

Katarzyna Lisek 
Uniwersytet Jagielloński

Szanse i słabości wykorzystania *crowdsourcingu* do analizy treści

DOI: <http://dx.doi.org/10.18778/1733-8069.15.4.12>

Abstrakt Analiza treści jest metodą szeroko wykorzystywaną nie tylko w naukach społecznych, ale też studiach humanistycznych. Automatyzacja oraz wsparcie komputerowe tej metody cieszy się dużym zainteresowaniem badaczy w Polsce i na świecie. Nowe perspektywy dla rozwoju tej dziedziny może otworzyć *crowdsourcing*, to jest metoda wirtualnej współpracy, do której zapraszani są liczni, anonimowi użytkownicy nowych technologii. Pierwsze próby wykorzystania tego fenomenu w nauce zakończyły się powodzeniem zarówno w obrębie nauk ścisłych, jak i humanistycznych. Rozpoznanie możliwości używania *crowdsourcingu* w analizie treści wymaga jednak dalszych testów i poszukiwań. Celem artykułu jest przedstawienie próby użycia pilotażowego narzędzia do *crowdsourcingowego* kodowania treści oraz refleksja na temat potencjału i ograniczeń tego podejścia. Przedstawiona zostanie krótka charakterystyka zjawiska *crowdsourcingu*, jego zastosowanie w nauce oraz opis proponowanego narzędzia. Podsumowanie artykułu stanowi analiza szans oraz słabości, które *crowdsourcing* może oferować dla rozwoju tej metody.

Słowa kluczowe *crowdsourcing*, analiza treści, tłum, nowe technologie

Katarzyna Lisek, magister socjologii, doktorantka w Zakładzie Socjologii Gospodarki, Edukacji i Metod Badań Społecznych Instytutu Socjologii Uniwersytetu Jagiellońskiego, ekspert Centrum Ewaluacji i Analiz Polityk Publicznych UJ. Jej zainteresowania naukowe to ewaluacja, polityki publiczne oparte na dowodach, innowacyjność oraz *crowdsourcing*.

Adres kontaktowy:

Instytut Socjologii Uniwersytetu Jagiellońskiego
ul. Grodzka 52, pokój 68 (III brama)
31-044 Kraków
e-mail: katarzyna.lisek@uj.edu.pl

Zainteresowanie nowymi technologiami obecne wśród badaczy zajmujących się analizą treści, rozumianą jako technika „służąca do obiektywnego, systematycznego i ilościowego opisu jawnej treści przekazu” (Berelson 1952: 18 za: Goban-Klas 2004: 186), owocuje używaniem coraz to bardziej zaawansowanych narzędzi w obrębie tej metody. Szeroko diskutowanymi kierunkami jej rozwoju jest wsparcie analizy przez oprogramowanie komputerowe (Niedbalski 2013; Dzięglewski 2017) oraz próby maszynowego kodowania analizowanych materiałów (Troszyński, Wawer 2017). Wsparcie to odpowiada na

zarzuty kierowane wobec tej metody, jakimi są niska rzetelność (ze względu na subiektywność badacza) oraz duża czaso- i kosztochłonność procesu analizy (Gibbs 2011). Poszukiwanie zastosowań nowych technologii dla wsparcia analizy treści wpisuje się w nurt cyfrowej humanistyki, która podkreśla możliwości tych rozwiązań nie tylko w aspekcie automatyzacji zbierania i analizowania danych, ale również pogłębienia ich analizy przez zwrócenie uwagi na ich kompleksowość i kontekstowość (Berry 2011).

Zjawiskiem, które może zaoferować nową jakość analizie treści, ale którego zastosowanie w tym obszarze nie zostało jeszcze dobrze wyeksplorowane, jest *crowdsourcing*, polegający na jasnym określeniu problemu, który stoi przed organizacją i poleceniu jego rozwiązania dużej grupie anonimowych użytkowników nowych mediów (Estelles-Arolas, González-Ladrón-de-Guevara 2012). Celem poniższego artykułu jest przedstawienie potencjału, jaki może nieść *crowdsourcing* do kodowania treści w oparciu o pilotaż projektu narzędzia do *crowdsourcingowego* kodowania treści¹.

Pierwsza część artykułu poświęcona została zdefiniowaniu zjawiska *crowdsourcingu*, charakterystyki jego głównych elementów oraz opisaniu jego zastosowań w nauce, w tym w analizie treści. Następnie przedstawiona zostanie konstrukcja proponowanego narzędzia do *crowdsourcingowego* kodowania oraz analiza materiału badawczego. Artykuł zostanie podsumowany przez przedstawienie szans płynących ze wsparcia tradycyjnych metod kodowania treści przez platformy *crowdsourcingowe* oraz ograniczeń tej metody.

¹ Praca naukowa finansowana ze środków budżetowych na naukę w latach 2013–2014 jako projekt badawczy w ramach programu pod nazwą „Diamentowy Grant”.

Użycie *crowdsourcingu* w nauce

Pierwszy raz sformułowania *crowdsourcing* (jak dotąd nieprzetłumaczonego na język polski) użył Jeff Howe (2006) na łamach czasopisma technologicznego „Wire”. Duży chaos pojęciowy wokół tego zjawiska został spowodowany zainteresowaniem nim nie tylko wśród naukowców, ale też dziennikarzy, marketinżów czy blogerów. Autorami najbardziej popularnej definicji *crowdsourcingu* są Enrique Estelles-Arolas i Fernando González-Ladrón-de-Guevara (2012), którzy w procesie systematycznej analizy literatury uporządkowali dotychczasową wiedzę z tego zakresu. Zaproponowana przez nich funkcjonalna definicja tego zjawiska skupia się na opisie kluczowych elementów, obecnych we wszystkich projektach tego typu.

Dwoma głównymi aktorami tego procesu są *crowdsourcer* oraz tłum. Definicja celu projektu, określenie formatu oczekiwanej odpowiedzi oraz sformułowanie zapytania za pośrednictwem nowych technologii są zadaniami pierwszego z nich. Należy zaznaczyć, że *crowdsourcing*, w przeciwieństwie do innych procesów otwartych innowacji, jest zawsze procesem odgórnym (ang. *top-down*) (Brabham 2009; Zhao, Zhu 2014).

Tłum – czyli szeroka, anonimowa zbiorowość – charakteryzuje się zwykle dużą różnorodnością pod względem pochodzenia, wiedzy oraz cech społecznych. Jego skuteczność tłumaczy się poprzez zjawisko inteligencji zbiorowej (Levy 1997; Woolley i in. 2010) czy mądrości tłumu (Surowiecki 2010). Wśród motywacji, które popychają tłum do zaangażowania się w projekt, wymienia się psychologiczne dowartościowanie, możliwość bycia częścią ważnej misji lub rekompensatę finansową (Schenk, Guittard 2011; Eickhoff i in. 2014).

W tym miejscu należy zaznaczyć, że pojęcie tłumy stosowane w powyższym kontekście może zastanowić wielu socjologów przywiązanych do klasycznej definicji tego pojęcia. Trzeba pamiętać, że pierwsze próby opisu *crowdsourcingu* zostały podjęte na gruncie dziennikarskim, związanym z zarządzaniem czy marketingiem, trudno więc oczekiwać tu nawiązań do klasycznej socjologii. Pojęcie tłumy jest konsekwentnie wykorzystywane przez większość teoretyków *crowdsourcingu* (Estelles-Arolas, González-Ladrón-de-Guevara 2012) – chcąc wpisać się w dyskurs w tym obszarze, nie można z niego zrezygnować. Inteligentna zbiorowość, która rozwiązuje, a nie generuje problemy, może być uznana w socjologii za przedmiot trzeciej generacji badań nad tłumem (Wexler 2011).

Warto również zwrócić uwagę, że opis kategorii tłumy oraz źródeł jego skuteczności spotyka się z krytyką. Podkreśla się, że zbiorowość uczestnicząca w tego typu aktywnościach jest mniej przypadkowa, niż niektórzy chcieliby sądzić. Badania wskazują, że przynajmniej część tego typu projektów przyciąga osoby o dużym potencjale intelektualnym i społecznym: młodych naukowców, nauczycieli, studentów (Ross i in. 2010). Często uzyskanie tą drogą innowacyjnego rozwiązania nie jest wcale wysiłkiem grupowego fenomenu, a raczej efektem pozyskania pracy jednej, wybitnej jednostki. Wątpliwości budzi również skupianie się na integrującym i zbiorowym aspekcie tego zjawiska z pominięciem aspektu biznesowego. Spojrzenie na użytkowników Internetu jako jednostki chcące bezinteresownie uczestniczyć w tworzeniu większego potencjału wiedzy dla dobra ogólnego w oderwaniu od interesów firm inwestujących w nowe technologie i wykorzystujących je na swoją korzyść jest podstawą do krytyki również

szerszego pojęcia inteligencji kolektywnej Pierre'a Lévy'ego (Barbrook 1997).

