

MAREK DEJA

Instytut Studiów Informacyjnych

Wydział Zarządzania i Komunikacji Społecznej, Uniwersytet Jagielloński

Analiza bayesowska w diagnozowaniu kultury informacyjnej organizacji

Bayesian Analysis in Diagnosing the Information Culture of an Organization

SŁOWA KLUCZOWE: kultura informacyjna, metodyka badań, statystyka bayesowska, wnioskowanie statystyczne, zachowania informacyjne

KEYWORDS: Bayesian statistics, information behavior, information culture, research methodology, statistical inference

Abstrakt

CEL/TEZA: Wnioskowanie bayesowskie w analizach statystycznych jest elementem pragmatycznego podejścia do prowadzenia badań ilościowych i mieszanych. Cel artykułu to przedstawienie bayesowskiej interpretacji wyników badań kultury informacyjnej w środowisku akademickim.

KONCEPCJA/METODYKA BADAŃ: Przeprowadzono analizę porównawczą na danych wykorzystanych wcześniej w badaniu kultury informacyjnej w środowisku organizacyjnym.

WYNIKI I WNIOSKI: Zastąpienie wartości prawdopodobieństwa testowego p wartością czynnika bayesowskiego zwiększa potencjał interpretacji wyników badań w naukach o komunikacji społecznej i mediach, które w znacznej mierze bazują na wykorzystaniu skal przedziałowych lub interwałowych, co wiąże się z trudnościami w ich interpretacji zgodnie z założeniami statystyki częstościowej.

OGRANICZENIA BADAŃ: Przedstawione porównanie nie uwzględnia wszelkich możliwych testów i implementacji czynnika bayesowskiego, a jedynie testowanie hipotez badawczych, jako podstawowej procedury opisu i weryfikacji dowodów naukowych w kontekście interdyscyplinarnym. Zgodnie z intencją autora i jego kompetencjami opisany został potencjał użyteczności czynnika bayesowskiego, a nie dowód matematyczny na istnienie przewagi statystyki bayesowskiej nad częstościową.

ORYGINALNOŚĆ/WARTOŚĆ POZNAWCZA: Statystyka bayesowska jest gałęzią analiz statystycznych o charakterze pragmatycznym. Ten typ analiz staje się coraz bardziej popularny w dyskursie interdyscyplinarnym, w szczególności w kontekście poszukiwania

alternatywnych i uniwersalnych metod wspierania decyzji i opisu dowodów naukowych, które byłyby zrozumiałe jednocześnie w wielu dyscyplinach nauki.

Wprowadzenie

Celem tego eseju badawczego jest przedstawienie charakterystyki wnioskowania bayesowskiego jako metody analizy statystycznej, która w opinii autora wpisuje się w pragmatyczne podejście do prowadzenia dociekań w naukach o komunikacji społecznej i mediach. Opracowanie stanowi też przyczynek do szerszej i pogłębionej analizy potencjału użycia wnioskowania bayesowskiego w nauce o informacji (informatologii).

W najprostszym możliwym ujęciu statystyka bayesowska stanowi typ analizy statystycznej przeznaczony dla badaczy i analityków, którzy chcą jednoznacznie zweryfikować prawdopodobieństwo, z jakim możliwe jest potwierdzenie hipotezy badawczej (Stamey et al., 2011). Klasyczna analiza statystyczna, nazywana też częstościową, ogranicza się do potwierdzenia, że wyniki zebrane w badaniu nie są przypadkowe (Lynch, 2007b). Wnioskowanie bayesowskie, bazujące na pierwszym z wymienionych typów analizy, jest zatem bardziej pragmatyczne. Ma bowiem na celu nie tylko wykluczenie możliwości wystąpienia błędu statystycznego w przedstawionym dowodzie naukowym – danych, ale także wzbogacenie analizy danych o pomiar prawdopodobieństwa, z jakim dostarczony dowód potwierdza przypuszczenia badacza. Stanowi to dodatkową wartość i potencjał do wykorzystania takich wyników w kontekście podejmowania decyzji i użycia wyników w praktyce (Kaplan, 2014).

