

**Mobilność jako kluczowa zmienna wyjaśniająca regionalne różnice w
dynamice zakażeń - Wyniki wstępne**

Andrzej Jarynowski*

Instytut Badań Interdyscyplinarnych we Wrocławiu, Polska

Monika Wójta-Kempa†

Zakład Socjologii Medycyny, Uniwersytet Medyczny we Wrocławiu, Polska

Daniel Płatek‡

Instytut Nauk Politycznych w Warszawie, Polska Akademia Nauk, Polska

Łukasz Krzowski§

Wojskowa Akademia Techniczna w Warszawie, Polska

Vitaly Belik¶

Instytut Biometrii i Epidemiologii Weterynaryjnej, Wolny Uniwersytet Berliński, Niemcy

Streszczenie

Problem: Istnieje potrzeba analizy czasowo-przestrzennej rozprzestrzeniania się wirusa SARS-CoV-2 w Polsce w celu przygotowania szczegółowych rozwiązań, umożliwiających podejmowanie działań minimalizujących zagrożenie dla zdrowia publicznego w czasie wysoce prawdopodobnej drugiej fali na jesień 2020.

Metodologia: Naszym zadaniem jest badanie związku między czasem dojścia wirusa i liczbą potwierdzonych przypadków COVID-19 w okresie 04.03-22.05.2020 (dane nieoficjalne), a zmiennymi społeczno-ekonomicznymi na poziomie powiatów za pomocą prostych technik statystycznych jak wizualizacja danych, analiza korelacji, kastrowanie przestrzenne i wieloraka regresja liniowa.

Wyniki: Proste modele uwzględniające wyłącznie dane społeczno-ekonomiczne pozwalają na wyjaśnienie zmienności liczby przypadków w 45%, a czasu dojścia zakażenia w 25%. Mobilność wyliczona jest jako centralność wierzchołkowa ważona na grafie przepływów pracowniczych na danych GUS najlepiej wyjaśnia zmienność dynamiki zakażeń w Polsce. Emigracja jest najlepszym predyktorem czasów dojścia SARS-CoV-2, a logarytm mobilności ogólnej najlepiej wyjaśnia rozmiar epidemii w powiatach. Poza mobilnością/migracją, poziom zatrudnienia, uprzemysłowienie i poparcie polityczne są najlepszymi predyktorami dynamiki zakażeń w znacznie większym stopniu niż wcześniej postulowane zmienne jak gęstość zaludnienia, dochód, czy wielkość populacji senioralnej.

Wnioski: Polskie władze mogłyby posiadając rzetelną analizę rozprzestrzeniania się wirusa przygotować się na drugą i zarządzać zasobami w sposób optymalny. Ze względu na dużą korelację między emigracją wewnętrzną i zewnętrzną, czasy dojścia zakażenia istotnie statystycznie związane są z migracją pracowników i nie mają istotnego związku jak wcześniej postulowano z wyjazdami turystycznymi, czy biznesowymi. Co więcej, dochód w ujęciu regionalnym wręcz zwiększa (nieistotnie) ryzyko zdiagnozowania COVID-19. Związek między liczebnością najbardziej podatnej na objawową formę zakażeń SARS-CoV-2 populacji senioralnej a liczbą zdiagnozowanych przypadków w modelu selektywnym został wyrugowany przez inne zmienne społeczno-ekonomiczne. W związku z tym, że duże ogniska często występują w przemysłowo-wydobywczych zakładach pracy, obserwujemy korelację między obszarami przemysłowymi lub o wysokim współczynniku zatrudnienia, o wysokiej mobilności oraz wysokim poparciu dla partii rządzącej z liczbą potwierdzonych przypadków COVID-19, należy więc wzmocnić personalnie, informatycznie i uprawnieńowo Inspekcję Sanitarną w powiatach o podwyższonym ryzyku przed kolejną falą zakażeń.

* ajarynowski@interdisciplinary-research.eu

† monika.wojta-kempa@umed.wroc.pl

‡ dplatek21@gmail.com

§ lukasz.krzowski@wat.edu.pl

¶ vitaly.belik@fu-berlin.de


WSTĘP

W związku z rozprzestrzenianiem się zakażeń wirusem SARS-CoV-2 i choroby COVID-19 w Polsce i na świecie zostały wprowadzone nefarmakologiczne działania mitygacyjne generujące ogromne koszty społeczne i ekonomiczne. Mimo, że naturalna zakaźność wirusa jest umiarkowana (wyjściowa stopa reprodukcji epidemii $R_0 \sim 2,5$ co może oznaczać całkowitą stopę reprodukcji pandemii na poziomie $R_0 \sim 1,5$), spora jest frakcja zakażeń bez lub skąpopojawowych (>85%), a śmiertelność w populacji ogólnej niska (CFR<1%) (ECDC [10]), pandemia przyczyniła się do głębokiej recesji ekonomicznej (GUS [19]) i problemów społecznych (Interdisciplinary [21]). Zakażenie SARS-CoV-2 występuje oficjalnie w Polsce od 04.03.2020, ale najprawdopodobniej introdukcje miały miejsce przynajmniej 2 tygodnie wcześniej, co wynika z dopasowania parametru R_0 do krzywej epidemicznej (Jarynowski et al. [29], Mostowy [38]).

W obliczu braku (na dzień dzisiejszych skutecznych) farmakologicznych środków zaradczych wobec COVID-19 (również w nieokreślonej perspektywie) praktycznie jedynymi metodami mitygacyjnymi są techniki behawioralne jak:

- redukcja kontaktów (np. izolacja/kwarantanna, czy fizyczne dystansowanie i restrykcje mobilności czyli tzw. „physical distancing” i „lockdown”);
- zmniejszenie prawdopodobieństwa zakażenia (np. izolacja standardowa jak higiena i stosowanie środków ochrony personalnej oraz immunomodulacja jak promocja zdrowego trybu życia);
- skrócenie czasu zakaźności (np. opracowywanie ognisk, śledzenie kontaktów i testowanie).

Różne kraje i regiony odniosły większy sukces niż inne w opóźnieniu pojawienia się wirusa oraz spowolnieniu wzrostu liczby przypadków COVID-19 (Gelfand et al. [15], Jarynowski et al. [28, 29]). Rozkład zakażeń koronawirusem w Polsce jest bardzo zróżnicowany. Dane o seroprevalencji świadczą wciąż o małej liczbie osób potencjalnie odpornych na zakażenie (np. 2% pod koniec kwietnia w Krakowie (Pyrz [47]), a prawdopodobnie ze względu na sezonowość i naturalne przygaszenie zapadalności latem (znaną np. z innych Koronawirusów (Neher et al. [39])) frakcja tych osób istotnie nie wzrośnie. Ze względu na to iż, dystansowanie fizyczne i lockdown nie będą możliwe do zastosowania w czasie drugiej fali („drugiego lockdownu już nie da się zrobić”(Szumowski [54])), a liczba testów molekularnych w obecnym reżimie technologicznym jest ograniczona przez skończoną liczbę laboratoriów oraz analityków medycznych, należy się zastanowić nad skuteczniejszą alokacją przeciwepidemicznych zasobów będących już w posiadaniu, bądź mogących zostać w krótkim czasie i tanio rozszerzonych. Zdolność odpowiedniego



Rysunek 1. Liczba zdiagnozowanych przypadków w Polsce na podstawie danych do 22.05 (Rogalski [49])

planowania na podstawie danych i zależności, a w konsekwencji wyprzedzającego reagowania przy ograniczonych zasobach logistycznych to podstawowa strategia działania w dobie kryzysu (Trzos et al. [56]).

Celem analizy jest poszukiwanie związków przyczynowo-skutkowych, przestrzennego rozkładu dynamiki zakażeń w relacji do społeczno-ekonomicznych uwarunkowań. Próbuje zdiagnozować czynniki katalizujące i inhibitujące dynamikę zakażeń. M.in. badamy hipotezę paradoksu nierówności: jak zapóźnienia cywilizacyjne (peryferyjność w systemie przepływów osobowych (Bartosiak [2])) i wykluczenie poszczególnych grup społecznych (samotność osób starszych (Duplaga [9], Jarynowski et al. [29])) wpływa na szerzenie się zakażeń na przykładzie Polski. Postaramy się zwrócić szczególną uwagę na modyfikowalnych czynnikach zaradczych w kontekście ich optymalnego rozdysponowania przed prawdopodobną jesienną falą zakażeń. Fundamentalne znaczenie dla sprawnego zarządzania w regionie na poziomie operacyjnym (powiat lub województwo) i taktycznym (ognisko lub zakażony) to przede wszystkim możliwość optymalnego rozlokowania zasobów w czasie oraz przestrzeni (Krzowski and Trzos [34]) i właśnie do tego przyczynkiem jest ta analiza.