Crowdsourcing, we wszystkich swoich odmianach, z powodzeniem wykorzystywany jest przy prowadzeniu badań naukowych (Franzoni, Sauermann 2014; Zhao, Zhu 2014). W ich ramach zadania, które są zlecane tłumowi, czyli zbiorowości anonimowych użytkowników, mogą mieć różny charakter. Z jednej strony możemy wyróżnić projekty, których celem jest otrzymanie odpowiedzi na pytanie z jedną możliwą odpowiedzią, której jeszcze nie znamy. Schenk i Guittard (2011) nazwali ten rodzaj *crowdsourcingu* selektywnym. W jego ramach możemy wyróżnić dwie podgrupy projektów (Brabham 2013):

1. Szerokopasmowe poszukiwania (ang. *the broadcast search*): są to projekty, w których prawidłowa odpowiedź na zadane pytanie jest obiektywnie weryfikowalna, ale jeszcze nieznaną. Przykładem może być projekt Polimath, w którym matematyk Tim Gowers poprosił internautów o pomoc w znalezieniu dowodu dla twierdzenia Halesa-Jewitta. Do pracy polegającej na publikowaniu własnych rozwiązań i komentowaniu wkładu innych włączyło się wielu naukowców i amatorów (Cranshaw, Kittur 2011).
2. Wzajemnie kontrolowana kreatywna produkcja (ang. *peer-vetted creative production*): użytkownicy są proszeni o zaprezentowanie swojego rozwiązania danego problemu i we wspólnym głosowaniu wybierają najlepsze z nich. Tego typu projekty najczęściej są stosowane do testowania rozwiązań innowacyjnych przed wprowadzeniem ich na rynek.

Kolejnym rodzajem projektów *crowdsourcingowych* są projekty integratywne (Schenk, Guittard 2011). Tym razem odpowiedzią na zapytanie *crowdsourcera* nie jest jedno rozwiązanie przedstawione przez jednego użytkownika, ale suma wysiłków całej grupy. Tłum nie musi posiadać zaawansowanej wiedzy do wykonania zadania, praca jest też zwykle mało czasochłonna – użytkownik może kontrolować to, jak dużo czasu i energii chce poświęcić projektowi. Wśród tego typu projektów wyróżnia się (Brabham 2013):

1. Odkrywanie i zarządzanie wiedzą (ang. knowledge discovery and management): w tej grupie znajdują się projekty, w których organizator jasno definiuje, jakiej informacji poszukuje, a następnie prosi o jej dostarczenie użytkowników. W nauce ten typ projektów jest wykorzystywany na etapie zbierania danych, tak jak w przypadku projektu EDDMapS, gdzie użytkownicy śledzą rozwój roślin inwazyjnych w swojej najbliższej okolicy (Wallance, Barger 2014), czy polskiego projektu Szlak Nadziei, gdzie internauci dzielili się pamiątkami swoich rodzin związanymi ze Szlakiem Andersa (Davies 2015).
2. Zadania dla zbiorowej inteligencji (ang. distributed human intelligence tasking): w tych projektach zadanie zlecane tłumowi jest dzielone na bardzo wiele mało skomplikowanych mikrozadań, a następnie udostępniane jak największej grupie użytkowników. Ten sposób współpracy w tłumie jest wykorzystywany do porządkowania zebranego materiału, jak w przypadku projektu CosmoQuest, gdzie użytkownicy oznaczają kratery na zdjęciach powierzchni księżyca (Robbins i in. 2014) czy projektu Old Weather, gdzie internauci transkrybują fragmenty opisów pogo-

dy ze źródeł historycznych (Eveleigh i in. 2013). Wśród projektów z tej grupy można wyróżnić te, które polegają na oznaczaniu czy tagowaniu treści zdjęć, filmów i tekstów (Ridge 2011).

Użycie *crowdsourcingu* w badaniach jakościowych

Pomysł wykorzystania *crowdsourcingu* w socjologii jakościowej wpisuje się w nurt cyfrowej humanistyki, gdzie potencjał nowych technologii ma być wykorzystany dla rozwoju tej dziedziny nauki przez udoskonalenie istniejących narzędzi badawczych lub wprowadzenie nowych rozwiązań, gwarantujących nową jakość w procesie badawczym (Bomba 2013). Na przestrzeni ostatnich lat metody analizy treści zostały poddane procesowi dużej transformacji dzięki rozwijającemu się oprogramowaniu. Był to krok nieunikniony w obliczu rosnącej liczby dostępnych źródeł danych. Nowy paradygmat prowadzenia badań, oparty na oprogramowaniu CAQDAS, którego pierwszymi autorami byli sami badacze, dał możliwość nie tylko uporządkowania procesu analizy danych, ale przede wszystkim podniesienia jego rzetelności. Dalsze prace nad udoskonaleniem tych narzędzi skupiają się między innymi na ich potencjale do wspierania budowania teorii przyczynowych czy w innych nurtach – na identyfikowaniu korelacji między konstruktami (Bryda 2014). Radzenie sobie z potężnymi bazami danych, zwanymi *big data*, wspomagane jest przez algorytmy samouczące (Brosz, Bryda, Siuda 2017). W obliczu tych kierunków rozwoju narzędzi metodologicznych *crowdsourcing* może stanowić inspirację, oferując kanał komunikacji badacza z szerszą zbiorowością, którą można traktować jako publiczność albo wsparcie w realizacji badania.

Próbie wykorzystania *crowdsourcingu* w analizie treści podjęli Terek Azzam i Elena Harman (2015). Z pomocą platformy *crowdsourcingowej* Amazon Mechanical Turk poprosili internautów o pomoc w interpretacji transkrypcji wywiadu. Zadaniem użytkowników było przeczytanie tekstu, odpowiedzenie na zadane do niego pytania na skali Likerta (np. Jak student ocenił wartość wykształcenia otrzymanego w szkole wyższej?) oraz wskazanie fragmentów tekstu, które usprawiedliwiają udzieloną przez nich odpowiedź. Wyniki badania potwierdziły wysoką stabilność udzielanych przez Internautów odpowiedzi oraz powtarzalność wskazywanych fragmentów.

Inną próbą włączenia *crowdsourcingu* w badania nad treścią komunikatu jest projekt przeprowadzony przez Christiana Broera i jego zespół (2016). Rozpoczęli oni od analizy programów dotychczas używanych w analizie danych pod kątem wykorzystania ich w badaniu z użyciem wsparcia internautów. Wskazali na to, że większość z nich jest skomplikowana w swojej budowie i wymaga długiego szkolenia dla koderów, nie jest przystosowana do prowadzenia badań online albo pozwala na używanie bardzo niewielkiej liczby tagów. W związku z tym postanowili stworzyć swoje narzędzie. Jest zaplanowane tak, aby wspierać cały proces badawczy, od stawiania pytań, poprzez zbieranie materiałów, do ich porządkowania i wyciągania wniosków. Oprogramowanie zostało poddane pilotażowi, ale prace nad jego ostatecznym kształtem wciąż trwają.

Cel artykułu

Celem niniejszego artykułu jest przedstawienie potencjału *crowdsourcingu* do wsparcia jakościowej analizy treści, w szczególności procesu kodowania. Pro-

blem ten został podjęty w oparciu o wyniki pilotażowego badania, w którym wykorzystano autorskie narzędzie do *crowdsourcingowej* analizy treści. Pilotaż projektowanego narzędzia miał za zadanie odpowiedzieć na następujące pytania:

1. W jaki sposób powinno wyglądać narzędzie do *crowdsourcingowej* analizy treści? Jakie elementy powinno zawierać? Czy jest możliwe zaprojektowanie narzędzia, które będzie odpowiadać wyzwaniom metodologicznym?
2. Czy możliwym jest zmobilizowanie użytkowników do wykonania pracy na rzecz *crowdsourcera*?
3. Jaki potencjał niesie zastosowanie zaprojektowanego narzędzia dla jakościowej analizy treści?

W artykule przedstawiono projekt narzędzia, następnie analizę próbki zebranych za jego pomocą danych. W oparciu o wnioski z przebiegu procesu badania oraz otrzymane wyniki dyskusji poddane zostają obszary, w których narzędzie mogłoby znaleźć zastosowanie, oraz ograniczenia narzędzia wynikające z jego niedoskonałej budowy oraz samego charakteru *crowdsourcingu*.