Podstawowe pytania dotyczące diagnostycznego zastosowania analizy bayesowskiej, jakie można sformułować w relacji do nauk o komunikacji społecznej i mediach, są następujące: W jakim kontekście nauki społeczne, w tym nauka o informacji, potrzebują analizy bayesowskiej do weryfikacji hipotez badawczych? Czy statystyka bayesowska może być równie użyteczna w pracy analityka biznesowego wspierającego procesy decyzyjne, co w pracy badacza poszukującego dowodu naukowego?

W niniejszym tekście autor stara się w sposób możliwie syntetyczny i oparty na przykładach przedstawić swoją opinię dotyczącą użycia czynnika bayesowskiego w analizie statystycznej. Po pierwsze, dokonane zostało porównanie założeń metodologicznych dwóch gałęzi statystyki – bayesowskiej i częstościowej – w kontekście obszaru badań nauk o komunikacji społecznej i mediach, obejmującego kulturę informacyjną organizacji. Po drugie, przeprowadzono porównanie wyników badania na podstawie stratyfikacyjnej techniki losowego doboru próby na danych użytych wcześniej w badaniu kultury informacyjnej.

Statystyka częstościowa a wnioskowanie bayesowskie

W podejściu częstościowym do statystyki zakłada się, że parametry opisujące cechę populacji (np. średni czas wyszukiwania, średnia liczba pozytywnych rezultatów, średni

poziom akceptacji zachowania informacyjnego, średni poziom kompetencji cyfrowych) są stałymi, nieznanymi wielkościami. Próba, od której chcemy uzyskać opis tej cechy, jest pobierana z populacji, a wnioskowanie odbywa się na ogół poprzez testowanie hipotez lub określenie przedziału ufności (Stamey et al., 2011). W rzeczywistości w takiej analizie często występuje kilka trudności, np. w naukach społecznych niejednokrotnie pojawia się brak możliwości zdobycia danych o charakterze parametrycznym ze skal o charakterze przedziałowym lub interwałowym w odniesieniu do bardzo niestałych cech zachowań informacyjnych. W tym zakresie należy jednak szukać metod analizy nieparametrycznej, w której statystyka bayesowska także wykazuje przewagę, bo stochastyczna symulacja bayesowska traktuje wszystkie niewiadome identycznie, nie skupia się na oszacowaniu parametrów idealnej pozycji testowej – wartości średniej (Gill & Casella, 2009). Jest to zatem analiza pożądana w przypadku diagnozy kultury informacyjnej organizacji – bada się ją najczęściej jako zachowania podlegające czynnikom normatywnym, w których czynniki afektywne mogą stanowić czynnik losowy, zniekształcający rezultaty badania organicznego pod względem czasu obserwacji. W szczególności jednak trudnością użycia statystyki częstościowej w badaniach społecznych jest paradygmat „powtarzanego próbkowania”, który utrudnia interpretację wyników odnoszących się do diagnozy prowadzonej poza warunkami idealnymi – eksperymentem badawczym – co sprawia, że wyniki mogą być nieintuicyjne w kontekście ich interpretacji w dyskursie interdyscyplinarnym.

Główny problem z ustaleniem dowodów przez częstościowe testowanie hipotez polega na tym, że procedura ta opisuje warunkową prawdziwą wartość nieznanego parametru badanej cechy w populacji, podczas gdy w rzeczywistości badacze rzadko mają taką informację i skupiają się na próbie, od której symulują rozkład parametru badanej cechy. Klasyczne wnioskowanie częstościowe nie wiąże prawdopodobieństw ze współczynnikami wielkości efektu opisującymi badaną cechę, np. kulturę informacyjną i relacje pracownicze przejawiane w trakcie zachowań informacyjnych. Zamiast tego wnioskowanie częstościowe opisuje stan statystyk testowych i przedziałów ufności w hipotetycznym powtarzanym próbkowaniu z populacji bazowej, tj. kultury informacyjnej w jej czystej, eksperymentalnej formie, niezachwianej przez zdarzenia losowe. Badacz na podstawie rozkładu częstości dokonanych pomiarów wnioskuje, że gdyby hipoteza zerowa była prawdziwa, to przy wielokrotnym próbkowaniu otrzymalibyśmy porównywalną wartość cechy w odniesieniu do parametru całej populacji, do której odnosi się problem badawczy (Western, 1999).