Epidemiologia

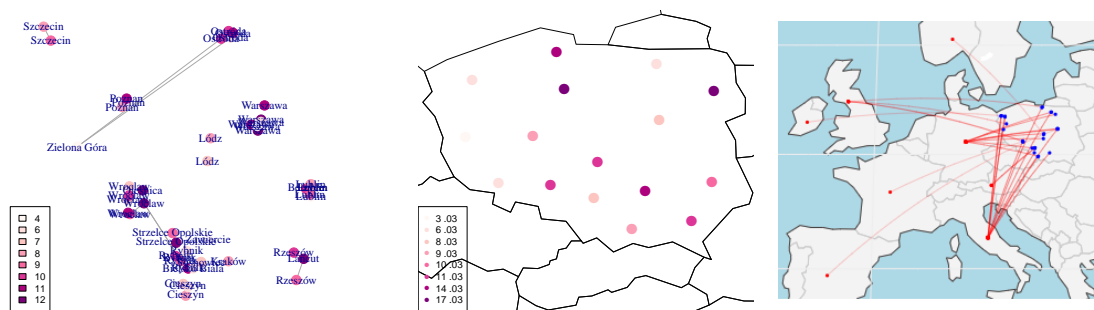
Dane epidemiologiczne dotyczące liczby zdiagnozowanych przypadków na przełomie kwietnia i maja wskazują, że trend liczby nowych zdiagnozowanych przypadków w większości powiatów w Polsce jest malejący. Oznacza, to że epidemia COVID-19 w Polsce jest prawdopodobnie już w stanie wygasania poza Śląskiem [Sitek et al. [52], Rys. 1], a dodatkowy spadek liczby zakażeń ze względu na sezonowość koronawirusów powinien nastąpić w następnych tygodniach (Neher et al. [39]). Oficjalnie dane o zapadalności na COVID-19 dostępne są jedynie z geograficzną dokładnością do województw (przy czym należy zwrócić uwagę, że dane oficjalne dane były podawane przez Ministerstwo Zdrowia poprzez Twittera w postaci obrazu a nie łatwo dostępnych tabelach (Ochab-Marciniak [40]), więc w naszej analizie będziemy polegać na danych zebranych przez wolontariuszy z Torunia (Rogalski [49]). Mimo, że w obiegu jest sporo prognoz sytuacji epidemiologicznej w Polsce przy wykorzystaniu modeli statystycznych (Chudy [4], exmetrix [11], StatSoft [53]), czy fenomenologicznych (Gambin and Rosniska [13], Gonczarek and Wojcik [17], Jarynowski et al. [29], Jasinski [30], Krueger [33], Mostowy [38], Rakowski [48]), to retrospektywnych analiz statystycznych próbujących wyjaśniać procesy jest jedynie kilka jak łączenie gęstość zaludnienia (Sitek et al. [52]), proporcję populacji senioralnej (Tarnowski [55]), czy liczbę testów (StatSoft [53]) z liczbą przypadków.

Np. dzięki danym udostępnionych przez Gazetę Wyborczą (GazetaWyborcza [14]) można przestawić opracowanie pierwszych 48 przypadków 04-12.03.2020 [Rys. 2-lewy]. Dane o związkach epidemiologicznych nie są udostępniane na poziomie indywidualnym (mimo iż wiadomo że takie dane posiada PZH-NIZP i Główny Inspektor Sanitarny) ani są nie prowadzone już żadne znane nam dziennikarskie śledztwa w tej sprawie.

METODOLOGIA I DANE

Głównym celem analizy wtórnej zastanych danych rejestrowych jest identyfikacja i wstępna charakterystyka znaczenia interakcji zmiennych ekonomiczno-społecznych (Drejerska et al. [8]) z dynamiką zakażeń SARS-CoV-2 zachodzących na różnych obszarach Polski. Poziomem analizy jest powiat (380 powiatów). Opracowany materiał bazuje na danych pozyskanych w oparciu o:

- 1) Dane o zakażeniach z arkuszy (Rogalski [49]) z powiatowych/wojewódzkich stacji sanitarno-epidemiologicznych i urzędów regionalnych oraz śledztw dziennikarskich Gazety Wyborczej.



Rysunek 2. Lewy - Opracowanie 48 pierwszych przypadków (Krawędź – związek epidemiologiczny, wierzchołek -pacjent zainfekowany węzłem, współrzędne i nazwy – miejsca zamieszkania/hospitalizacji i współrzędne geograficzne (z szumem), kolory – dzień potwierdzenie przypadku - dzień marca 03-12.03.2020). Środkowy - Pierwsze potwierdzone przypadki w poszczególnych województwach, Prawy Kierunki ostatnich podróży pacjentów z potwierdzonym zakażeniem do 17.03.2020 (UWM [58])

Baza danych z dokładnością do powiatów jest na bieżąco poprawiana i aktualizowana (w artykule przedstawiamy stan do 22.05), ale zawiera około 5% braków danych. Dzięki tej bazie możemy zdefiniować zmienne wyjaśniane:

- czas dojścia (arrival SARS-CoV-2) - definiujemy jako różnicę między dniem ogłoszenia pierwszego zdiagnozowanego przypadku SARS-CoV-2 a 04.03.2020 - czyli pierwszym potwierdzonym przypadkiem w Polsce. W przypadku braku zdiagnozowanych przypadków w danym powiecie przyjmujemy wartość maksymalną - czyli 83 (zakładamy, że wirtualnie zakażamy te powiaty 23.05.2020);
- Liczba przypadków (size COVID-19) - definiujemy jako sumę wszystkich przypadków na dzień 22.05.2020.

Dostępna są jeszcze utworzone przez wolontariuszy z Olsztyna (UMW [57]) i Łodzi (Ambasada-Kultury [1]) bazy danych z dokładnością geograficzną do miejscowości, jednak ze względu na brak rozróżnienia między powiatami ziemskimi i miastami na prawach powiatu nie zdecydowaliśmy się z nich skorzystać poza ilustracją potencjalnych kierunków importu zakażeń (Rys. 2-prawy ,UWM [58]).

2) Dane rejestrowe: dane pozyskane z Banku Danych Lokalnych GUS (GUS [18]) - dokładne definicje dostępne są na stronie GUS-u:

- zarobki (Income) znormalizowane dane o zarobkach w gospodarce z 2019 (100 - średnia dla Polski);
- zalesienie (Forest density) - % lasów w 2018;
- gęstość zaludnienie (density) - w os/km2 w 2019;
- wielkość populacji (population) - liczba osób zamieszkujących powiat w 2018;
- migracje wewnętrzne i zewnętrzne (Internal/External Emi/Immigration) - liczba osób przedmeldowanych na pobyt stały w 2017;
- struktura zawodowa (employment in industry/agriculture/service) - liczba osób pracujących w sektorach przemysłowych/rolniczym/usługach w 2014;
- liczba osób w wieku poprodukcyjnym (No. people in postproductive age) w 2019;
- Sprzedaż całkowita przedsiębiorstw przemysłowych (industry revenue) w 2018 w mln złotych.

Dane pochodzą z różnych lat np. ze względu na to po 2015 dane o sektorach zatrudnienia nie są już podawane z dokładnością do powiatu. Liczba osób starszych może potencjalnie wiązać się z wielkością pandemii ze względu na większą podatność populacji senioralnej na objawową postać choroby i diagnozę COVID-19 (ECDC [10], Jarynowski et al. [29]). Dane o strukturze zatrudnienia mogą wiązać się z zakażeniami zakładowymi (GIS [16]) oraz poziomem pracy zdalnej (Wojta-Kempa and Jarynowski [59]). W celu analizy interakcji między zmiennymi wprowadziliśmy zmienne pośrednie, np. frakcję osób w wieku poprodukcyjnym (senior fraction) oraz frakcję osób zatrudnionych w przemyśle (industry employment faction) do całej populacji powiatu.

3) Dane o mobilności zawodowej (GUSPoznan [20]) z lat 2016-2017:

- liczba osób zarejestrowanych w urzędzie skarbowym obejmującym gminę A i pracujących w gminie B (miejsce zarejestrowania działalności pracodawcy). Dane zostały zagregowane do poziomu powiatu. Wagi krawędzi skierowanych oznaczają liczbę osób związanych z urzędem skarbowym w powiecie X, a pracujących w przedsiębiorstwie zarejestrowanych w powiecie Y;

- mobilność (mobility) - centralność wierzchołkowa ważona (Jarynowski et al. [24]) - podstawowa miara w analizie sieci społecznościowych, czyli sumaryczna liczba osób wjeżdżających i wyjeżdżających z danego powiatu;
- Imigracja (mobility in) - suma wag wchodzących krawędzi (liczby osób pracujących w danym powiecie a zamieszkałych w innym) grafu mobilności;
- Emigracja (mobility out) - suma wag wychodzących krawędzi (liczby osób zamieszkałych w danym powiecie a pracujących w innym) grafu mobilności.

