziedzinowej (np. geomorfometria lub ekologia krajobrazu) z informatyką. Dodatkowo, w 2018 roku zostałem zaproszony jako wykładowca podczas szkoły letniej GEOSTAT 2018, gdzie miałem okazję wyjaśnić zastosowanie oprogramowania GeoPAT 2 około 70 studentom z ponad 20 krajów na całym świecie.

Tabela 7: Przeprowadzone warsztaty

Data	Tytuł	Konferencja	Miejsce
2020-07-27	First steps in spatial data handling and visualization	useR! 2020	Saint Louis (konferencja zdalna)
2020-05-14	Introduction to Landscape Ecology with R	The IALE-NA 2020 Annual Meeting	Toronto (konferencja zdalna)
2019-09-27	Basics of Spatial Data Analysis	Why R? 2019	Warszawa
2019-03-22	Analiza geoinformacyjna w R	VII Forum BioGIS	Poznań

2018-08-22	GeoPAT 2 - analysis of spatial and temporal patterns	GEOSTAT 2018	Praga
2018-05-14	Geocomputation with R	eRum 2018	Budapeszt
2017-09-04	Spatial Data and the Tidyverse	GeoComputation 2017	Leeds
2015-06-25	GRASS GIS and R as a tool for large geomorphometric mapping	Geomorphometry	Poznań
2015-06-01	R, czyli jak stworzyć mapę interaktywną za pomocą kilku linii kodu	GIS w nauce	Poznań
2014-10-15	Analiza danych przestrzennych w R	PAZUR	Poznań

Wykonałem także szereg recenzji dla czasopism naukowych (liczba recenzowanych artykułów w nawiasie), takich jak *Aerobiologia* (3), *Ecological Modelling* (1), *Entropy* (1), *Environmental Modelling and Software* (1), *Environmental Monitoring and Assessment* (1), *International Journal of Biometeorology* (2), *International Journal of Geographical Information Science* (2), *ISPRS International Journal of Geo-Information* (1), *Journal of Forestry Research* (1), *Journal of Geographical Systems* (2), *Land* (1), *Landscape Ecology* (4), *Methods in Ecology and Evolution* (1), *The R Journal* (1), *Transactions in GIS* (2). Ponadto **byłem recenzentem oprogramowania** dla ROpenSci (1) oraz **recenzentem propozycji wydawniczej** dla CRC Press (1).

Osiągnięcia popularyzatorskie

Mam na swoim koncie także kilka osiągnięć popularyzatorskich. Od czasu rozpoczęcia studiów licencjackich miałem okazję wygłosić kilka prelekcji (2009, 2010, 2012, 2013, 2018, 2019) i prowadzić warsztaty (2015) na GIS Day w Poznaniu. Moje prezentacje miały na celu wzbudzenie w licealistach i studentach pierwszego roku zainteresowania naukami przestrzennymi i nastawieniem na rozwiązywanie problemów środowiskowych w oparciu o dane. W 2011 i 2012 roku pomagałem przy organizacji, a w 2013 i 2014 roku prowadziłem warsztaty na Festiwalu Nauki i Sztuki w Poznaniu. W 2014 i 2015 roku opowiadałem o narzędziach programistycznych używanych przez geografów na Poznańskim Zlocie Użytkowników R. W 2017 roku przeprowadziłem zestaw szkoleń dla studentów geografii na Uniwersytecie w Cincinnati oraz warsztaty “GIS with R: how to start?” dla GIS Learning Community w Cincinnati. W 2018 roku wprowadziłem zagadnienia związane z geoinformacją w R dla Cincinnati Dayton R User Group w Dayton. Pomagałem również przy organizacji Dnia Kandydata na Uniwersytecie Adama

Mickiewicza w 2018, 2019 i 2020 roku, gdzie popularyzowałem geoinformatykę i promowałem ilościowe podejście do geografii. Z kolei w 2020 roku w cyklu webinarów fundacji Why R? wygłosiłem prelekcję na temat najnowszych zmian w pakietach R związanych z analizą danych przestrzennych.