W przeciwieństwie do wnioskowania częstościowego z powtarzanym próbkowaniem, które jest zwykle używane w naukach ścisłych i paradygmacie ilościowym nauk społecznych, statystyka bayesowska symuluje rozkład prawdopodobieństwa na podstawie parametrów statystycznych, np. próbkowania Monte Carlo łańcuchami Markowa dla rozkładu Cauchy'ego (Morey et al., 2011). Ten rozkład prawdopodobieństwa określa ilościowo niepewność badacza co do wartości parametru populacji. Jak zauważył Bruce Western (1999), „w praktyce socjologowie często interpretują wartości p i przedziały

ufności jako opisy prawdopodobnej wartości parametrów. W konsekwencji większość socjologów zachowuje się, jakby stosowali wnioskowanie bayesowskie, nawet jeśli nie przeprowadzają jawnie bayesowskich obliczeń” (Western, 1999, 9).

We wnioskowaniu bayesowskim probabilistyczna interpretacja parametrów przebiega w dwóch etapach. Po pierwsze, badacze posługują się subiektywną koncepcją prawdopodobieństwa. Po drugie, subiektywne rozkłady prawdopodobieństwa, zwane rozkładami *a priori*, są szacowane lub symulowane, zanim dane zostaną poddane analizie. Znacznie bardziej sensowne jest uzależnienie wniosków od tego, co jest faktycznie znane, czyli danych, a następnie ich weryfikacja w kontekście założeń początkowych badania (Lynch, 2007a). Twierdzenie Bayesa zapewnia możliwości w zakresie obliczania prawdopodobieństwa warunkowych zdarzeń losowych występujących w populacji, które mają potencjalny wpływ na uzyskane rezultaty. Statystyki bayesowskie mogą zatem zyskać na znaczeniu, gdy badacz chce badać kulturę informacyjną organizacji, ale wie, że potencjalnie na różnicę jego wyników w stosunku do wcześniej uzyskanych rezultatów mogą wpłynąć czynniki losowe związane z przejściowym stanem organizacji – atmosferą organizacyjną.

Kontekst diagnozy kultury informacyjnej organizacji

W kontekście badań nad kulturą informacyjną istotne są dwa główne założenia badawcze: kultura informacyjna to oparta na kompetencjach informacyjnych potencjalna zdolność osoby lub grupy do efektywnego uczestnictwa w kulturze informacji (Batorowska, 2013; Kisilowska, 2016) oraz kultura informacyjna to normy zachowań informacyjnych – indywidualne lub zbiorowe – ukierunkowane na efektywną realizację procesów informacyjnych i rozwój wiedzy (Deja, 2021; Virkus & Salman, 2020). Sporadycznie w literaturze te dwa konteksty – kompetencyjny i normatywny – traktowane są jako współzależne, jeżeli w diagnozie zachowań informacyjnych badacz za czynnik normatywny uznaje motywacje kognitywne (Deja & Rak, 2019).

Chociaż w obu wymienionych kontekstach w badaniach empirycznych dominuje paradygmat jakościowy, to nie oznacza to, że badania ilościowe nie są dobrą alternatywą diagnostyczną lub nie są komplementarne w stosunku do obserwacji jakościowej. W szczególności trzeba w tym zakresie zwrócić uwagę na problem kształtowania dyskursu międzynarodowego, w którym ogólnie zrozumiałe metody wspierające argumentację lub transparentność procesu badawczego są istotne dla zrozumienia przez szerokie grono odbiorców decyzji i procesu wnioskowania badacza, nawet bez szczególowej wiedzy na temat krajowego kontekstu, w którym dany system społeczny był diagnozowany (Lupia & Alter, 2014). Badania jakościowe wymagają znacznie większego zaangażowania badacza nie tylko w opis procedury gromadzenia i opracowywania danych, np. iteracyjnego tworzenia struktury kodowej, ale też w bardzo precyzyjną argumentację, która odzwierciedla jego czysto subiektywne wnioskowanie odnoszące się do intensywnych i wieloaspektowych obserwacji, co dla odbiorcy z innego regionu