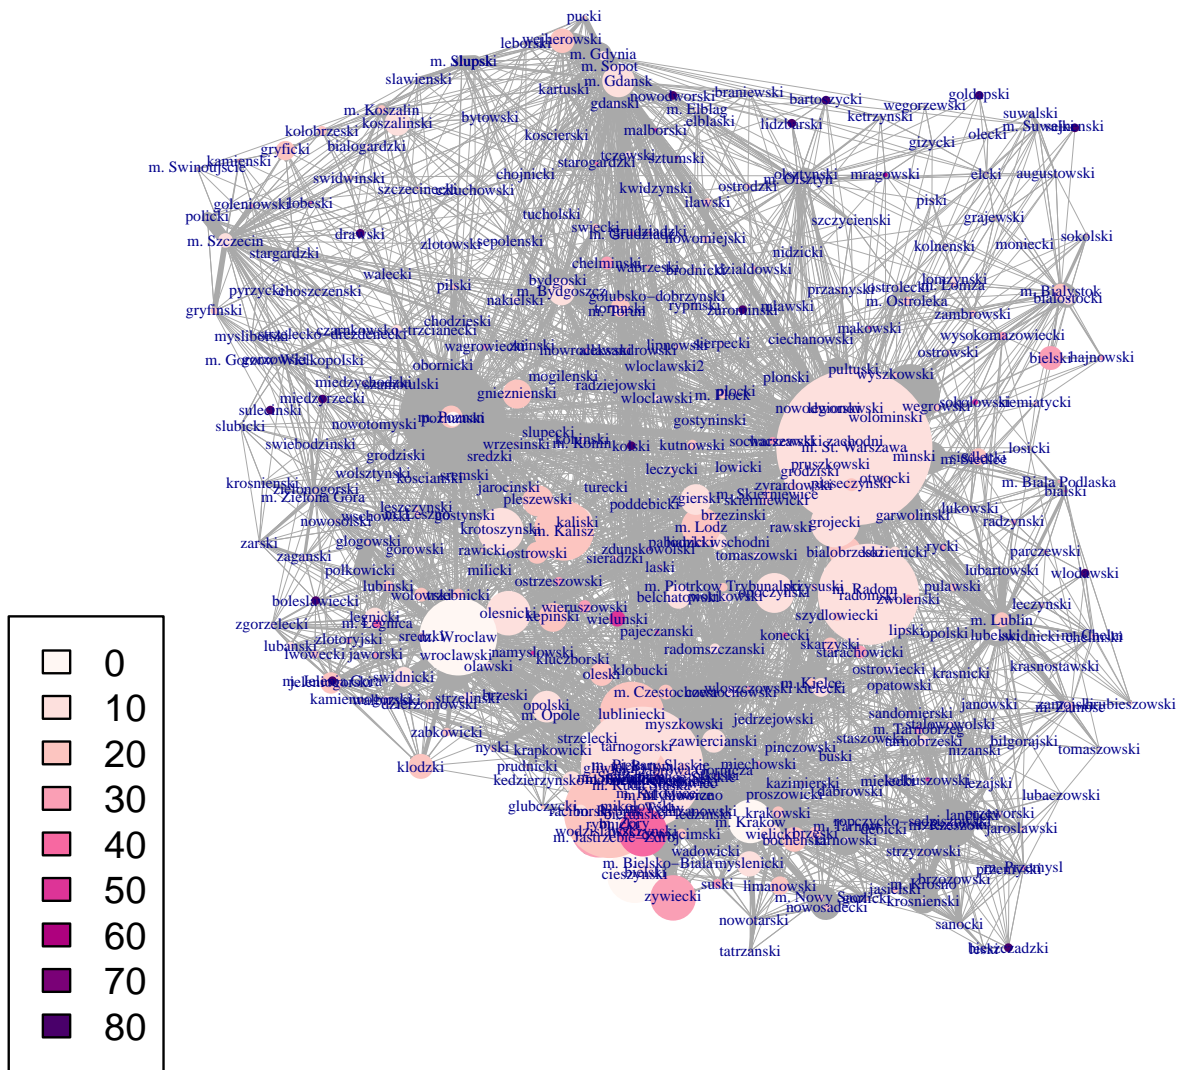
4) Współrzędne geograficzne centroidów powiatów długość i szerokość (longitude/latitude) w stopniach. Policzyliśmy również odległości radialne między centroidami powiatów $d(x,y)$ w stopniach. Stworzyliśmy miary zależności geograficznych dla każdego powiatu y z uwzględnieniem innych 379 powiatów x jak: $neighbors_{arr}(y) = \sum_{x \neq y} \frac{arrSARS(x)}{d(x,y)}$ i $neighbors_{size}(y) = \sum_{x \neq y} \frac{sizeCOVID(x)}{d(x,y)}$ wskazujące na potencjalne korelacje przestrzenne

5) Wyniki z Państwowej Komisji Wyborczej (PKW [44]) - poparcie dla partii PiS, gdyż ze względu na brak badań sondażowych z dokładnością do powiatu, to właśnie preferencje wyborcze są bardzo dobrym wskaźnikiem społecznych postaw w społecznościach lokalnych (Jarynowski and Klis [26]).

Mobilność i migracja oraz w mniejszym stopniu inne demograficzne-społeczne zróżnicowanie okazały się już kluczowymi się czynnikami dynamiki zakażeń SARS-CoV-2 w ujęciu regionalnym m.in. w USA (Messner and Payson [37]), Chinach (Jia et al. [31]), w Niemczech (Felbermayr et al. [12], Mense and Michelsen [36]), we Francji (Pullano et al. [46]) oraz międzypaństwowo w Europie (Sannigrahi et al. [50]), stąd można się również spodziewać podobnych wyników w Polsce [Rys. 3].

WYNIKI


Zróżnicowanie przestrzenne w Polsce nie dotyczy tylko Śląska [Rys. 1, 3] i naszym zadaniem jest przedstawienie tej skomplikowanej struktury. Czynnikiem sprawczym postępu/propagacji pandemii koronawirusa jest mobilność ludzi (Belik et al. [3]). W układzie hierarchicznym (dendrogramy) korelacji można zauważyć cluster silnie dodatnio skorelowanych zmiennych mobilnościowych prostych z wiekiem i uprzemysłowieniem populacji (lewy górny róg Rys. 4). Kolejnym klastrem są zmienne związane z zaludnieniem, mobilnością złożoną i liczbą przypadków



Rysunek 3. Mapa dynamiki zakażeń (wierzchołki - powiaty, kolor oznacza czasy dojścia (w dniach), wielkości wierzchołków - liczba przypadków; Krawędzie skierowane- migracje pracownicze między powiatami)

COVID-19 (środkowe pasma Rys. 4). Ostatnim klastrem (prawy dolny róg Rys. 4) odnosi się zmiennych lekko negatywnie skorelowanych związanych z geograficznymi i społecznymi aspektami jak również czasem dojścia SARS-CoV-2.

Analiza regresji liniowych modeli pełnych [Rys. 5] wskazuje na niewielką (na poziomie istotności statystycznej) rolę bliskości geograficznej pojawiania się pierwszych przypadków na czas introdukcji zakażenia w nowe miejsce oraz małą (ale istotną statystycznie) rolę grupowania się powiatów o podobnej liczbie przypadków. Zmienność czas dojścia w powiatach najlepiej wyjaśnia (6%) zlogarytmowana mobilność, co tym bardziej świadczy o nieliniowym charakterze

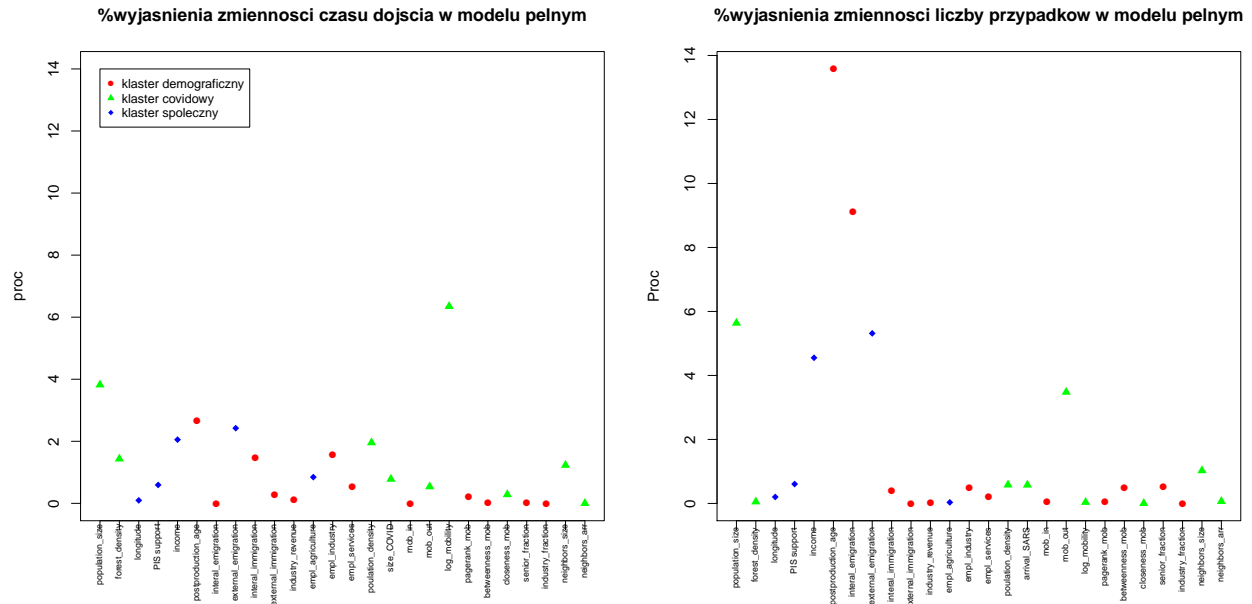


Rysunek 4. Macierz korelacji Pearsona między zmiennymi branymi pod uwagę w analizie w układzie hierarchicznym