Metoda

Aby przetestować możliwość wsparcia analizy treści przez *crowdsourcing*, stworzono prototyp narzędzia przeznaczonego do włączenia internautów w proces kodowania tekstu. Wykorzystanie dotychczasowych narzędzi wiązało się z ograniczeniami wskazywanymi przez zespół Christiana Broera (2016), a użycie już istniejących platform *crowdsourcingowych*, jak Amazon Mechanical Turk, stanowi-

ło duże wyzwanie dla badań prowadzonych w tak oryginalnym języku, jakim jest język polski.

Narzędzie wpisano się w charakterystykę projektów z grupy „zadania dla zbiorowej inteligencji” i przy jego projektowaniu kierowano się doświadczeniami innych projektów tego typu (Brabham 2013). Proces kodowania tekstu nazwano „tagowaniem”, a kody klasyfikacyjne „tagami”. Po pierwszych testach oprogramowania język ten wydawał się bliższy i bardziej zrozumiały odbiorcom. Uczestnicy zostali poinformowani, że biorą udział w badaniu naukowym, a na najbardziej zaangażowanych uczestników czekały nagrody.

Po wejściu na stronę główną portalu, gdzie zawarte zostały podstawowe informacje dotyczące projektu, użytkownik zapraszany był do rozpoczęcia zabawy i próby zakodowania pierwszego tekstu. Zanim użytkownik przeszedł do modułu kodowania, wyświetla-

ny był mu krótki film wyjaśniający, na czym będzie polegało jego zadanie i jak technicznie powinien je wykonać. Po obejrzeniu tak zwanego tutorialu, użytkownik przechodził do zakodowania pierwszego, próbnego tekstu.

W panelu tagowania użytkownikowi wyświetlony został fragment tekstu, na którym ten miał pracować, krótka instrukcja, lista dostępnych tagów oraz pasek postępu (rysunek 1). Po zaznaczeniu kurso-rem fragmentu tekstu, na ekranie pojawiała się lista rozwijana z dostępnymi kodami, wśród których użytkownik mógł wybrać ten należący do danego fragmentu. Jeśli w trakcie pracy nad tekstem użytkownik zmienił zdanie co do oznaczonego wcześniej fragmentu, mógł do niego wrócić i usunąć wybrany tag. Użytkownik mógł wybrać do oznaczenia danym tagiem fragment nie krótszy niż jedno słowo i nie dłuższy niż jedno zdanie.

Rysunek 1. Wygląd panelu kodowania w zaprojektowanym narzędziu do *crowdsourcingowego* kodowania treści.



Źródło: opracowanie własne.

Każdy fragment tekstu był kodowany przez użytkowników dwukrotnie. Dwa etapy kodowania różniły się od siebie listą dostępnych dla użytkownika tagów. W pierwszym etapie (nazwanym „identyfikowanie”) użytkownik miał za zadanie odnalezienie bardzo skonkretyzowanych i łatwo weryfikowalnych wyrażen, takich jak nazwa geograficzna, data, nazwa marki. Ich odnalezienie nie wymagało dokładnego przeczytania całe-

go tekstu, jedynie szybkiej analizy w poszukiwaniu danych słów i fragmentów. W drugim etapie (nazwanym „rozumienie”) kody odnosiły się do bardziej skomplikowanych konstruktów, których odnalezienie wymagało od kodera rozumienia treści czytanego tekstu. Miał on za zadanie odróżnienie opinii blogera od faktów czy wskazanie na fragmenty będące reklamą. Pełna lista tagów znajduje się w tabeli nr 1.

Tabela 1. Lista kodów używanych w pierwszym i drugim etapie kodowania.

ETAP I	ETAP II
nazwa portalu społecznościowego	
wyrażenie obcojęzyczne	
neologizm	autoreklama
cytat	bloger o sobie
nazwa marki	ciekawostka
data	zwrot do adresata
nazwa / nazwisko artysty lub celebryty	opinia blogera
tytuł filmu, serialu, książki, albumu	porada dla czytelników
nazwa innego bloga lub blogera	wspomnienie blogera
nazwa geograficzna	fakt
imię bliskiego blogera	opinia kogoś innego
nazwa wydarzenia	odwołanie do wcześniejszych postów reklama
nazwa akcji społecznej	

Źródło: opracowanie własne.

Uczestnicy projektu byli proszeni o pokrycie kodami możliwie dużego obszaru wyświetlanego tekstu. Otrzymywali punkt za pracę nad każdym tekstem, w którym dopasowali tagi do przynajmniej połowy znaków. Pasek postępu pokazywał użyt-

kownikom, jak duży odsetek znaków udało się im oznaczyć. Do każdego oznaczonego fragmentu w danym etapie użytkownik mógł dopasować tylko jeden tag. Oznaczone fragmenty nie mogły więc się zazębiać.

W artykule przedstawiono analizę próbki materiału składającego się z wpisów z polskich blogów, liczącego 65 028 znaków, którego fragmentom przyporządkowano 19 136 kodów. Przeanalizowano 4 416 kodów nadanych w pierwszym etapie kodowania oraz 14 720 kodów w drugim etapie.

Doświadczenia innych projektów naukowych wykorzystujących *crowdsourcing* do tagowania lub flagowania danych wskazują na to, że za poprawną odpowiedź udzieloną przez tłum powinno przyjmować się tę, która powtarza się kilkakrotnie (Ridgeway 2011; Azzam, Harman 2015). Przykładem zastosowania takiej praktyki może być projekt EyeWire, w którym za prawidłowe rozwiązanie uznaje się

to, które powtórzyło się wśród uczestników 5 razy (Kim i in. 2014).

W analizowanym materiale w wielu przypadkach dany fragment tekstu został oznaczony danym kodem tylko raz – oznaczało to, że dopasowanie to zostało wykonane tylko przez jednego koderę. Sytuacja taka miała miejsce w przypadku 8% dopasowań: 12% w etapie I i 7% w etapie II. Dopasowania te zostały wykluczone z dalszej analizy. Podobnie stało się z dopasowaniami, które powtórzyły się dwa razy. Do analizy włączono te fragmenty, którym nadano ten sam tag trzy razy i więcej, tym samym ograniczając próbkę do 82% oznaczeń: 3 533 w etapie I i 12 070 w etapie II.

Tabela 2. Liczba analizowanych kodów na każdym z etapów oraz odsetek powtarzających się dopasowań.

	wszystkie kody	przynajmniej raz powtórzone	powyżej 1 powtórzenia	powyżej 2 powtórzeń	powyżej 3 powtórzeń	powyżej 4 powtórzeń
Etap I	4416	88%	83%	80%	76%	74%
Etap II	14720	93%	88%	82%	77%	74%
Ogółem	19136	92%	87%	82%	77%	74%

Źródło: opracowanie własne.

Rezultaty

Pierwszy etap tagowania

Przyglądając się statystykom używania kodów na etapie pierwszym, możemy zauważyć cztery wzory:

- kody pojawiające się często i z wysoką powtarzalnością;

- kody pojawiające się rzadziej i z wysoką powtarzalnością;
- kody pojawiające się często i z niską powtarzalnością;
- kody pojawiające się rzadziej i z niską powtarzalnością.

Kody z wysokim odsetkiem powtarzalności (zostały nadane kilkakrotnie temu samemu fragmento-

wi tekstu) można uznać za najbardziej precyzyjne – użytkownicy podobnie rozumieli ich znaczenie i oznaczali nimi te same fragmenty. Mało precyzyjnie używane były tagi o niskiej powtarzalności – większość fragmentów została oznaczona nimi zaledwie raz lub dwa razy. Warto zauważyć, że na etapie pierwszym częstotliwość pojawiania się da-

nego kodu nie jest ściśle połączona z jego powtarzalnością: można wyróżnić tu kod „imię bliskiego blogera”, który pojawiał się stosunkowo rzadko, ale fragmenty nim oznaczone powtarzały się, oraz kod „neologizm”, za pomocą którego, pomimo częstego występowania, oznaczano inne fragmenty analizowanego tekstu.

Tabela 3. Liczba analizowanych kodów na etapie pierwszym oraz odsetek powtarzających się dopasowań.