kulturowego może okazać się barierą w zrozumieniu jakościowo i subiektywnie generowanych wniosków. W badaniach kultury informacyjnej problem ten jest szczególnie widoczny, gdy analizuje się komunikację naukową odnoszącą się do badań prowadzonych w różnych krajach i skrajnie różnych środowiskach informacyjnych organizacji. Są to konteksty na tyle odmienne, że tworzenie analogii ontycznych i epistemicznych na podstawie analiz jakościowych stwarza warunki jałowej dyskusji, w której badacze nie wspinają się znacząco po stopniach piramidy dowodu naukowego. Inaczej ujmując: obserwacje jakościowe o tak dużym zróżnicowaniu ontologicznym nie skłaniają badaczy do kontynuowania dyskursu i stawiania hipotez badawczych w celu zwiększenia istotności i powtarzalności badań naukowych w analogiach epistemicznych, np. na próbach randomizowanych, a to wyklucza możliwość dostarczenia najwyższej jakości dowodu naukowego – pochodzącego z metaanalizy (Moher et al., 2009; Stroup et al., 2000). W badaniach kultury informacyjnej brakuje klasycznie definiowanych dowodów naukowych opartych na podstawowych testach statystycznych. Badania te od wielu lat utrzymują się na poziomie obserwacji i wiedzy eksperckiej, które stanowią fundament piramidy dowodów w nauce; z nielicznymi przykładami badań ilościowych.

Hipoteza badawcza i prawdopodobieństwo jej potwierdzenia

Hipoteza zerowa jest właściwa dla danego testu statystycznego i może np. zakładać brak zależności między zmiennymi lub równość wartości średnich w badanych grupach respondentów. Do jej weryfikacji stosowane jest obliczanie wartości p , która – co warto zaznaczyć w kontekście omawianej statystyki bayesowskiej – nie odnosi się do prawdopodobieństwa, że hipoteza zerowa jest prawdziwa, co jest częstym błędem w interpretacji analiz częstościowych. Wartość p określa prawdopodobieństwo wystąpienia błędu statystycznego typu I, tj. odrzucenia hipotezy zerowej, gdy w rzeczywistości jest ona prawdziwa. Jest zatem prawdopodobieństwem zaobserwowania zbioru danych tak skrajnie małego lub dużego w rozkładzie normalnym jak ten, który faktycznie zaobserwowano, jeśli hipoteza zerowa jest prawdziwa (Kaplan, 2014).

Badacz odwołujący się do prawdopodobieństwa testowego p jest zmuszony interpretować hipotezę badawczą, opierając się na podstawowym warunku dowodowym, który pozostaje nieznanym, gdyż odwołuje się tylko do danych pierwotnych, zebranych w badaniu, z pominięciem założenia *a priori*. Mankamentem klasycznego wnioskowania statystycznego jest przede wszystkim to, że hipoteza zerowa nie jest równoznaczna z hipotezą badawczą i często stanowi jej negację, dla której z danych wyliczane są szanse na jej niezafałszowane odrzucenie. Szanse te powinny być jak najmniejsze, bliskie zeru, aby można było się skupić na wartości efektu i potwierdzeniu siły dowodu odnoszącej się np. do stopnia zależności lub różnicy uzyskanych wartości średnich. Jest to informacja trudna do użycia w procesie decyzyjnym. Dostajemy bowiem potwierdzenie tego, że dane nie wskazują na możliwość wystąpienia błędu statystycznego typu I oraz że wielkość efektu jest przeciętna lub duża, np. informację, że osoby, które stanowiły

grupę właściwą, uzyskały nieznaczny, umiarkowany albo dużo niższy lub wyższy wynik. W odniesieniu do zagadnień takich jak stopień akceptacji zachowań informacyjnych albo poziom kompetencji, wyrażonych w skalach interwałowych, taki dowód naukowy na niewiele się zdaje osobom, które muszą oszacować prawdopodobieństwo np. tego, że inwestycja w kurs lub interwencja w zespole będzie opłacalna pod względem potencjalnych rezultatów. Inwestycja zapewne się opłaci, ale jaka jest skala prawdopodobieństwa w tym zakresie, biorąc pod uwagę, że dana organizacja różni się od tej wcześniej badanej, pracownicy przejawiają inne nastawienie do kompetencji, a sytuacja w otoczeniu organizacji jest bardzo niestabilna? Tego osoba decyzyjna nie może już zweryfikować, bo w swoich szacunkach badacze nie uwzględnili założeń *a priori*.