relacji. W przypadku liczby przypadków, zdecydowanie najlepszą moc wyjaśniania zmienności (14%) ma liczba osób w wieku poprodukcyjnym. Wiąże się to na pewno z nadreprezentacją przebiegów objawowych zakażenia SARS-CoV-2 u osób starszych (ECDC [10]), ale możliwe są również związki na poziomie społeczno-ekonomicznych. Następnymi czynnikami są emigracje: wewnętrzna (9%) i zewnętrzna (5%) oraz mobilność wyjazdowa (4%), co może się wiązać z falą powrotów z obszarów o większej chorobowości populacyjnej (prewalencji) SARS-CoV-2, ale też również charakterem społeczno-ekonomicznym przyczyn decyzji o wyjazdach na pobyt stały. Z istotnych czynników warto jeszcze wyróżnić wielkość populacji (6%) oraz dochód (4%).

Analiza głównych składowych (PCA) na wszystkich zmiennych ujawnia 3 główne klastry również oznaczone na Rys. 5 (w nawiasie procent wyjaśnianej zmienności):

- demograficzny (45%) - ("postproduction_age", "interal_emigration", "interal_immigra-



Rysunek 5. Liniowy model predykcyjny czasów dojscia (lewy - model daje 29% wyjaśnionej zmienności) i liczby przypadków (prawy - model daje 47% wyjaśnianej zmienności) na wszystkich niewspółliniowych (niebędących liniową kombinacją innych zmiennych) zmiennych. Na osi y przedstawiono % wyjaśnianej zmienności dla każdej ze zmiennych na osi x. Punkty oznaczono i pokolorowano zgodnie z klasyfikacją PCA (jak w legendzie dla obu wykresów)

tion", "external_immigration", "industry_revenue", "empl_industry", "empl_services", "mob_in", "mobility", "pagerank_mob", "betweenness_mob", "senior_fraction", "industry_fraction") uwzględniający zmienne związane z osobami starszymi, strukturą zatrudnienia i mobilnością;

- covidowy (11%) - ("population_size", "forest_density", "poulation_density", "arrival_SARS", "size_COVID", "mob_out", "log_mobility", "closeness_mob", "neighbors_size", "neighbors_arr") uwzględniający zmienne związane z pandemią, zaludnieniem, korelacjami przestrzennymi i migracją nieliniową/emigracją;
- społeczne (8%) - ("longitude", "PiS support", "income", "external_emigration", "empl_agriculture") uwzględniający zmienne związane z odległością od granicy niemieckiej, dochodem, emigracją, rolnictwem i konglomeratem zmiennych społecznych kryjących się za poparciem partii PiS.

Należy zwrócić uwagę, że klastrowanie metodą PCA różni się od klastrowania hierarchicznego

koleracji [Rys. 4] m.in. uwzględnieniem relacji w jednym klastrze również istotnych relacji przeciwnych.

Jednak o dynamice transmisyjnej zakażeń w już dotkniętym obszarze decydują głównie czynniki behawioralne jak struktura kontaktów i stosowanie się do zaleceń mitygacyjnych (Jarynowski et al. [28, 29]). Dotychczasowa struktura zakażeń w Polsce (GIS [16]) i na świecie (ECDC [10]) sugeruje główną ścieżkę transmisji w ramach intensywnych i długotrwałych kontaktów (zakażenia domowe i zakładowe stanowią około 75% zakażeń). Co wiąże się z inną funkcją mobilności, ale już w mniejszym stopniu, czyli wzmożenia transmisji w obszarze już zapowietrzonym. Na podstawie analiz wśród użytkowników smartfonów z włączoną geolokalizacją i połączeniami internetowymi spadek mobilności do wartości bazowych w czasie największych ograniczeń w ogólnej populacji mieścił się w przedziale 20-50% (Krueger [33]), a od momentu rozpoczęcia rozmrażania gospodarki mobilność powoli wraca do normy. Warto zwrócić uwagę, że mobilność na Śląsku spadła w czasie restrykcji wyraźniej słabiej niż w pozostałych obszarach Polski (Selectivv [51]).


Mamy do czynienia z układem zmiennych bardzo silnie skorelowanych [Rys. 4]. Mobilność/Migracja pełni różne funkcje w wyjaśnianiu zmienności. Dokonano selekcji modelu głównego (bez uwzględnienia korelacji przestrzennych i interakcji między liczbą przypadków i czasem dojścia, aby uwidocznic czynniki niezwiązane bezpośrednio z pandemią) metodą mieszaną backward/forward przy użyciu kryterium Akaikego [Tab. I]. W związku z powyższym wyselekcjonowane regresje wielorakie [Tab. I] należy interpretować z uwzględnieniem macierzy korelacji [Rys. 4] oraz % wyjaśnienia zmienności w modelu pełnym.

Inne miary centralności (Jarynowski et al. [24]) bazujące na sieci przepływów pracowniczych jak closeness, pagerank i betweenness również istotnie korelują ze zmiennymi wyjaśnionymi (zwłaszcza closeness z czasem dojścia i pagerank z liczbą przypadków). Ze względu na zaobserwowane nieliniowości logarytm z mobilności został wzięty również pod uwagę i koreluje on silnie z czasem dojścia. Poza mobilnością/migracją najwyższą pozytywną korelację z liczbą zakażeń mamy z liczbą osób zatrudnionych w przemyśle [Rys. 4]. Z uwagi na przepływy ludności w postaci dojazdów do pracy i interakcjami między pracownikami, przemysł jest sektorem, który właściwie nie daje się zdigitalizować i przestawić na pracę zdalną (PolskiInstytutEkonomiczny [45]). Czas dojścia koreluje najmocniej z mobilnością/migracją (zwłaszcza kierunek wychodzący co sugerować może przede wszystkim odpływ pracowników zwłaszcza za granicę i wiązać się z ich powrotami do Polski). Ważna dla szybkiego pojawienia się wirusa była również aktywność zawodowa, zwłaszcza w przemyśle.

Predictors	Arrival time (in days) of first SARS-CoV-2 case			No. confirmed SARS-CoV-2 cases		
	Estimates	CI	p	Estimates	CI	p
(Intercept)	97.2081	71.7159 – 122.7003	<0.001	2.1558	-69.1973 – 73.5089	0.953
Forest density	8.3439	-2.4153 – 19.1031	0.128			
Longitude (East-West)	0.5790	-0.2005 – 1.3584	0.145	-4.6957	-9.0974 – -0.2941	0.037
PIS (support in EU election 2019)	-0.2191	-0.4065 – -0.0316	0.022	1.4375	0.5736 – 2.3014	0.001
No. people in post-productive age	-0.0001	-0.0001 – 0.0000	0.115			
Emigration internal	0.0027	-0.0006 – 0.0059	0.107			
Emigration external	-0.0119	-0.0240 – 0.0002	0.054	0.1646	0.0993 – 0.2299	<0.001
Immigration internal	-0.0025	-0.0049 – -0.0001	0.044			
Employment in agriculture	-0.0003	-0.0007 – 0.0001	0.138			
Incoming Mobility (in centrality)	0.0002	-0.0000 – 0.0004	0.096			
Outgoing Mobility (out centrality)	0.0005	-0.0001 – 0.0010	0.082	0.0063	0.0044 – 0.0082	<0.001
log_mobility (centrality in mobility graph)	-8.3480	-10.8195 – -5.8765	<0.001			
Employment in industry				-0.0030	-0.0057 – -0.0004	0.025
Employment in services				0.0011	0.0006 – 0.0016	<0.001
Industry Employment fraction				0.0001	0.0000 – 0.0002	0.028
Population size						
Population density						
Immigration External						
Fraction of seniors						
Income						
Industry revenue						
Observations (poviats)	380			380		
R ² / R ² adjusted	0.270 / 0.248			0.446 / 0.436		