ETAP I	wszystkie kody	przynajmniej raz powtórzone	powyżej 1 powtórzenia	powyżej 2 powtórzeń	powyżej 3 powtórzeń	powyżej 4 powtórzeń
nazwa geograficzna	1625	98%	97%	95%	95%	93%
nazwa marki	271	96%	95%	94%	90%	88%
nazwa portalu społecznościowego	147	96%	95%	93%	87%	84%
nazwa innego bloga lub blogera	255	95%	95%	93%	93%	91%
nazwa / nazwisko artysty lub celebryty	143	94%	94%	94%	88%	88%
imię bliskiego blogera	96	93%	93%	83%	54%	54%
wyrażenie obcojęzyczne	627	91%	85%	81%	77%	74%
data	286	88%	79%	76%	70%	65%
tytuł filmu, serialu, książki, albumu	83	88%	86%	82%	82%	82%
cytat	222	72%	66%	62%	55%	48%
neologizm	536	58%	40%	28%	24%	19%
nazwa wydarzenia	95	54%	49%	37%	37%	37%
akcja społeczna	30	53%	27%	17%	17%	0%

Źródło: opracowanie własne.

Na pierwszym etapie kodowania tagami o najwyższym odsetku przyjętymi do analizy fragmentów były te związane z nazwami geograficznymi, nazwami marek oraz nazwami portali społecznościowych. Wszystkie trzy kategorie mają dość jasne i intuicyjne definicje, są jednoznaczne i łatwe do zidentyfikowania.

Koderzy zidentyfikowali 80 unikatowych fragmentów analizowanego tekstu jako nazwy geograficzne. Wśród nich zaledwie 10 nie stanowi nazw własnych, a są nazwami obiektów naturalnych, takimi jak „fiord”, „księżyc” czy „archipelag”. Pozostałe obserwacje stanowią nazwy własne miejscowości (np. „Łodzi”, „Santa Cruz”), państw (np. „Czarnogórze”, „Norwegia”) czy innych obiektów geograficznych (np. „Lofoty”, „Svartisen”). Co ciekawe, jako nazwy geograficzne zostały potraktowane również nazwy dróg, takie jak „E6” czy „Fv 103”.

Wśród analizowanych fragmentów wyróżniono 23 unikatowe nazwy marek. Znalazły się wśród nich między innymi nazwy sklepów odzieżowych (np. „Zara”, „Lunaby”), portali (np. „Trello”, „Dropboxa”) czy gazet (np. „Ty i Ja”), a nawet organizacji (np. „Federacja Konsumentów”, „Stowarzyszenie Konsumentów Polskich”). Ciekawym jest, że użytkownicy za nazwę marki uznali określenia „Zuzia Górka” oraz „Coco Chanel”. O ile w pierwszym wypadku imię i nazwisko projektantki jest jednocześnie nazwą jej marki, o tyle w drugim przypadku analizowany tekst odnosił się do postaci, a nie jej firmy. Warto również zaznaczyć, że wśród zakodowanych nazw marek nie pojawiają się nazwy portali społecznościowych takich jak „Facebook” czy „Youtube”. Jak było zaznaczone wcześniej, uczestni-

cy mogli oznaczyć dany tekst tylko jednym tagiem, co jest z pewnością przyczyną tych braków.

Dwie wspomniane wcześniej obserwacje pojawiają się za to wśród 12 fragmentów oznaczonych jako „nazwa portalu społecznościowego”. Poza nimi koderzy oznaczyli w ten sposób inne portale służące do komunikacji (np. „Slack”), ale również nazwy innych portali, niekoniecznie pełniących społecznościowe funkcje (np. „Allegro”, „Trello”). Użytkownicy poradzi sobie z rozpoznaniem skrótu „FB”, do nazw portali zaliczyli jednak również wyrażenie „social media”.

Kolejną grupą tagów, wśród oznaczeń których większość obserwacji miała przynajmniej 3 powtórzenia, były te dotyczące nazwy innych blogów lub blogerów, imion osób bliskich blogerowi oraz imion czy nazw artystów i celebrytów. We wszystkich tych kategoriach oczekiwano rozpoznania przede wszystkim imion, pseudonimów i nazw własnych. Okazało się, że granice pomiędzy tymi kategoriami mogą być bardziej rozmyte, niż by się to początkowo wydawało.

W analizowanym materiale użytkownicy oznaczyli 10 unikatowych określeń wskazujących na inne blogi czy blogerów. Największą liczbę wskazań miały nazwy blogów (np. „Minimal Plan”, „Blimsien”), nieco mniej wskazań miały imiona blogerów (np. „Andrzej”, „Justyny”). Należy zaznaczyć, że wśród obserwacji znalazło się również imię Zuzi Górskiej, projektantki, oraz Agnieszki, redaktorki ze Społecznego Instytutu Wydawniczego Znak. Żadna z tych pań nie wystąpiła w tekście jako autorka bloga, ich profesja była jasno wskazana w analizowanym materiale.

Podobny problem pojawia się w przypadku tagu dotyczącego imion artystów i celebrytów. Chociaż wśród wyróżnionych 10 obserwacji zdecydowana większość wskazań trafnie identyfikuje artystów (np. „McClathy”, „Beyonce”), wśród obserwacji znowu pojawia się imię redaktorki Agnieszki, niemieszczące się w tej kategorii.

W analizowanym materiale koderzy wskazali na 16 określeń dotyczących bliskich blogera. Pojawiają się wśród nich imiona osób, o których z kontekstu wiemy, że przyjaźnią się z autorem tekstu (np. „Daniela”, „Karinę”), a nawet imiona zwierząt (np. „Chrupek”). Wiele wskazań dotyczy jednak po prostu imion, niezależnie od tego, do kogo należą. I tak w tej kategorii znalazły się imiona osób, których twórczość została polecona przez autora (np. „Justyna”, „Andrzeja” – o których z kontekstu wiemy, że są po prostu innymi blogerami) czy imię czytelniczki („Aga”). Wśród zakodowanych fragmentów znalazła się również nazwa miasta „Reine”.

Kolejne dwa tagi zasługujące na uwagę i bardzo zbliżone semantycznie to te związane z wyrażeniami obcojęzycznymi (czyli wyrażeniami zaczerpniętymi z języka innego niż polski) oraz neologizmami (czyli nowymi słowami stworzonymi przez autora wypowiedzi). Co ciekawe, obydwie te kody pojawiały się w analizowanym materiale niezwykle często, pierwszy z nich miał jednak dużo wyższą powtarzalność niż drugi.

Użytkownicy w analizowanym materiale oznaczyli 54 wyrażenia jako zwroty obcojęzyczne. Wśród nich 15 jest wyrażeniami obcojęzycznymi, z zachowaną oryginalną pisownią (np. „*fear of missing out*”,

„*slow fashion*”). Wyrażenia obcojęzyczne ze spolszczoną pisownią lub odmianą znalazły się wśród zakodowanych fragmentów 31 razy (np. „deadlinów”, „stokfiszę”). Pięć z zakodowanych fragmentów to nazwy własne (np. „Minimal Plan”, „Vagan”). Co ciekawe, wśród oznaczonych wyrażen znalazły się również te o obcojęzycznym pochodzeniu, ale używane w języku polskim (np. „garderoba”).

Do analizy włączono aż 97 wyrażen oznaczonych jako neologizmy. 20% z nich to te same wyrażenia, które zaliczono również do wyrażen obcojęzycznych (np. „t-shirty”, „*shopping*”). Niemal co 7 oznaczony jako neologizm fragment jest odmianą słowa „blog”, „mail” lub „post”. Wśród oznaczonych fragmentów są również słowa, które mogą wydawać się nowymi sformułowaniami, ale które funkcjonują w języku polskim (np. „zblazowane”, „dziewczyńskie”, „rozmemłany”).

Jeśli chodzi o fragmenty oznaczone tagiem „data”, wśród 25 unikatowych wyrażen najczęściej wskazywano te opisujące konkretny moment w czasie (np. „w lipcu 2014”, „1 lipca 2015”). Wśród rzadziej wskazywanych fragmentów znalazły się również te mniej precyzyjne określenia danego dnia (np. „zeszłego roku”, „na początku czerwca”), odstępów czasowego (np. „pięć dni temu”), czy godziny („we wczesnych godzinach popołudniowych”). Użytkownicy jako datę oznaczyli również inne określenia związane z czasem, niekoniecznie wskazujące na dany moment (np. „14 dni”, „3 tygodnie”).

Równie mało precyzyjnie użytkownicy posługiwali się kodem „cytat”. O ile wśród 20 unikatowych fragmentów najczęściej oznaczanymi były stwierdzenia

przytoczone bezpośrednio od rozmówcy (np. „stoi dziewczyna przed szafą pełną ubrań i jak zwykle nie ma się w co ubrać, he he he”), o tyle połowa włączonych do analizy fragmentów stanowi wyrażenia występujące w analizowanym materiale w cudzo-słowie (np. „o «dziewczyńskich» sprawach”).