7 Oprócz kwestii wymienionych w pkt. 1-6, wnioskodawca może podać inne informacje, ważne z jego punktu widzenia, dotyczące jego kariery zawodowej

Moim ogólnym dążeniem jest dostarczanie studentom, naukowcom, społeczeństwu i instytucjom informacji mogących przyczynić się do poprawy jakości życia ludzi oraz pomocy w zarządzaniu zasobami i ochronie środowiska. Z tego powodu wspieram otwartą naukę (ang. *open science*) we wszystkich aspektach mojej pracy. Obejmuje to publikowanie prac jako preprinty lub w otwartym dostępie (gdy możliwe), rozpowszechnianie zbiorów danych, udostępnianie oprogramowania open-source oraz dzielenie się moimi materiałami dydaktycznymi na licencji Creative Commons (<https://nowosad.github.io/presentations/>).

Ważną częścią mojej kariery zawodowej jest tworzenie, współpraca nad i ulepszanie oprogramowania geoinformacyjnego. **Stworzyłem kilkanaście programów open-source do analizy danych przestrzennych, ułatwiających dostęp do istniejących baz danych, oraz służących do przetwarzania i wizualizacji danych.** Kilka z tych pakietów było częścią projektów badawczych wspomnianych już w poprzednich rozdziałach, dlatego przedstawię tylko te, które nie zostały jeszcze omówione. Co ważne, do większości z wymienionych poniżej programów dołączona jest również rozbudowana, zawierająca przykłady użycia, dokumentacja.

W trakcie mojego stażu podoktorskiego byłem członkiem grupy, która opracowała zestaw narzędzi do analizy opartej na strukturach przestrzennych o nazwie GeoPAT 2 (Netzel i in. 2018). Napisałem również pakiet R o nazwie **rgeopat2** (Nowosad 2020b), który rozszerza funkcjonalność GeoPAT 2.

W 2019 roku stworzyłem pakiet R **comat**, którego celem jest tworzenie różnych typów macierzy współwystępowania (ang. *co-occurrence matrices*) na podstawie przestrzennych danych rastrowych (Nowosad 2020a). Zawiera on standardowe macierze współwystępowania, ważone macierze współwystępowania (ang. *weighted co-occurrence matrices*) oraz zintegrowane macierze współwystępowania (ang. *integrated co-occurrence matrices*). Główne fragmenty tego pakietu zostały napisane w wydajnym kodzie C++, w celu umożliwienia wykorzystania tego pakietu jako silnika obliczeniowego w innych programach.

Pakiety R mogą być również wykorzystywane jako miejsce przechowywania przykładowych danych do demonstracji różnych technik i metod. W tym celu utworzyłem pakiety **spData** i **spDataLarge** jako kolekcje różnorodnych zbiorów danych przestrzennych do testowania metod, analizy porównawczej (ang. *benchmarking*) i nauczania analizy danych przestrzennych (Bivand i in. 2020; Nowosad i in. 2020). Od momentu powstania, **spData** został wykorzystany w kilkunastu

innych pakietach R i zgromadził w sumie ponad 1,5 miliona pobrań.

W połowie 2020 r. Główny Urząd Geodezji i Kartografii (*GUGiK*) publicznie udostępnił swoje zasoby, w tym ortofotomapy, cyfrowe modele wysokościowe (DTM, DSM, Point Cloud) oraz modele 3D budynków w standardach LOD1 i LOD2. Jednakże, znalezienie plików z oczekiwanymi właściwościami (np. konkretną datą czy rozdzielczością) i ich pozyskanie wymaga żmudnego, ręcznego pobierania. Aby rozwiązać ten problem, współpracowałem nad pakietem **rgugik** (Dyba i in. 2020), który ma na celu automatyczne wyszukiwanie i pobieranie danych przestrzennych z *GUGiK*. Pakiet ten otrzymał wyróżnienie w konkursie na najlepsze wykorzystanie danych i usług *GUGiK* w 2020 roku.