Dowód naukowy w badaniu kultury informacyjnej

Najprostszą metodą dostarczenia dowodu naukowego w badaniach ilościowych kultury informacyjnej rozumianej w kontekście kompetencyjnym jest test T Studenta lub jego nieparametryczne alternatywy dla dwóch grup obserwacji – test U Manna–Whitneya i test Wilcoxon, oraz analiza wariancji (ANOVA) i jej nieparametryczna wersja – test H Kruskala–Wallisa dla wielu niezależnych grup obserwacji. Testy te występują w dwóch podstawowych wariantach: a) dla prób niezależnych, b) dla pomiarów sparowanych lub prób zależnych, a ponadto test T przeprowadza się dla jednej próby w odniesieniu do danych z populacji. Opcja pierwsza (a) zakłada najczęstszy wariant eksperymentalny – występowanie grup testowych (kontrolnej) i właściwej, między którymi porównywana jest wartość parametru populacji, tj. wynik średni lub mediana. W opcji drugiej (b) badacz zakłada, że poszukiwana jest różnica między wskazaniami pomiaru przed interwencją i po niej, np. po kursie z zakresu OSINT, aby wykazać wpływ tej interwencji na zmianę poziomu kompetencji. Hipoteza zerowa w wymienionych testach zakłada brak statystycznie istotnej różnicy między pomiarami wykonanymi w grupach, a gdy potwierdzenie takiej równości średnich jest mało prawdopodobne do udowodnienia, to wartość efektu w grupie właściwej (*t* lub *F*) wskazuje na to, jak duża jest różnica wartości parametru w grupach w stosunku wahań obserwacji wewnątrz grupy (Goss-Sampson, 2020). Generalnie testy oparte na porównaniach parametrów mogą być bardziej przydatne w kontekście kompetencyjnym diagnozy kultury informacyjnej, co zostanie opisane w kolejnym podrozdziale na przykładzie badania przeprowadzonego w 2019 roku.

Mimo że takie testy są podstawowymi formami analizy danych ilościowych, to w odniesieniu do diagnozy kultury informacyjnej badacze częściej stosują analizę regresji, tj. korelacji i regresji liniowej, aby badać strukturę modelu badawczego na podstawie zależności zmiennych charakteryzujących zachowania informacyjne jako wskaźniki kultury informacyjnej (Choo et al., 2006; 2008; Deja & Wójcik, 2021). Kulturę w kontekście normatywnym lub behawioralnym łatwiej jest diagnozować przez relacje zachodzące między pracownikami, a w modelu statystycznym – relacje między zmiennymi,

które opisują zbiorowe zachowania informacyjne w skali interwałowej, najczęściej skali Likerta. Inaczej rzecz ujmując: dwa zachowania w zakresie np. poszukiwania informacji są mierzone w skali akceptacji społecznej Likerta, aby móc dokonać analizy ich zależności. Badacze zakładają, że im wyższa zależność w zebranych danych, tym bardziej współzależne wyniki opisujące zachowania informacyjne w kulturze populacji, a zatem bardziej jednorodnie kształtujące kulturę informacyjną i wszelkie czynniki efektywności, które są od niej uzależnione. Hipoteza zerowa dla analizy korelacji zachodzącej między zachowaniami informacyjnymi zakłada brak istotnej zależności między zachowaniami.