Tagami o bardzo niskiej powtarzalności, ale też najrzadziej używanymi były te związane z nazwą wydarzenia i akcjami społecznymi. W przypadku obydwu tych tagów najczęściej oznaczonym przez nie fragmentem była nazwa „Światowy Dzień Książki”. Wśród fragmentów rozumianych jako nazwa wydarzenia można znaleźć również nazwę „II wojna

światowa” ale też nazwy prywatnych celebrazji jak „norweska przygoda” albo „urodziny”.

Drugi etap kodowania

W analizowanym materiale z drugiego etapu kodowania znalazło się znacznie więcej fragmentów analizowanego tekstu niż w pierwszym. Zaznaczano również dłuższe fragmenty – o ile średnia liczba znaków fragmentów analizowanych w pierwszym etapie wynosi 12, o tyle w drugim etapie równa się 76 znaków. Różnice wynikają z charakterystyki dostępnych dla użytkowników kodów w poszczególnych etapach.

Tabela 4. Liczba analizowanych kodów na etapie drugim oraz odsetek powtarzających się dopasowań.

ETAP II	wszystkie	przynajmniej raz powtórzone	powyżej 1 powtórzenia	powyżej 2 powtórzeń	powyżej 3 powtórzeń	powyżej 4 powtórzeń
wspomnienie blogera	2825	97%	95%	92%	88%	85%
bloger o sobie	3245	96%	93%	88%	85%	82%
opinia blogera	3165	96%	91%	87%	82%	77%
zwrot do adresata	1044	94%	89%	86%	84%	83%
porada dla czytelników	1013	91%	83%	77%	71%	65%
fakt	1788	91%	80%	72%	65%	62%
opinia kogoś innego	328	87%	79%	76%	71%	68%
autoreklama	134	85%	75%	63%	63%	60%
odniesienie do wcześniejszych postów	175	77%	70%	58%	56%	54%
reklama	149	82%	63%	55%	36%	36%
ciekawostka	854	79%	62%	51%	38%	34%

Źródło: opracowanie własne.

Na drugim etapie trzema najczęściej pojawiającymi się tagami były te związane ze wspomnieniami blogera, jego opisem samego siebie oraz jego opiniami. Najwyższy odsetek tych tagów został też włączony do analizy.

W przypadku tagu „wspomnienie” do analizy włączono 283 unikatowych fragmentów nim oznaczonych. W wielu z nich odniesienia do przeszłości można zidentyfikować po pojawiających się wyrażeniach wyznaczających niemal konkretną datę (np. „w lipcu zeszłego roku”, „3 tygodnie temu”), określających mniej dokładny moment w czasie (np. „już w podstawówce”, „jakiś czas temu”) lub oznaczających sekwencję pewnych wydarzeń (np. „po powrocie z lodowca”, „gdy zaczęliśmy podróżować”). Inne wyrażenia wskazujące na przeszłość odnoszą się do samego autora wypowiedzi (np. „pamiętam, że kiedyś”, „długo zajęło mi”). Większość oznaczonych fragmentów zawierała czasowniki w czasie przeszłym, warto jednak zaznaczyć, że jako wspomnienia rozpoznane były również wyrażenia w czasie teraźniejszym, które stanowiły relacje z przeszłości (np. „przez Narwik tylko przejeżdżamy, nie zwiedzamy go”).

Wśród 327 fragmentów oznaczonych jako określenia blogera o sobie przeważają generalne stwierdzenia mówiące o tym, jak autor ocenia sam siebie. Są wśród nich stwierdzenia opisujące cechy (np. „jestem beznaście przyziemna”, „jestem bezkonkurencyjna”), upodobania (np. „nie lubię skomplikowanych procesów”, „uwielbiam korzystać z rad”), przyzwyczajenia (np. „staram się nie gromadzić”, „najczęściej pracuję w salonie”) czy wcześniejsze zachowania (np. „marzyłam od zawsze”, „długo nazywałam pliki”). Rza-

dziej wśród fragmentów występują odniesienia do konkretnych wydarzeń (np. „tej wiosny wyjątkowo czuję”, „pierwszy raz tworzyłam”, „byłam wystraszona”) – prawdopodobnie dlatego, że zostały one przez część użytkowników zakwalifikowane jako wspomnienia blogera.

Opinie blogera, których w sumie doszukano się w 333 fragmentach, można zidentyfikować po charakterystycznych dla tego typu wypowiedzi wyrażeniach, na przykład „podoba mi się”, „moim zdaniem”, „uważam, że”. Wśród analizowanych fragmentów wiele odnosi się do doświadczeń zmysłowych autora wypowiedzi (np. „smakowała znakomicie”, „wyglądają apetycznie”, „w środku jest ślicznie”, „brzmiało fantastycznie”). Znaleźć wśród nich można również oceny konkretnych osób (np. „Justyna pisze szczerze, otwarcie i prosto z mostu”), miejsc (np. „szlak się robi dziksz, mniej zadbany”) czy przedmiotów (np. „czyta się ją fantastycznie”). Jako opinię autora oznaczano również mocne stwierdzenia, niepodparte argumentacją (np. „fotografia cyfrowa nas rozpieściła”), a także generalne opinie (np. „wena jest przereklamowana”) i „prawdy życiowe” (np. „pies to najlepszy przyjaciel człowieka”). Wśród analizowanych fragmentów występuje również wiele wykrzykników (np. „pięknie!”, „rewelacyjną ceną!”).

W kolejnej grupie tagów, rzadziej się pojawiających, ale niemal równie często powtarzalnych, znajdują się te dotyczące zwrotów do adresata, porady dla czytelników oraz faktów. Ich rzadsze pojawianie się wytłumaczyć można węższą pojemnością znaczeniową w stosunku do trzech wcześniejszych tagów. Mają one też znacznie precyzyjniejsze znaczenie.

W analizowanym materiale jako zwrot do adresata oznaczono 76 unikatowych fragmentów tekstu. Ich cechą charakterystyczną jest częste występowanie zaimków osobowych (np. „Wy”, „Wam”, „Waszą”) oraz czasowników w drugiej osobie liczby mnogiej (np. „podzielcie się”, „macie”). Wśród oznaczonych fragmentów pojawiły się pytania retoryczne (np. „Jak to się dzieje, że po tylu latach wolnego rynku polska moda wciąż jest do tyłu?”), pytania do komentujących posty (np. „a jak to wygląda u Was?”), prośby do czytelników (np. „dajcie znać, klikając przycisk «Lubię to!»”) oraz twierdzenia (np. „założę się, że Was też taka sytuacja spotkała”).

Kodem podobnym do zwrotu do adresata, z uwagi na bezpośrednie skierowanie komunikatu do czytelnika, był ten dotyczący porad. W tym przypadku wśród analizowanych fragmentów również pojawiły się te zawierające czasowniki w drugiej, ale też pierwszej osobie liczby mnogiej (np. „jesteśmy”, „nie potrzebujemy”). Wiele z fragmentów zawierało wyrażenia charakterystyczne dla udzielania wskazówek, na przykład „dobrą praktyką jest”, „warto pamiętać o”. Warto zaznaczyć, że wiele z fragmentów miało budowę zdania podrzędnego okolicznikowego (np. „Jeśli pozbędziesz się ubrań, w których nie chodzisz, te wszystkie rzeczy nie będą już problemem”).

Użytkownicy oznaczyli 190 fragmentów analizowanego materiału jako fakty. Te dopasowania, które powtarzały się najczęściej, dotyczyły sytuacji regulowanych prawem (np. „na rozpatrzenie naszej reklamacji sprzedający ma 14 dni”) czy opisów geograficznych (np. „to archipelag na Morzu Norweskim, 300 km na północ od koła podbiegunowego”). Równie często jako fakty zostały oznaczone obiek-

tywne informacje dotyczące opisywanych przedmiotów czy sytuacji (np. „wszystkie trzy są pisane przez kobiety”, „akcja Andrzeja jest skierowana do blogerów”) oraz informacje dotyczące bieżących wydarzeń (np. „książka trafi na półki w księgarniach na początku czerwca”). Wśród fragmentów, których oznaczenie jako fakt pojawiało się znacznie rzadziej, znaleźć można te same stwierdzenia, które przez innych użytkowników oznaczone zostały jako opinia blogera (np. „praca w domu nie jest dla wszystkich”).