Moja praca nad danymi przestrzennymi spowodowała, że zainteresowałem się bliżej wykorzystaniem kolorów do celów wizualizacji danych przestrzennych. Zaowocowało to zaimplementowaniem schematów kolorów dla map i innych grafik zaprojektowanych przez firmę CARTO w postaci pakietu **rcartocolor** (Nowosad 2019c). Pakiet ten został pobrany ponad 54 tys. razy i został wykorzystany w kilku artykułach naukowych oraz publikacjach internetowych. Praca nad **rcartocolor** wzbudziła również moje zainteresowanie właściwościami kolorów, a w szczególności tym, jak różne palety kolorów są postrzegane przez osoby z zaburzeniami rozpoznawania barw. W wyniku tej pracy stworzyłem **colorblindcheck** (Nowosad 2019a), który dostarcza narzędzi do oceny, jak wybrane schematy kolorów są odbierane przez osoby z zaburzeniami rozpoznawania barw, oraz ocenia, które z istniejących palet kolorów są przyjazne dla osób ze ślepotą barw.

Podczas moich studiów doktoranckich zacząłem również rozwijać pakiet **pollen** (Nowosad 2019b) do określania sezonów pylenia, zastępowania wartości odstających i obliczania sum temperatur efektywnych.

W 2019 roku opracowałem i opublikowałem zbiór informacji przestrzennych pod nazwą Country-level Land Cover - categories and transitions (<https://cl-land-cover.netlify.app/>). W tym projekcie wykorzystałem National Identifier Grid i dane CCI-LC, aby stworzyć zestawy danych dla każdego kraju na świecie. Obejmują one kategorie, przejścia i całkowite zmiany kategorii pokrycia terenu na poziomie krajów w latach 1992-2015.

Ponadto publikuję również wpisy na mojej prywatnej stronie internetowej pod adresem <https://nowosad.github.io/post/> oraz na stronie Geocomputation with R pod adresem <https://geocompr.github.io/post/>. Tematyka wpisów jest bardzo zróżnicowana, od poradników dotyczących oprogramowania, poprzez prezentację możliwych sposobów pracy z danymi przestrzennymi, aż po wyjaśnienie nowych metod i popularyzację współczesnych idei związanych z analizą i wizualizacją geoinformacyjną. Obie strony internetowe były w ciągu ostatniego roku

odwiedzone przez około 20 tys. unikalnych użytkowników.

Inne oprogramowanie, które nie zostało wymienione w poprzednich sekcjach

1. Bivand, R., J. Nowosad i R. Lovelace (2020). *spData: Datasets for Spatial Analysis*. R package version 0.3.8.
2. Dyba, K. i J. Nowosad (2020). *rgugik: Search and Retrieve Spatial Data from GUGiK*. R package version 0.1.3.
3. Nowosad, J. (2020a). *comat: Creates Co-Occurrence Matrices of Spatial Data*. R package version 0.8.2.
4. Nowosad, J. (2020b). *rgeopat2: Additional Functions for 'GeoPAT' 2*. R package version 0.3.9.
5. Nowosad, J. i R. Lovelace (2020). *spDataLarge: Large datasets for spatial analysis*. R package version 0.5.0.
6. Nowosad, J. (2019a). *Check Color Palettes for Problems with Color Vision Deficiency*. R package version 0.1.0.
7. Nowosad, J. (2019b). *pollen: Analysis of Aerobiological Data*. R package version 0.71.
8. Nowosad, J. (2019c). *rcartocolor: 'CARTOCOLORS' Palettes*. R package version 2.0.0.
9. Netzel, P., J. Nowosad, J. Jasiewicz, J. Niesterowicz i T. Stepinski (2018). *Geopat 2.0: User'S Manual*. doi: 10.5281/zenodo.1185408.



(podpis wnioskodawcy)