Zarówno w wariancie kompetencyjnym, jak i normatywnym warto zwrócić uwagę na to, co daje badaczowi powołanie się na wartość testową p . Mark Goss-Sampson opisał ten problem tak, że gdy wartość $p < 0,05$, mamy mniej niż 5% szans na wystąpienie błędu statystycznego typu I, a zatem badacz może z dosyć dużą pewnością sprawdzić wartość efektu, tzn. siły dowodu na to, że hipoteza alternatywna ma podstawy zastosowania. Innymi słowy: kiedy badacz stawia hipotezę badawczą, najczęściej zakłada hipotezę alternatywną (zależność), a stara się ją potwierdzić przez odrzucenie hipotezy zerowej (szansę na to, że brak zależności jest nieprawdziwy, gdy zakładamy jego prawdziwość), tj. badacz zakłada istnienie związku o pewnej domniemanej intensywności między zmiennymi lub różnicę wartości średnich zmiennych, które mierzą skalę lub stopień akceptacji pewnych zachowań w badanej populacji zainteresowania. Tak naprawdę w analizie statystycznej badacz weryfikuje brak tego związku lub równość średnich w danych. W wariancie normatywnym zależność między dwoma zachowaniami w danych wyrażona jest wartością efektu r Pearsona (obserwacja czasu procesów lub częstości zachowań w skali ciągłej) lub ρ Spearmana (samoocena w skali interwałowej), a dla małych prób τ Kendalla, która określa stopień korelacji. Siła efektu jest następnie arbitralnie, w zależności od uprawianej dyscypliny naukowej, interpretowana w przedziałach: brak/mały/średni/duży/bardzo duży/ekstremalny (Goss-Sampson, 2020).

Statystyka częstościowa jest szczególnie potrzebna w nauce tam, gdzie możliwe jest zdobycie niepodważalnego dowodu na oddziaływanie danej interwencji na próbę w eksperymencie badawczym w warunkach idealnych, z kontrolowaną próbą randomizowaną, która ma minimalizować prawdopodobieństwo wpływu nieznanymi czynników środowiskowych spoza modelu na stronniczość uzyskanych wyników i jednocześnie zwiększyć szansę na wykazanie istotnego wyniku efektu statystycznego (Good, 2006). W takich warunkach od korelacji można łatwo przejść do współczynnika determinacji R^2 i doszukiwania się predykcji badanych czynników, np. kształtowania się kultury informacyjnej w organizacji.

Czy takie warunki są możliwe do osiągnięcia podczas zwykłej ankiety online w odniesieniu do ludzkich zachowań, samooceny kompetencji lub ocen studenckich? Na to pytanie nie ma jednoznacznej odpowiedzi, chociaż autor tego eseju skłania się ku odpowiedzi „Nie”. Przyczyn jest kilka: występowanie mnogości i różnorodności czynników afektywnych, krótkotrwałe stany i sytuacje problemowe oraz obciążenie rozkładu obserwacji zamkniętą skalą porządkową, co skutecznie utrudnia uzyskanie rozkładu

normalnego w rozkładzie częstości odpowiedzi. W większości przypadków analizowanej literatury metodologicznej, gdy autorzy procedur badawczych starają się odnieść interpretację wyników statystycznych do danych interwałowych i nieparametrycznych, mówi się o konieczności zachowania dużej ostrożności w zakresie wnioskowania opartego na wartości efektu i prawdopodobieństwie testowym (Goss-Sampson, 2020). Trudno jest takim wynikom zaufać na tyle, aby móc na podstawie takich danych podejmować racjonalne decyzje w organizacji. Potrzebę alternatywnych podejść do analizy odczuli w szczególności analitycy danych i informacji, którzy bardzo często nie mogą zapewnić równego rozkładu próby, a jednocześnie muszą łączyć dane wtórne i pierwotne z różnych modeli danych. Dodatkowo zwiększa to obciążenie wnioskowania czynnikami zewnętrznymi, których nie można uwzględnić w modelu badawczym, a poprzec można je wyłącznie intuicją i wnioskowaniem indukcyjnym (Cleveland, 2001; Ziemba, 1961). W ostatnich latach wzrosło też zainteresowanie statystyką bayesowską w kontekście eksperymentów kontrolowanych w firmach IT, w których prawdopodobieństwo osiągnięcia lepszych rezultatów lub wyższych przychodów jest kluczem do podejmowania decyzji (Kamalbasha & Eugster, 2021).