Kolejnym tagiem wartym uwagi jest ten, którym użytkownicy oznaczali fragmenty będące opinią kogoś innego niż autor. Wśród 31 fragmentów oznaczonych w ten sposób znaleźć można te, w których występuje wyraźne wskazanie na autora wypowiedzi (np. „McClatchy pisze, że”, „chłopak w przytoczonym filmiku mówi”), ale również oceny przytaczane z mniej konkretnych źródeł (np. „rzadko polecanej w przewodnikach”, „czytałam, że”). Pojawiają się również wśród nich generalne, zasłyszane gdzieś opinie (np. „często zaleca się”, „podobno uroczej, przepięknie położonej”). Co ważne, wśród oznaczonych fragmentów pojawiają się również stwierdzenia, które same w sobie nie zawierają zwrotów wskazujących na bycie opinią osób trzecich, jednak z kontekstu całego materiału wynika, że są one przedstawieniem treści opisywanych książek czy czasopism.

Najrzadziej pojawiającymi się kodami na drugim etapie były te opisujące fragmenty odnoszące się do wcześniejszych postów autora, oznaczające reklamę i autoreklamę. W przypadku pierwszego kodu najczęściej oznaczeń otrzymały fragmenty odnoszące

się bezpośrednio do konkretnego wpisu na blogu w przeszłości (np. „poprzedni odcinek to też już były Lofoty”). Nieco rzadziej oznaczane były fragmenty odnoszące się do generalnej historii bloga (np. „kiedyś polecałam tradycyjną metodę”). Oznaczenia te otrzymały również fragmenty powracające do komentarzy pod wcześniejszymi wpisami (np. „pod niedawnym postem jedna z Czytelniczek, Aga, zapytała mnie”).

Dwa kolejne kody, „reklama” i „autoreklama”, mogą wydawać się bardzo zbliżone, jednak fragmenty nimi oznaczone różniły się od siebie. W przypadku pierwszego kodu (którym oznaczono 18 unikatowych fragmentów) najczęściej wśród obserwacji pojawiały się nazwy polecanych książek czy blogów (np. *Coutellerie* czy *Decide: Work Smarter, Reduce Your Stress, and Lead by Example*), ale też pozytywne opinie dotyczące opisywanych produktów (np. „jest bardzo przydatna przy wielowatkowych projektach”). Kodem „autoreklama” oznaczano przede wszystkim fragmenty mówiące o innych produktach autora, takich jak jego książka (np. „w książce przedstawiam dużo prostszy i skuteczniejszy sposób”), o zapowiedziach kolejnych postów (np. „tej rewelacyjnej wycieczce poświęcę następny odcinek”), a także prośby na reakcje w social mediach (np. „jeśli podobał Wam się tekst, nie zapomnijcie kliknąć w guzik «Lubię to»”).

Tagiem pojawiającym się często w analizowanym materiale, ale cieszącym się bardzo niską powtarzalnością, jest ten dotyczący ciekawostek. Należy przyznać, że definicja tego tagu nie jest intuicyjna i mógł on być rozumiany bardzo różnie przez użytkowników. Poza tym jego znaczenie może zają-

biać się ze znaczeniem tagu „wspomnienie” oraz „opinia blogera”. Wśród oznaczonych fragmentów pojawiały się przede wszystkim te związane z ciekawymi szczegółami opisywanej rzeczywistości, dotyczące miejsc (np. „Droga na północ często jest tu tak szybko zasypywana nawianym śniegiem, że kierowcy muszą czekać, aż przyjedzie pług śnieżny i samochody wtedy rządkiem jadą za nim”), ludzi (np. „mam koleżankę, która zawsze wie, która jest godzina, bez patrzenia na zegarek”) czy wydarzeń (np. „śpimy na dziko, bo w Norwegii to legalne”).

Potencjał wykorzystania *crowdsourcingu* w analizie treści

Zaprezentowane wyniki wskazują na to, że analizowane dopasowania fragmentów materiału do klucza kategoryzacyjnego dokonane przez użytkowników platformy nie są pozbawione logiki. Wysoki odsetek powtórzeń danych fragmentów w obrębie jednego kodu oraz analiza treści zakodowanych fragmentów pozwala wierzyć, że metoda ta może w przyszłości przynieść dodatkową wartość dla badań jakościowych. Warto pamiętać, że przeprowadzone badanie miało charakter pilotażowy i polegało na przetestowaniu użyteczności zaprojektowanego narzędzia, nie oferuje więc pełnego wykorzystania i zrozumienia potencjału płynącego ze zjawiska *crowdsourcingu* dla badań jakościowych.

Celem proponowanego sposobu użycia *crowdsourcingu* w analizie treści nie jest zastąpienie dotychczasowych metod badawczych ani wytworzenie nowej metodyki (Azzam, Harman 2015). Chodzi raczej o wsparcie dotychczasowych metod prowadzenia tego typu analiz. Przeprowadzony pilotaż

może wskazywać na kilka obszarów, w których to podejście może być wykorzystywane i rozwijane.

Po pierwsze, narzędzie może być pomocne w budowaniu klucza kodowego oraz testowaniu jego trafności. Proces ten zakłada stworzenie kodów *a priori*, a następnie przetestowanie ich trafności w ramach próbnego kodowania – sprawdzenie tego, czy mają one jasne definicje, czy są w podobny sposób rozumiane przez koderów i czy oddają całość mierzonego konstrukt (White, Marsh 2006; Maj 2013). W tym zadaniu badacze mogą wesprzeć użytkownicy platformy. Niestety, w pilotażowym badaniu poszczególnym kodom nie towarzyszyły dostępne dla użytkowników definicje, co znacznie obniża możliwości konstruowania jednoznacznych wniosków w obszarze trafności klucza kategorizacyjnego. To, co może być analizowane, to sposób rozumienia przez użytkowników danych pojęć i ich szerokość semantyczna.

Analizowane fragmenty zakodowane przez użytkowników pozwoliły zidentyfikować kody, których zrozumienie nastęcza największych problemów i w których precyzja oznaczania była najniższa. Poza tym, wśród fragmentów oznaczonych jednym kodem pojawiały się treści o różnym charakterze. Dobrym przykładem jest w tym przypadku kod „blogger o sobie”, gdzie wśród oznaczonych fragmentów pojawiały się opisy cech, zachowań i przyzwyczajzeń blogera. Może wskazywać to na potrzebę stworzenia klucza kodowego o hierarchicznej budowie i włączenia tych trzech kodów kategorizacyjnych jako podkategorii oryginalnego kodu. Można też wskazać na fragmenty, których zakwalifikowanie do jednej kategorii było dla uczestników trud-

nym zadaniem. Wskazują one na kody, które nie są rozłączne i których wyraźne granice powinny zostać nadane przez jasne definicje.

Kolejną wartością dodaną włączenia internautów do procesu kodowania tekstu jest możliwość skonfrontowania pracy profesjonalnych koderów z rozumieniem tekstu przez jego adresatów. Jednym z zarzutów kierowanych wobec analizy treści jest jej niska rzetelność, to jest wyniki mogą być obciążone subiektywnością koderów. Badacze często nakładają na tekst własny system znaczeń i nie ma pewności, że odczytują treści w ten sposób, w który robi to szersza społeczność (Gibbs 2011). W przypadku analizy tekstów z blogów czy innych treści publikowanych online użytecznym w konstrukcji definicji kodów oraz w instrukcjach dla koderów może się okazać spojrzenie na to, jak dane kategorie interpretują internauci. I tak jako reklamę czy autoreklamę użytkownicy określili nie tylko wymienianie konkretnych produktów, ale też wyrażanie pozytywnych opinii w danym temacie, bez intencji polecenia danego produktu czytelnikom. Badacz powinien zdecydować, czy tego typu fragmenty odpowiadają jego rozumieniu tej kategorii i świadomie włączyć je lub wyłączyć z jego definicji.

W naukach społecznych użytkownicy platform *crowdsourcingowych* bywają traktowani jako respondenci rekrutowani do próby badawczej (Behrend i in. 2011). Oczywiście, słabością tego sposobu rekrutacji badanych jest fakt, że nie prowadzi do konstrukcji reprezentatywnych prób. Traktowanie koderów rekrutowanych z tłumu jako respondentów otwiera nowe możliwości w badaniach nad rozumieniem treści pisanych. Przykładem może być

spojrzenie na te fragmenty, które przez część użytkowników oznaczone zostały jako opinia blogera, a przez innych jako obiektywny fakt. Odpowiedź na pytanie, czym językowo i znaczeniowo różnią się one od fragmentów, które w obydwu kategoriach nie sprawiały problemów interpretacyjnych użytkownikom, a także jak odpowiedzi różniły się wśród respondentów z różnym pochodzeniem społecznym, mogłaby okazać się ważnym wkładem w naukę o języku i konstruowaniu komunikatu.