Tablica I. Regresja liniowa wieloraka (selekcja wg. kryterium Akaikego). Zmienne zależne: czasy dojścia i liczba przypadków (UWAGA - inne modele selekcji i pogębiona analiza zostaną uwzględnione w kolejnych wersjach pracy)

Policzyliśmy regresje na czasy dojścia COVID-19 do każdego powiatu i na liczbę przypadków. Bardzo silny związek między mobilnością we wszystkich wymiarach oraz poparciem dla partii rządzącej a liczbą przypadków w modelu wyjaśniającym zmienność aż w 45% świadczy o społeczno-ekonomicznym uwarunkowaniu pandemii [Tab. I]. Dodatkowo na progu istotności znajduje się długość geograficzna (proxy odległości od atraktorów gospodarczych w Europie Zachodniej, w których wcześniej niż w Polsce występowało zakażenie). Poparcie dla partii PiS jest również istotnym statystycznie predyktorem dynamiki zakażeń, co wiąże się pośrednio ze strukturą społeczną elektoratu. W przypadku czasów dojścia model jest znacznie słabiej dopasowany a jedynie mobilność i imigracja wewnętrzna i emigracja międzynarodowa istotnie przyspieszały pojawienie się pierwszych przypadków SARS-CoV-2. Dodatkowo warto zwrócić uwagę, że wielkość populacji i gęstość oraz dochód osób oraz przedsiębiorstw nie różnicuje istotnie zmienności dynamiki zakażeń.

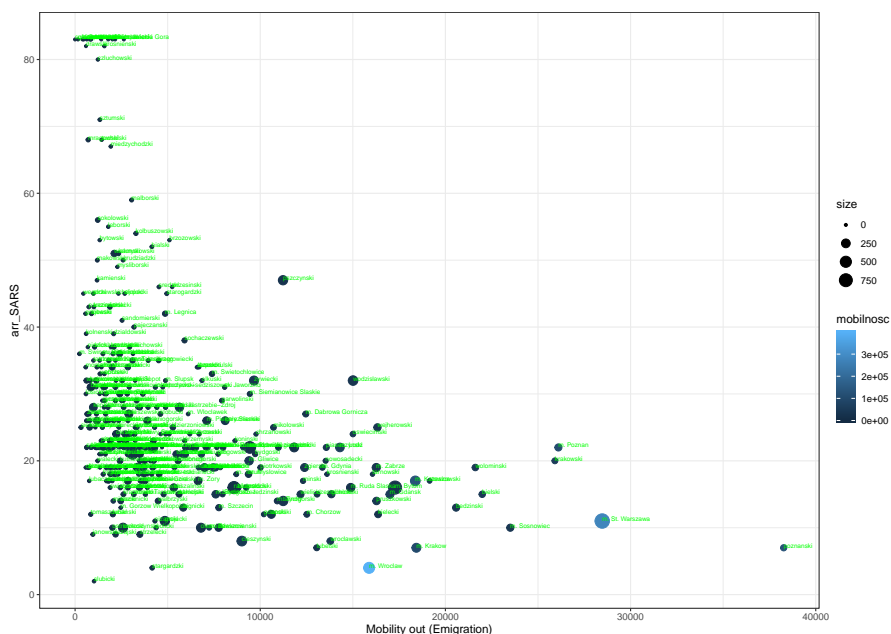


Rysunek 6. Zależność między mobilnością a liczbą zakażeń (w skali podwójnie logarytmicznej zmiennych). Wielkość punktów odpowiada odwrotności czasu dojścia, a kolor poparciu dla partii rządzącej dla danego powiatu.

W konwencji wykresu rozrzutu obserwujemy [Rys. 6], że liczba zakażeń bardzo wyraźnie koreluje z mobilnością (po logarytmowaniu) [Rys. 6] i widzimy które powiaty względnie gorzej (powiaty śląskie i łódzkie) lub lepiej (powiaty wielkopolskie, lubuskie i podkarpackie) sobie radziły niżby to wynikało z prostej regresji. W 108 powiatach nie odnotowano żadnego nowego przypadku między 1-22.05.2020 (czyli dłużej niż referencyjny czas eliminacji wynoszący około 2 tygodnie).

Czas dojścia SARS-CoV-2 jest związany mocno z mobilnością/migracją zewnętrzną (emigracją) [Rys. 7]. 12 powiatów 22.05.2020 nie zareportowało ani jednego przypadku (stąd otrzymało czas maksymalny dojścia równy 83 dni).

Zastosowano klastrowanie przestrzenne (Jarynowski and Belik [23]), żeby zobaczyć czy powiaty o intensywnej liczbie zakażeń lub braku/małej liczbie zakażeń występują w klastrach geograficznych. Liczbę przypadków przeskalowaną tak, żeby odpowiadała zmienności (odchylenie standardowe) wymiarom szerokości i długości geograficznej. Otrzymaliśmy m.in. duży klaster (nr 6 niebieski [Rys. 8]) obejmujący wolne/bądź o małej liczbie zakażeń obszary ciągnące się od Województwa Lubuskiego przez Kujawy, Kurpie po graniczne powiaty Województwa Warmińsko-

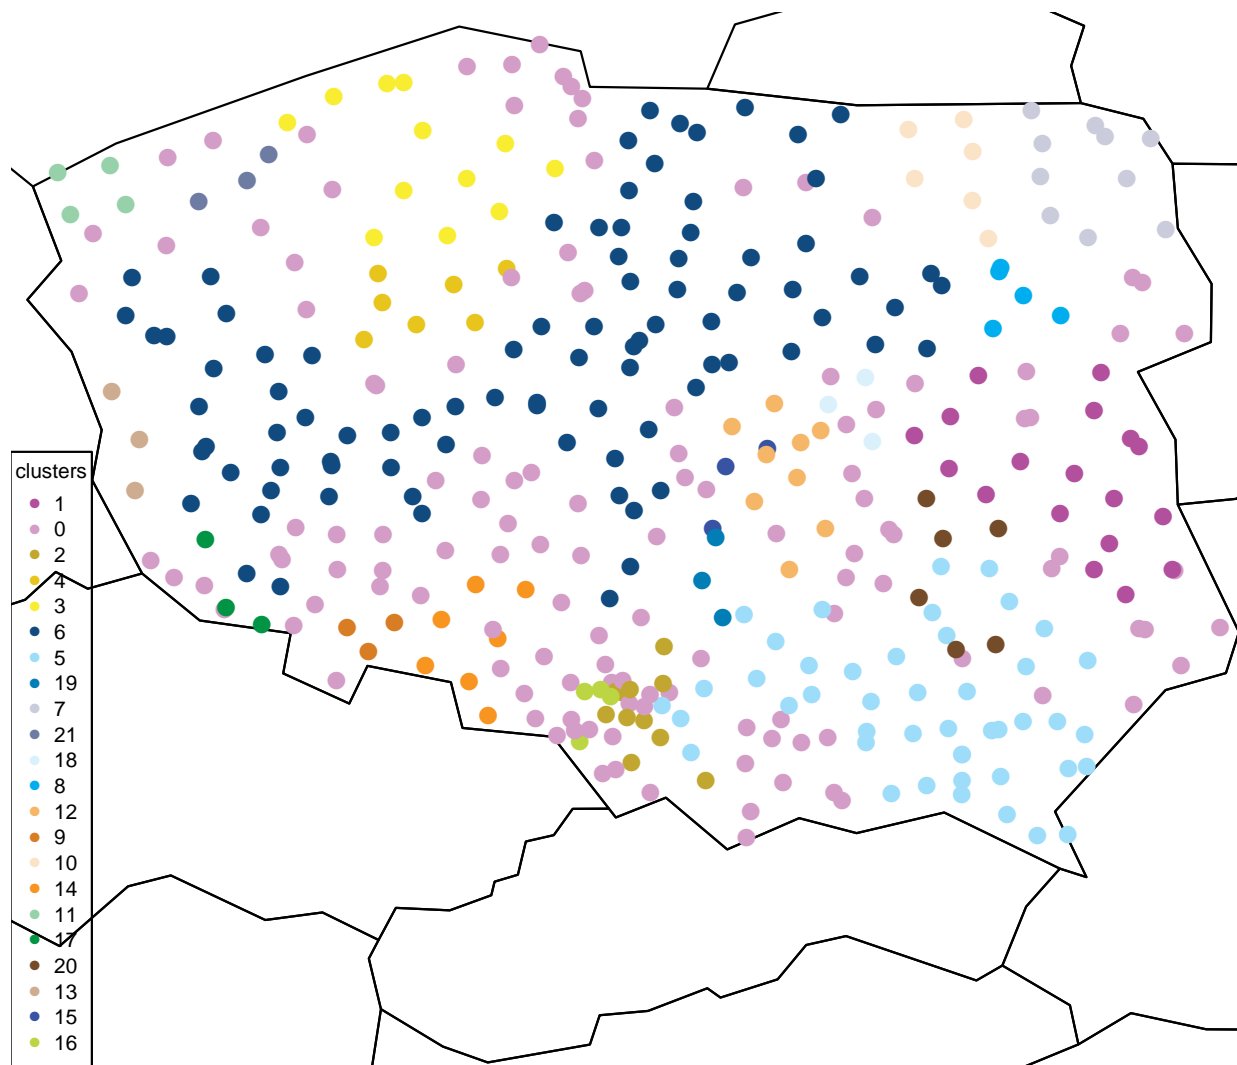


Rysunek 7. Zależność między emigracją a czasem dojścia zakażenia (w dniach od introdukcji do Polski 04.03). Wielkość punktów odpowiada liczbie przypadków, a kolor ogólnej mobilności dla danego powiatu.