W zakresie prowadzenia dyskursu naukowego ogólna ostrożność stawianych wniosków jest akceptowalna, np. autor powołujący się na wyniki badania może wziąć poprawkę na możliwość wystąpienia statystycznej stronniczości wyników, aby nie dopuścić w swoim systematycznym przeglądzie badań do błędnego formułowania warunków kategoriycznych odnoszących się do zachowań ludzkich. Jednak w zakresie implikacji wyników i ich aplikacji w praktyce zarządzania informacją może się okazać, że częstościowe podejście nie uwzględnia początkowej niepewności w stosunku do niższej jakości dowodów, które następnie są trudne do zoperacjonalizowania bez ryzykownych nadinterpretacji. To, co przemawia za użyciem statystyk bayesowskich w pracy analityka danych oraz badacza, który przyjmuje pragmatyczne założenia metodologiczne, to stanowisko relatywistyczne, tj. wnioskowanie prawdopodobne lub inaczej ujmując: rozumowanie indukcyjne, w którym badacz racjonalnie może przechodzić od wiary w przesłanki do czasowej wiary we wniosek, odwołując się do prawdopodobieństwa potwierdzenia hipotezy alternatywnej i biorąc pod uwagę wiarę w hipotezę zerową (Ziemba, 1961).

Użycie czynnika bayesowskiego w badaniu kultury informacyjnej

Główną zaletą wnioskowania bayesowskiego jest inne niż klasyczne pojmowanie prawdopodobieństwa, tj. przez pryzmat subiektywnego prawdopodobieństwa zdarzeń losowych. Przyjmijmy, że w badaniu kultury informacyjnej jedno z pytań dotyczące użycia procedury gromadzenia danych to pytanie zamknięte z odpowiedzią binarną „Tak/Nie”. Statystyka częstościowa definiuje prawdopodobieństwo na podstawie częstości zdarzeń w wielokrotnej, a nawet nieskończonej serii prób. Mamy zatem 50% szans na wybór odpowiedzi „Tak” przy założeniu, że jeżeli respondent nie będzie miał pojęcia,

jak odpowiedzieć, i losowo wybierze odpowiedź, to w nieskończonej serii prób odpowiedź „Tak” będzie stanowiła także 50% odpowiedzi. Statystyka bayesowska definiuje prawdopodobieństwo jako subiektywną reprezentację niepewności co do takich zdarzeń. W takiej perspektywie, gdy zakładamy, że prawdopodobieństwo uzyskania odpowiedzi „Tak” jako przypadku losowego w pojedynczym wyborze respondenta wynosi 50%, to bierzemy też pod uwagę założenie *a priori*, że zasłania on oczy, aby ta losowość wyboru była faktycznie przypadkowa, i wybór „Tak” albo „Nie” jest równie prawdopodobny. Ponadto badacz, który wie, jak respondenci udzielali odpowiedzi wcześniej w innym badaniu z użyciem tego pytania, może także przyjąć, że proporcja odpowiedzi wynosi 50 : 50 albo 70 : 30, bo wcześniej na odpowiedź wpływ miał podobny sposób udostępniania procedury.

W statystyce częstościowej wnioskujemy z danych *a posteriori*, a w statystyce bayesowskiej zderzamy twierdzenie *a priori* z rozkładem obserwacji *a posteriori* uzyskanym z danych, gdzie we wnioskowaniu od razu możemy dokonać oszacowania prawdopodobieństwa, że hipoteza zerowa jest wielokrotnie bardziej prawdopodobna do potwierdzenia niż hipoteza alternatywna (lub odwrotnie). Dzięki temu badacz może w analizie zweryfikować siłę dowodu na potwierdzenie hipotezy badawczej bez dodatkowych, autonomicznych oszacowań odnoszących się do wielkości różnicy parametru, jak ma to miejsce w statystyce częstościowej (Goss-Sampson, 2020).