Obszarem do dalszych eksploracji i eksperymentów jest również połączenie kodowania opartego na *crowdsourcingu* z możliwościami kodowania maszynowego. Współpraca internetowego tłumu z algorytmem była już wykorzystywana w projektach *crowdsourcingowych*, przynosząc znaczącą poprawę jakości zarówno w pracy uczestników projektu, których zadania w początkowym stadium zaangażowania były sprawdzane i poprawiane przez program, jak i w pracy algorytmu, który uczył się, obserwując schematy decyzyjne użytkowników (Kim i in. 2014). *Crowdsourcing* niesie ze sobą możliwość zidentyfikowania przypadków niejednoznacznych (brzegowych) oraz wsparcia zespołu koderów, co jest kluczowym dla kodowania maszynowego wysokiej jakości (Troszyński, Wawer 2017).

Ograniczenia prototypu narzędzia oraz samego *crowdsourcingu*

Omawiając ograniczenia badania, możemy wskazać na te wynikające z projektu i wykonania zaproponowanego oprogramowania do *crowdsourcingowego* kodowania treści, oraz na te, które są rezultatem charakteru samego zjawiska *crowdsourcingu*.

Najbardziej istotnym ograniczeniem w konstrukcji pilotażowanego narzędzia był brak definicji zaproponowanych kodów. Proces projektowania oprogramowania stanowił nieustanny kompromis pomiędzy jego rozrywkowym charakterem mającym uatrakcyjnić uczestnikom udział w zabawie (Eickhoff i in. 2014) a rygiorem metodologicznym koniecznym do uzyskania rzetelnych wyników. Odwołanie do „tagowania”, procesu raczej popularnego wśród internautów, miało stanowić uproszczenie procedury – jak się okazuje, nazbyt posunięte. Chociaż zapoznanie użytkowników z definicjami kodów przed rozpoczęciem kodowania znacznie wydłużyłoby proces przygotowawczy i mogłoby obniżyć atrakcyjność projektu, prowadziłoby z pewnością do uzyskania danych umożliwiających bardziej pogłębioną analizę, na przykład skupioną na trafności klucza kodowego. Angażowanie do pracy nad tekstem amatorów nie zmienia faktu, że proces kodowania treści wymaga odpowiedniego treningu dla koderów i upewnienia się, że ich rozumienie kategorii klasyfikacji jest podobne (Krippendorff 2004). W kolejnych próbach zastosowania podejścia opartego na *crowdsourcingu* powinno się skupić uwagę na znalezieniu kompromisu między koniecznością szkolenia użytkowników a atrakcyjnością procesu, chociażby przez skrócenie listy kodów lub próbę przygotowania szkolenia dla użytkowników w interaktywny i angażujący sposób.

Do ograniczeń stosowanej metody należy zaliczyć również możliwość nadawania tylko jednego kodu danemu fragmentowi tekstu. W związku z tym w poszczególnych kategoriach najczęściej wskazań otrzymały fragmenty w sposób najbardziej oczywisty do nich należące, jak opisy sytuacji regulowa-

nych prawem w przypadku tagu „fakt” albo zdania zawierające sformułowania typu „moim zdaniem” w przypadku tagu „opinia”. Fragmenty trudniejsze do dopasowania do jednej kategorii otrzymywały znacznie mniej oznaczeń w ramach jednego kodu, pojawiały się za to wśród fragmentów oznaczonych kilkoma kodami. Na przykład fragment „Dzisiaj chciałam Was zachęcić do szybkiego przeglądu zawartości dysku” pojawiał się w analizowanym materiale niemal tyle samo razy jako „zwrot do adresata” co „porada dla czytelników”. Chcąc podwyższyć próg liczby powtarzających się oznaczeń do włączenia fragmentu do analizy, takie sformułowania mogłyby zostać pominięte. Sposobem na rozwiązanie tego wyzwania byłoby usunięcie technicznego ograniczenia (a tym samym zwiększenie skomplikowania zadania dla użytkowników) lub stosowanie klucza kodowego, w którym kategorie są rozłączne.

Innym ograniczeniem oprogramowania jest brak wiedzy o uczestnikach projektu. Szczególnie dużym niedociągnięciem oprogramowania jest niemożliwość przyporządkowania kodu do osoby go nadającej, a także monitorowanie liczby uczestników. Jak pokazują inne projekty naukowe realizowane za pomocą platform *crowdsourcingowych*, ich uczestnicy są zwykle młodszy i lepiej wykształceni niż ogół populacji (Ross i in. 2010). Ponieważ sposób rozumienia analizowanego tekstu, jak również samych kategorii klasyfikacyjnych może być uzależniony od pochodzenia społecznego czy wcześniejszych doświadczeń koderów (Krippendorff 2004), wiedza na temat cech społecznych uczestników mogłaby stanowić dodatkową wartość w interpretacji wyników ich pracy. Prośba o udostępnienie danych uczestników podwyższa jednak próg wejścia

do projektu oraz generuje dodatkowe wyzwania związane z przetwarzaniem danych osobowych.

Wśród ograniczeń wynikających z samego charakteru zjawiska, jakim jest *crowdsourcing*, warto wymienić problem trudności analizowanego tekstu oraz kategorii klasyfikacyjnych. Autorzy zajmujący się problematyką skuteczności naukowych projektów *crowdsourcingowych* wskazują na to, że wraz ze wzrostem trudności zadania wzrasta również liczba nietrafnych odpowiedzi oraz „szum informacyjny” (Hutt i in. 2013). Tego typu wsparcie analizy treści może więc okazać się nieskuteczne w przypadku tekstów o trudnej tematyce lub przy próbie bardziej dogłębnej analizy. W przypadku kodu „neologizm”, którego definicja może nie być oczywista, większość oznaczonych fragmentów nie mieściła się w kategorii, była równoznaczna ze słowami obcojęzycznymi lub słowami powszechnie używanymi w języku polskim. Może to świadczyć o tym, że uczestnicy nie rozumieli tej kategorii. Innym problemem, który można zauważyć szczególnie wśród tagów nadawanych w pierwszym etapie kodowania (np. „imię bliskiego” albo „cytat”), jest niskie zrozumienie kontekstu, w jakim pojawiają się oznaczane wyrażenia.

Należy pamiętać, że potencjał projektów wykorzystujących *crowdsourcing* leży nie tylko w ich dodatkowej wartości dla samego procesu badawczego, ale również możliwości interakcji z potencjalnymi odbiorcami badania już od samego początku jego planowania i przeprowadzania oraz budowania ich zaangażowania w proces (Aristeidou, Scaulon, Sharples 2017). Projekty włączające szeroką publiczność w cały proces badawczy, a nie tylko pasywnie przekazujące wyniki, cieszą się ogromnym zainteresowaniem. Pozwalają na

skrócenie drogi między komunikacją wyników a ich wykorzystaniem w praktyce oraz pozwalają na dołączenie do publicznej agendy tematów ważnych społecznie (Gregory, Atkins 2018). Jednak to, co jest szan-

szą, rodzi również wyzwania. Dla powodzenia tego procesu naukowiec musi sprawnie posługiwać się nie tylko kompetencjami badawczymi, ale też komunikacyjnymi czy animacyjnymi.

Bibliografia

Aristeidou Maria, Scaulon Eileen, Sharples Mike (2017) *Profiles of Engagement in Online Communities of Citizen Science Participation*. „Computers in Human Behavior”, vol. 74, s. 246–256.

Azzam Tarek, Harman Elena (2015) *Crowdsourcing for Quantifying Transcripts: An Exploratory Study*. „Evaluation and Program Planning”, vol. 54, s. 63–73.

Barbrook Richard (1997) *Review: Collective net*. „New Scientist” [dostęp 17 października 2019 r.]. Dostępny w Internecie: <<https://www.newscientist.com/article/mg15621125-800-review-collective-net/>>.

Behrend Tara S. i in. (2011) *The Viability of Crowdsourcing for Survey Research*. „Behavior Research Methods”, vol. 43, s. 800–813.

Berry David (2011) *The Computational Turn: Thinking about the Digital Humanities*. „Culture Machine”, vol. 12, s. 1–22.