Mazurskiego. Z drugiej strony otrzymaliśmy klastry o dużej zakaźności jak GOP, czy Warszawa.

WNIOSKI

Dzięki mądrymu korzystaniu z doświadczeń obecnej fazy epidemii, możemy wprowadzić zarządzania epidemiologicznego, dzięki czemu nasze służby medyczne będą mogły w przypadku fali jesiennej sprawniej gromadzić i analizować dane, dystrybuować zasoby, a także zidentyfikować potencjalnie zakażonych i poddawać ich izolacji. Covid-19 uderzył najwcześniej i najmocniej w regiony, najlepiej skomunikowane i najbogatsze (np. aglomeracja Śląska, Warszawa, Wrocław), a najłabiej biedniejsze i gorzej skomunikowane (np. w pas relatywniejszej biedy od Ziemi Lubuskiej po Mazury - klaster 6) [Rys. 8]. Pandemia dotarła w peryferia cywilizacyjno-gospodarcze statystycznie istotnie później (porównując czasy dojścia) i w mniejszym stopniu (porównując liczbę przypadków) [Rys.4, Tab. I]. Jednak odpływowy charakter regionów z dużą liczbą emigrantów istotnie przyspieszył pojawienie się tam pierwszych przypadków i ognisk. Wirus SARS-CoV-2 oficjalnie później dotarł w słabiej zurbanizowane (np. mocno zalesione) obszary. Zdaje się jednak, że wpływ (zwłaszcza negatywny) nierówności społecznych widoczny np. w USA, gdzie biedniejsze hrabstwa (z dużą frakcją ludzi ubogich) istotnie gorzej sobie radzą



Rysunek 8. Dbscan - klastrowanie przestrzenne z dodatkowym wymiarem - normalizowana liczbą przypadków. Parametryzacja $\text{eps}=0.5$, minimalna liczba powiatów w klastrze=3. Otrzymano 21 klastrów i 108 powiatów zostało niesklasyfikowanych (klaster 0)

ze zwalczaniem COVID-19 (Gelfand et al. [15], Messner and Payson [37]), co nie ma odzwierciedlenia w Polsce (dochód sprzyja rozwojowi epidemii, aczkolwiek nieistotnie [Rys.4, 5]). Co za tym idzie, hipoteza o utrwalaniu nierówności (Domanski [6]), raczej nie sprawdzi się na poziomie ekologicznym (zagregowanym do powiatu). Być może właśnie dzięki bardzo niskiej centralności w światowej sieci przepływów osób (interconnectivity (Bartosiak [2])). Również dane o umiERALNOŚCI populacyjnej w ujęciu indywidualnym z Europy np. ze Szwecji (bez uwzględnienia ludności napływowej) świadczą o tym, dochód zwiększa ryzyko śmierci z COVID-19 (Drefahl et al. [7]), co między innymi można tłumaczyć inną niż w Polsce strukturą zamieszkania osób

starszych (Oczkowska [41]). Polska miała więcej czasu niż inne kraje europejskie, aby podjąć odpowiednie decyzje na podstawie wiedzy epidemiologicznej dostępnej na tamten czas. Emigracja zarobkowa - w rozumieniu potoków pracowników zamieszkujących polskie powiaty, a pracujących za granicą, istotnie statystycznie przyspieszyła pojawienie się SARS-CoV-2. Autorzy artykułu już w styczniu 2020, wskazywali że to najprawdopodobniej kontynentalną dojdzie do introdukcji wirusa do Polski określanego wtedy mianem 2019-nCoV (Interdisciplinary [22]). Co ważne, dochód a co za tym idzie zdolność do masowej turystyki i podróży biznesowych nie miał wpływu na wyjaśnienie zmienności ani liczby przypadków, ani czasu dojścia zakażenia, co wyróżnia Polskę od innych państw jak Niemcy (Felbermayr et al. [12]) czy USA (Killeen et al. [32]). Można wytłumaczyć to wciąż niską siłą nabywczą Polaków (przeciętny Polak podróżuje za granicę turystycznie 5 razy rzadziej niż Niemiec (Jarynowski et al. [29])). Ponadto brak znaczenia imigracji zewnętrznej wiąże się z jej marginalnym wymiarem w 2017 roku (GUS nie udostępnił nowych danych), i być może na aktualnych danych efekt napływu zagranicznych imigrantów byłby wyraźniejszy ze względu na wykładniczy przyrost imigrantów w ostatnich kilku latach np. w Wielkopolsce (Paradowski et al. [42]). Globalne miary centralności (jak closeness, pagerank, czy betweenness) nie wyjaśniają zmienności w dynamice zakażeń lepiej niż miary lokalne (centralność wierzchołkowa ważona całkowita oraz wchodząca i wychodząca), w czym Polska różni się np. od innych krajów (Felbermayr et al. [12], Jia et al. [31], Maier and Brockmann [35], Puliano et al. [46]). Oznacza to relatywnie krótkie łańcuchy zakażeń, co wiąże się prawdopodobnie z jednoczesną introdukcją wirusa do dużej liczby powiatów, będących źródłem dla najczęściej tylko jednego sąsiedniego powiatu. Tą interpretację potwierdza również fakt, że geograficzna bliskość powiatów już zapowietrzonych nie wpłynęła istotnie na czas introdukcji, a jedynie liczba przypadków w sąsiednich przypadkach istotnie wpływa na czas dojścia i liczbę przypadków w danych powiecie. W naszych badaniach potwierdzamy, że do głównych przyczyn sprzyjających dynamice zakażeń należy koncentracja przemysłu oraz usług (Sitek et al. [52]) i osób starszych (zwłaszcza w DPS-ach i ZOL-ach). Zaznaczyć należy, że gęstość zaludnienia, czy wielkość populacji tracą moc predycją wobec dynamiki zakażeń na rzecz innych zmiennych [Tab. I]. Wielkość, czy frakcja populacji senioralnej również traci na ważności w modelu selektywnym [Tab. I]. Oznaczać to może, że rozmiar pandemii ma przede wszystkim związek ze społeczno-gospodarczym uwarunkowaniem regionów. Istotny statystycznie związek liczby przypadków z poparciem partii aktualnie rządzącej ujawnia prawdopodobny związek między elektoratem PiS-u (duże zakłady przemysłowo-wydobywcze oraz średniej wielkości miasta, duży odsetek osób starszych) a po-

datnością na wybuch ognisk. Również może być to związane z poziomem skuteczności władz samorządowych w zarządzaniu epidemią na szczeblu lokalnym. Należy zwrócić uwagę, że obszary które mają potwierdzone doświadczenie w walce chorobami zakaźnymi (np. zakażeniami szpitalnymi szczepami NDM-2 Jarynowski et al. [25]) jak Poznań radzą sobie z pandemią lepiej, niż to wynika z predykcji modelu [Rys. 6]. Podobnego scenariusza możemy się spodziewać w czasie prawdopodobnej drugiej fali zakażeń jesienią 2020, do czego można się już przygotować planując czasowo-przestrzenne lokowanie zasobów.