Bomba Radosław (2013) *Narzędzia cyfrowe jako wyznacznik nowego paradygmatu badań humanistycznych* [w:] Radomski Andrzej, Bomba Radosław, red., *Zwrot cyfrowy w humanistyce. Internet/ Nowe Media/ Kultura 2.0*. Lublin: E-naukowiec.

Brabham Daren C. (2009) *Crowdsourcing the Public Participation Process for Planning Projects*. „Planning Theory”, vol. 8, s. 242–262.

Brabham, Daren C. (2013) *Crowdsourcing: A Model for Leveraging Online Communities* [w:] Delwiche Aaron, Henderson Jennifer J., eds., *The Participatory Cultures Handbook*. New York: Routledge, s. 120–129.

Broer Christian i in. (2016) *Open Online Research: Developing Software and Method for Collaborative Interpretation*. „Forum: Qualitative Social Research”, vol. 17 [dostęp 18 listopada 2019 r.].

Dostępny w Internecie: <<http://www.qualitative-research.net/index.php/fqs/article/view/2388/4039>>.

Brosz Maciej, Bryda Grzegorz, Siuda Piotr (2017) *Od redaktorów: Big Data i CAQDAS a procedury badawcze w polu socjologii jakościowej*. „Przegląd Socjologii Jakościowej”, t. 13, nr 2, s. 7–23.

Bryda Grzegorz (2014) *CAQDAS a badania jakościowe w praktyce*. „Przegląd Socjologii Jakościowej”, t. 2, s. 12–38.

Cranshaw Justin, Kittur Aniket (2011) *The Polymath Project: Lessons from a Successful Online Collaboration in Mathematics*. „Proceedings of the SIGCHI Conference on Human Factors in Computing Systems (CHI '11)”, s. 1865–1874.

Davies Norman (2015) *Szlak Nadziei. Armia Andersa. Marsz przez trzy kontynenty*. Przełożyły Aleksandra Zych, Iwona Zych. Warszawa: Rosikon Press, s. 5–6.

Dzięglewski Mariusz (2017) *CAQDAS w badaniach digitalizacji i odbioru dziedzictwa kulturowego. Korzyści i ograniczenia*. „Przegląd Socjologii Jakościowej”, t. 13, nr 2, s. 24–45.

Eickhoff Carsten i in. (2014) *Quality through Flow and Immersion: Gamifying Crowdsourced Relevance Assessments*. „Proceedings of the 35th international ACM SIGIR conference on Research and Development in Information Retrieval”, s. 871–880.

Estelles-Arolas Enrique, Gonzáles-Ladrón-de-Guevara Fernando (2012) *Towards an Integrated Crowdsourcing Definition*. „Journal of Information Science”, vol. 38, s. 189–200.

Eveleigh Alexandra i in. (2013) *“I want to be a capitan! I want to be a capitan!”: Gamification in the Old Weather Citizen Science Project*.

„Proceedings of the First International Conference on Gameful Design, Research, and Applications”, s. 79–82.

Franzoni Chiara, Sauermann Henry (2014) *Crowd Science: The Organization of Scientific Research in Open Collaborative Projects*. „Research Policy”, vol. 43, s. 1–20.

Gibbs Graham (2011) *Analizowanie danych jakościowych*. Przełożyła Maja Brzozowska-Brywczyńska. Warszawa: Wydawnictwo Naukowe PWN.

Goban-Klas Tomasz (2004) *Media i komunikowanie masowe: teorie i analizy prasy, radia, telewizji i Internetu*. Warszawa: Wydawnictwo Naukowe PWN.

Gregory Amanda, Atkins Jonathan (2018) *Community Operational Research and Citizen Science: Two Icons in Need of Each Other?* „European Journal of Operational Research”, vol. 269, s. 1111–1124.

Howe Jeff (2006) *The Rise of Crowdsourcing*. „Wired Magazine”, vol. 14, s. 1–4.

Hutt Hugo i in. (2013) *How Clumpy Is My Image? Evaluating Crowdsourced Annotation Tasks*. „Computational Intelligence (UKCI), 13th UK Workshop”, s.136–143.

Kim Jinseop S. i in. (2014) *Space-time Wiring Specificity Supports Direction Selectivity in the Retina*. „Nature”, vol. 509, s. 331–348.

Krippendorff Klaus (2004) *Content Analysis: An Introduction to Its Methodology*. Thousand Oaks: Sage Publications.

Lévy Pierre (1997) *Collective Intelligence: Mankind's Emerging World in Cyberspace*. Cambridge: Perseus Books.

Maj Agnieszka (2013) *Analiza treści* [w:] Makowska Marta, red., *Analiza danych zastanych*. Warszawa: Wydawnictwo Naukowe Scholar, s. 127–147.

Niebalski Jakub (2013) *CAQDAS – oprogramowanie do komputerowego wspomaganie analizy danych jakościowych. Historia, ewolucja i przyszłość*. „Przegląd Socjologiczny”, t. 62, s. 153–166.

Ridge Mia (2011) *Playing with Difficult Objects: Game Designs to Improve Museum Collections* [w:] Trant J, Bearman D., eds., *Museums and the Web 2011: Proceedings*. Toronto: Archives & Museum Informatics, s. 3–10.

Robbins Stuart J. i in. (2014) *The Variability of Crater Identification among Expert and Community Crater Analysts*. „Icarus”, vol. 234, s. 109–131.

Ross Joel i in. (2010) *Who are the Crowdworkers? Shifting Demographic in Mechanical Turk*. „Proceedings of the 28th International Conference on Human Factors in Computing Systems, CHI 2010, Extended Abstracts Volume”, s. 2863–2872.

Schenk Eric, Guittard Claude (2011) *Towards a Characterization of Crowdsourcing Practices*. „Journal of Innovation Economics & Management”, vol. 7, s. 93–107.

Surowiecki James (2010) *Mądrość tłumu. Większość ma rację w ekonomii, biznesie i polityce*. Przełożyła Katarzyna Rojek. Gliwice: OnePress.

Troszyński Marek, Wawer Aleksander (2017) *Czy komputer rozpozna hejtera? Wykorzystanie uczenia maszynowego (ML) w jakościowej analizie danych*. „Przegląd Socjologii Jakościowej”, t. 13, nr 2, s. 62–80.

Wallace Rebekah D., Barger Charles T. (2014) *Identifying Invasive Species in Real Time: Early Detection and Distribution Mapping System (EDDMapS) and Other Mapping Tools* [w:] Ziska Lewis H., Dukes Jeffery S., eds., *Invasive Species and Global Climate Change*. Oxfordshire: CABI, s. 220–231.

Wexler Mark N. (2011) *Reconfiguring the Sociology of the Crowd: Exploring Crowdsourcing*. „The International Journal of Sociology and Social Policy”, vol. 31, s. 6–20.

White Marilyn D., Marsh Emily (2006) *Content Analysis: A Flexible Methodology*. „Library Trends”, vol. 55, s. 22–45.

Woolley Anita W. i in. (2010) *Evidence for a collective intelligence factor in the performance of human groups*. „Science”, vol. 330, s. 686–688.

Zhao Yuxiang, Zhu Qinghua (2014) *Evaluation on crowdsourcing research: Current status and future direction*. „Information Systems Frontiers”, vol. 16, s. 417–434.

Cytowanie

Lisek Katarzyna (2019) *Szanse i słabości wykorzystania crowdsourcingu do analizy treści*. „Przegląd Socjologii Jakościowej”, t. 15, nr 4, s. 250–270 [dostęp dzień, miesiąc, rok]. Dostępny w Internecie: <www.przegladsocjologiijakosciowej.org>. DOI: <http://dx.doi.org/10.18778/1733-8069.15.4.12>.

The Advantages and Limitations of Using Crowdsourcing for Content Analysis

Abstract: Content analysis has become a research method that is widely used not only in social sciences, but also in the humanities in general. The automation and computerization behind this method is gaining a lot of interest among researchers in Poland and around the world. New perspectives for the development of this field can be opened by the phenomenon of crowdsourcing – a virtual collaboration method whereby numerous anonymous users of new technologies are the participants. The first attempts to use this phenomenon in science were successful, both within exact sciences and the humanities. However, confirming the possibility of using crowdsourcing in content analysis requires further research and exploration.

The aim of this article is to present the attempt of using a pilot tool for crowdsourcing content coding. A reflection on the potential advantages and limitations of this approach will be offered, too. The author will provide a short characterization of the phenomenon of crowdsourcing and its application in science, as well as the description of the proposed tool. The article is concluded with the analysis of the opportunities and weaknesses that crowdsourcing can offer for the development of content analysis.

Keywords: crowdsourcing, content analysis, crowd, new technologies