Podsumowując, służby epidemiologiczne (zwłaszcza Inspekcja Sanitarna) powinny zostać szczególnie wzmocnione w regionach wysoce skomunikowanych, o wysokim odsetku osób starszych oraz o charakterystyce przemysłowej/o dużym zatrudnieniu, aby mogły szybko i skutecznie opracowywać oraz wygaszać ogniska (Krueger [33]) w zakładach pracy, czy pobytu osób starszych. Należy zwrócić uwagę, że wiele Stacji Sanitarno-Epidemiologicznych już w kwietniu 2020 przekroczyło budżet zaplanowany na cały rok 2020 (WSSElubuskie [60]), a samorządy terytorialne oraz organy administracji rządowej w regionach w różnym stopniu współfinansują zwalczanie pandemii. Wskazywanie szczególnie zagrożonych powiatów ma na celu wsparcie walki z pandemią (zwłaszcza kadrowego w celu pogłębionych i jak najszybszych opracowań ognisk zakażeń) i w żadnym razie nie może być odczytywane jako stygmatyzowanie poszczególnych powiatów i ich mieszkańców, co wiąże się z oderwaną od rzeczywistego zagrożenia percepcją ryzyka (Jarynowski et al. [27]). Pomimo stosowania obostrzeń kosztujących już polską gospodarkę setki miliardów złotych (Pinkas et al. [43]), nie zastosowano w możliwym stopniu prawdopodobnie jak najbardziej kosztowo-efektywnej (poza izolacją standardową) techniki mitygacyjnej, czyli trop, śledź i wygaszaj. Wzmocnienie służb santranych przez specjalistów służby zdrowia oraz ich pomocników ma już miejsce w wielu krajach i przykładowo docelowo nowych etatów ma przybyć około 20 tys w Wielkiej Brytanii oraz 200 tys w USA (CNBC [5]). Warto pamiętać, że w krajach anglosaskich już istnieje profesja specjalisty od opracowywania i wygaszania ognisk zakażeń (Disease Intervention Specialist), co nie ma odpowiednika w Polsce. Jednak w tym celu potrzeba zabezpieczyć do jesieni więcej przeszkolonych rąk do pracy oraz wsparcia informatycznego w inspekcjach sanitarnych ze względu na narastający zakres nakładanych obowiązków zwłaszcza w najbardziej zagrożonych powiatach, które w tej pracy identyfikujemy. Odpowiednie wykorzystanie skąpych zasobów logistycznych (ludzkich i informatycznych) to kluczowa dziedzina w dobie kryzysu epidemicznego (Krzowski and Trzos [34]).

Opracowania statystyczne i epidemiologiczne oraz badania empiryczne na polskim społec-

czeństwie są podstawowym warunkiem poprawnego zarządzania kryzysowego ze względu na specyfikę polskiego społeczeństwa (Interdisciplinary [21]). Należy jednak pamiętać, że dane o dynamice zakażeń pochodzą ze społecznej sprawozdalności, w związku tym nie posiadają one charakteru oficjalnego i należy zachować powściągliwość w interpretacji przedstawionych obserwacji. Również dane GUS-u np. dotyczące imigracji są już nieaktualne. Warto też zwrócić uwagę na zróżnicowanie regionalne w liczbie wykonanych testów (brak danych z dokładnością do powiatu), gdyż bogate regiony (jak Warszawa, GOP, Zagłębie Miedziowe) wykonują relatywnie więcej testów (Rogalski [49]). Należy również być świadomym ograniczeń rozumowania epidemiologicznego, którego wnioskowanie przyczynowo-skutkowe jest znacznie niżej ułożone w hierarchii dowodów naukowych niż np. podwójnie ślepe losowe badania kliniczne. Jednakże takie projekty mogłyby uzupełnić luki w socjo-medycznych badaniach nad zbiorowym działaniem w zagrożeniu istotną dla zdrowia publicznego chorobą zakaźną.

Adnotacje. Dane i analizy zostały zdeponowane w formie interaktywnej: <https://www.kaggle.com/andrzejarynowski/spatial-covid-19-in-poland/>. Autorzy pragną podziękować za wsparcie NCN (2016/22/E/HS2/00034), Dolnośląskiemu Urzędowi Marszałkowskiemu (E/3026/2020/I), Komisji Europejskiej (EOSC- 48) oraz epidemiologom z Państwowej i Wojskowej Inspekcji Sanitarnej jak Ireneuszowi Skawinie, ekonomistom jak Marioli Chrzanowskiej oraz specjalistom zdrowia publicznego i socjologii medycyny za konsultacje.

BIBLIOGRAFIA

- [1] AmbasadaKultury (2020). koronawirus mapa polski wedlug powiatow. <https://t.co/iAqzy8brWG>. Accessed: 2020-05-27.
- [2] Bartosiak, J. (2019). *Przeszłość jest prologiem*. Zona Zero.
- [3] Belik, V., T. Geisel, and D. Brockmann (2011). Natural human mobility patterns and spatial spread of infectious diseases. *Physical Review X* 1(1), 011001.
- [4] Chudy, F. (2020). Covid-19 prognoza. https://docs.google.com/spreadsheets/d/1ZIdpVF5AfbkFvGxey92RQLjRVWF8_owN5-hSbFDL8g0/edit#gid=254242832. Accessed: 2020-05-27.

- [5] CNBC (2020). how many contact tracers the u.k. has hired. <https://www.cnb.com/2020/05/18/uk-contact-tracer-jobs-confusion.html>. Accessed: 2020-05-27.
- [6] Domanski, H. (2020). pandemia moze byc zjawiskiem wzmacniajacym hierarchie społeczna. <http://naukawpolsce.pap.pl/aktualnosci/news%2C82066%2Cprof-domanski-pandemia-moze-byc-zjawiskiem-wzmacniajacym-hierarchie>. Accessed: 2020-05-27.
- [7] Drefahl, S., M. Wallace, E. Mussino, M. Kolk, M. Brandén, B. Malmberg, M. Kolk, M. Brandén, and B. Malmberg (2020). Socio-demographic risk factors of covid-19 deaths in sweden : A nationwide register study. *Stockholm Research Reports in Demography* 23.
- [8] Drejerska, N., M. Chrzanowska, and I. Pomianek (2014). Strefa podmiejska warszawy.
- [9] Duplaga, M. (2020). Determinants and consequences of limited health literacy in polish society. *International Journal of Environmental Research and Public Health* 17(2), 642.
- [10] ECDC (2020). Enhanced surveillance data. <https://qap.ecdc.europa.eu/public/extensions/COVID-19/COVID-19.html>. Accessed: 2020-05-27.
- [11] exmetrix (2020). Najnowsza prognoza rozwoju pandemii covid-19. <http://www.exmetrix.com/pl/posty/koronawirus-w-polsce-aktualna-prognoza-exmetrix/>. Accessed: 2020-05-27.
- [12] Felbermayr, G., J. Hinz, and S. Chowdhry (2020). Apres-ski: The spread of coronavirus from ischgl through germany. https://www.ifw-kiel.de/fileadmin/Dateiverwaltung/IfW-Publications/Gabriel_Felbermayr/Apres-ski__The_Spread_of_Coronavirus_from_Ischgl_through_Germany/coronavirus_from_ischgl.pdf.
- [13] Gambin, A. and M. Rosniska (2020). Covid-19. <https://covid19.mimuw.edu.pl>. Accessed: 2020-05-27.
- [14] GazetaWyborcza (2020). Koronawirus w polsce. <https://biqdata.wyborcza.pl/biqdata/7,159116,25755719,koronawirus-w-polsce-europie-i-na-swiecie-mapy.html>. Accessed: 2020-05-27.
- [15] Gelfand, M., J. C. Jackson, X. Pan, D. Nau, M. Dagher, and C.-Y. Chiu (2020). Cultural and institutional factors predicting the infection rate and mortality likelihood of the covid-19 pandemic.
- [16] GIS (2020). Struktura zakazen sars-cov-2 /8 kwietnia 2020 r/. <https://gis.gov.pl/bez-kategorii/struktura-zakazen-sars-cov-2-8-kwietnia/>. Accessed: 2020-

05-27.

- [17] Gonczarek, A. and M. Wojcik (2020). Jak przewidzieć rozwój pandemii sarscov-2 w polsce przy pomocy modeli matematycznych i uczenia maszynowego. <http://alphamoon.ai/blog/2020/03/25/jak-przewidziecrozwoj-pandemii-sars-cov-2-w-polsce/>. Accessed: 2020-05-27.
- [18] GUS (2020a). Bank danych lokalnych. <https://bdl.stat.gov.pl/BDL/start>. Accessed: 2020-05-27.
- [19] GUS (2020b). Gusdashboard. <https://dashboard.stat.gov.pl>. Accessed: 2020-05-27.
- [20] GUSPoznan (2020). Migracje pracownicze. <https://poznan.stat.gov.pl>. Accessed: 2020-05-27.
- [21] Interdisciplinary (2020a). Empiryczne badania społeczne w polsce istotne dla zdrowia publicznego i epidemiologii w kontekście covid-19. <http://interdisciplinary-research.eu/badania-empiryczne-spoeczne-w-polsce-istotne-dla-zdrowia-publicznego-i-epidem>. Accessed: 2020-05-28.
- [22] Interdisciplinary (2020b). Kiedy 2019-ncov trafi do polski? <http://interdisciplinary-research.eu/kiedy-2019n-cov-trafi-do-polski>. Accessed: 2020-03-04.
- [23] Jarynowski, A. and V. Belik (2020). African swine fever (asf) virus propagation in poland (spatio-temporal analysis). <https://bit.ly/3dv8ysS>.
- [24] Jarynowski, A., A. Buda, and P. Nyczka (2014). *Obliczeniowe nauki społeczne w Praktyce*. WN:Głogów.
- [25] Jarynowski, A., A. Grabowski, et al. (2019). Niewykorzystany potencjał systemów informatycznych w epidemiologii zakażeń szpitalnych w polsce. *Collegium of Economic Analysis Annals* (56), 261–273.
- [26] Jarynowski, A. and M. Klis (2012). Socio-economic models of divorces in different societies. *XVIII Krajowa Konferencja Zastosowan Matematyki w Biologii i Medycynie, Krynica Morska*.
- [27] Jarynowski, A., M. Wójta-Kempa, and V. Belik (2020). Trends in perception of covid-19 in polish internet. *medRxiv*.
- [28] Jarynowski, A., M. Wójta-Kempa, D. Płatek, and V. Belik (2020). Social values are significant factors in control of covid-19 pandemic—preliminary results.
- [29] Jarynowski, A., M. Wójta-Kempa, D. Płatek, and K. Czopek (2020). Attempt to understand public health relevant social dimensions of covid-19 outbreak in poland. *Society Register* 4(3), 7–44.

- [30] Jasinski, M. (2020). Prognozy rozwoju epidemii koronawirusa. <http://www.fizykwyjasnia.pl/na-biezaco/prognozy-rozwoju-epidemii-koronawirusa/>. Accessed: 2020-05-27.
- [31] Jia, J. S., X. Lu, Y. Yuan, G. Xu, J. Jia, and N. A. Christakis (2020). Population flow drives spatio-temporal distribution of covid-19 in china. *Nature*, 1–11.
- [32] Killeen, B. D., J. Y. Wu, K. Shah, A. Zapaishchykova, P. Nikutta, A. Tamhane, S. Chakraborty, J. Wei, T. Gao, M. Thies, et al. (2020). A county-level dataset for informing the united states’ response to covid-19. *arXiv preprint arXiv:2004.00756*.
- [33] Krueger, T. (2020). Epidemia covid-19: Analiza sytuacji bieżącej i prognozy krótkoterminowe. https://mocos.pl/images/reports/20200513/wroclaw/report_wroclaw_20200513.pdf.
- [34] Krzowski, L. and A. Trzos (2020). Prewencja zachorowań, triage, zarządzanie i wstępna diagnostyka covid-19. *Na ratunek* 2(2).
- [35] Maier, B. F. and D. Brockmann (2020). Effective containment explains sub-exponential growth in confirmed cases of recent covid-19 outbreak in mainland china. *medRxiv*.
- [36] Mense, A. and C. Michelsen (2020). Pendlerverflechtungen haben starken einfluss auf die verbreitung des corona-virus. https://www.diw.de/de/diw_01.c.790305.de/publikationen/diw_aktuell/2020_0043/pendlerverflechtungen_haben_starken_einfluss_auf_die_verbreitung_des_corona-virus.html.
- [37] Messner, W. and S. E. Payson (2020). The influence of contextual factors on the initial phases of the covid-19 outbreak across us counties. *medRxiv*.
- [38] Mostowy, R. (2020). Analiza pandemii covid-19 w polsce w czasie rzeczywistym. <https://rmostowy.github.io/covid-19/czas-rzeczywisty/>. Accessed: 2020-05-27.
- [39] Neher, R. A., R. Dyrdak, V. Druelle, E. B. Hodcroft, and J. Albert (2020). Potential impact of seasonal forcing on a sars-cov-2 pandemic. *Swiss medical weekly* 150(1112).
- [40] Ochab-Marciniak, A. (2020). Koronawirusstatystykiaom. http://soft.ichf.edu.pl/ochab/coronavirus_poland/2020.04.08/koronawirus_statystyki.2020.04.08.html. Accessed: 2020-05-27.
- [41] Oczkowska, M. (2020). Bezpieczeństwo osób starszych w czasie pandemii covid-19: sytuacja mieszkaniowa osób w wieku 65 + w polsce na tle innych krajów europy. *Komentarze CenEA*, 1–7.
- [42] Paradowski, M. B., A. Jarynowski, K. Czopek, and M. Jelińska (2020). Peer interactions and second

- language learning: The contributions of social network analysis in immersion/study abroad vs at-home environments - preprint. <http://interdisciplinary-research.eu/wp-content/uploads/2020/05/paradowski-1.pdf>.
- [43] Pinkas, J., M. Jankowski, Łukasz Szumowski, A. Lusawa, W. S. Zgliczyński, F. Raciborski, W. Wierzbica, and M. Gujski (2020). Public health interventions to mitigate early spread of sars-cov-2 in poland. *Medical Science Monitor* 26.
- [44] PKW (2020). Wyniki głosowania na listy procentowo w powiatach w wyborach do parlamentu europejskiego. https://pe2019.pkw.gov.pl/pe2019/pl/dane_w_arkuszach. Accessed: 2020-05-27.
- [45] PolskiInstytutEkonomiczny (2020). Pandemics - zestaw narzędzi fiskalnych i monetarnych w dobie kryzysow. <http://pie.net.pl/wp-content/uploads/2020/04/PIE-Pandemics.pdf>. Accessed: 2020-05-27.
- [46] Pullano, G., E. Valdano, N. Scarpa, S. Rubrichi, and V. Colizza (2020). Population mobility reductions during covid-19 epidemic in france under lockdown.
- [47] Pyrc, K. (2020). Covid-19: liczba chorych bezobjawowych jest wieksza niz sadzono. <https://www.cm-uj.krakow.pl/index.php/collegium/aktualnosc/2542>. Accessed: 2020-05-27.
- [48] Rakowski, F. (2020). Predicting the course of the covid-19 epidemic in poland. <https://www.youtube.com/watch?v=Q00VrIZ69RY>. Accessed: 2020-05-27.
- [49] Rogalski, M. (2020). Covid-19 wedlug powiatow. https://docs.google.com/spreadsheets/d/1Tv6jKMUYdK6ws6SxxAsHVxZbglZfisC8x_HZ1jacmBM/edit?usp=sharing. Accessed: 2020-05-27.
- [50] Sannigrahi, S., F. Pilla, B. Basu, and A. S. Basu (2020). The overall mortality caused by covid-19 in the european region is highly associated with demographic composition: A spatial regression-based approach. *arXiv preprint arXiv:2005.04029*.
- [51] Selectivv (2020). Sytuacja podczas covid-19 na podstawie danych z mobile. <https://selectivv.com/sytuacja-podczas-covid-19-na-podstawie-danych-z-mobile/>. Accessed: 2020-05-27.
- [52] Sitek, S., S. Pytel, and E. Zuzanska-Zysko (2020). Rozmieszczenie i zasieg wystepowania sars-cov-2 w wojewodztwie slaskim. <https://us.edu.pl/prof-s-sitek-prof-s-pytel-prof-e-zuzanska-zysko-rozmieszczenie-i-zasieg-wystep>

- [53] StatSoft (2020). Statystyczna analiza zachorowan na koronawirusa w polsce. <https://www.statsoft.pl/systemy-data-mining/statystyczna-analiza-zachorowan-na-koronawirusa-w-polsce/>. Accessed: 2020-05-27.
- [54] Szumowski, u. (2020). Z prof. lukaszem szumowskim rozmawia dorota losiewicz. <https://www.wsieciprawdy.pl/szumowski-w-sieci-niszcza-moja-rodzine-pnews-4394.html>. Accessed: 2020-05-27.
- [55] Tarnowski, P. (2020). wizualizacje dla powiatow. https://public.tableau.com/profile/piotrekt#!/vizhome/covid19_powiaty/covid19Podzianapowiaty. Accessed: 2020-05-27.
- [56] Trzos, A., Ł. Krzowski, and K. Długosz (2017). Specyfika działań ratownictwa medycznego. *Na Ratunek* 4, 17.
- [57] UMW (2020). Poland coronavirus data. <https://github.com/dtandev/coronavirus>. Accessed: 2020-05-27.
- [58] UWM (2020). Kierunki ostatnich podróży pacjentów z potwierdzonym zakażeniem. http://wirusnamapie.pl/?fbclid=IwAR28gtmw12XIr-P3oonfJXT6MZ1PoGDRdOGZ6TJ1LnkE_Uvon0HioNI3aRU. Accessed: 2020-05-27.
- [59] Wojta-Kempa, M. and A. Jarynowski (2020). Ocena poziomu poinformowania na temat przebiegu i skutkow pandemii covid-19. https://drive.google.com/file/d/1WijPJLcGEmEwaJfo6e8ZudvamNn0_D3K/view? Accessed: 2020-05-27.
- [60] WSSElubuskie (2020). Wydatki jednostek budzetowych. <https://shorturl.at/rwEFZ>. Accessed: 2020-05-27.