Czy zatem w naukach o komunikacji społecznej i mediach, a w szczególności w badaniu kultury informacyjnej, gdzie zachodzi trudność zachowania warunków eksperymentalnych w diagnozie, istnieje konieczność stosowania statystyk częstościowych? Zdecydowanie nie. W kilku dotychczasowych badaniach kultury informacyjnej (Abrahamson & Goodman-Delahunty, 2013; Choo et al., 2006, 2008; Deja & Wójcik, 2021) badacze nie stosują czystej procedury eksperymentalnej, jest to raczej obserwacja przypadku szczególnego z techniką ankiety, a co najwyżej quasi-naturalne podejście eksperymentalne, w którym grupy wyodrębniane są naturalnie, na podstawie kategorii obserwacji – atrybutów kultury informacyjnej – charakteryzujących badane środowisko informacyjne. Diagnoza kultury informacyjnej ma w takich projektach badawczych wymiar pragmatyczny, w którym z jednej strony celem jest dostarczenie dowodu naukowego, ale z drugiej – realizacja tego celu ma być aplikowana w projektowaniu i usprawnianiu działania systemów informacyjnych organizacji (Materska, 2007).

Tak używane modele badawcze mogą być wykorzystywane również przez praktyków w diagnostyce zarządzania informacją, np. analityków biznesowych, którzy rozwijają swoją wiedzę ekspercką na podstawie faktów, dowodów naukowych, na bazie których tworzą swoje przypuszczenia (Cleveland, 2001), a przede wszystkim prowadzą własne analizy instytucjonalne, aby wspierać decyzje w różnych typach organizacji (Zych, 2020). Wnioskowanie bayesowskie na podstawie prawdopodobieństwa potwierdzenia hipotezy badawczej, a nie częstościowa negacja błędu statystycznego, może być zatem bardziej użyteczne do oceny w analizie statystycznej możliwości wystąpienia efektów wynikających z decyzji odnoszących się do kształtowania kultury informacyjnej w kontekście

kompetencyjnym (inwestycja w kursy poszerzające kompetencje informacyjne) i normatywnym (inwestycja w kształtowanie relacji między ludźmi i komunikację cyfrową).

Przykład analizy statystycznej wyników badania kultury informacyjnej w organizacji

Ilościowe badania kultury informacyjnej najczęściej oparte są na pomiarach w interwałowej skali Likerta (Deja, 2021). Użycie tej skali stwarza trudność ze wspomnianą już wcześniej parametrycznością wyników. Thomas Lumley et al. (2002) potwierdzili, że gdy mamy do czynienia z małymi próbkami, trudnością we wnioskowaniu statystycznym jest to, że większość podstawowych metod statystycznych wymaga założeń dotyczących rozkładu normalnego. Dlatego argumentem przemawiającym za użyciem testów nieparametrycznych opartych na rangach jest powszechne stosowanie w nauce o komunikacji społecznej i mediach skal porządkowych lub interwałowych – zwłaszcza w kontekście problemów badawczych odnoszących się do ludzkich zachowań, kompetencji lub samooceny różnych czynników normatywnych w organizacji. Mnogość ukrytych czynników oddziałujących na ludzkie zachowania i ich zbiorową percepcję jest tak duża, że najczęściej nawet w projekcie eksperymentalnym nie jest możliwe ich całkowite wykluczenie lub uwzględnienie w modelu statystycznym. Główna uwaga badacza powinna być jednak zwrócona na fakt, że nawet jeżeli zmienna wynikowa obliczona jest z wartości średniej lub sumy kilku itemów/opisów w ramach każdej obserwacji, to i tak przedziałowy układ skali Likerta zwiększa szanse na uzyskanie danych nieparametrycznych nawet w dużych próbach badawczych (Bishop & Herron, 2015).

Ponadto Phillip Bishop i Robert Herron zwracają uwagę na brak logiki interpretacji wyniku zapisanego jako 4,53 w pięciostopniowej skali interwałowej, który i tak uwzględnia czwarty próg skali „Raczej się zgadzam”, a odczytywany jest jako *Raczej się zgadzam*.⁵³ Dlatego do odczytywania statystyk nieparametrycznych w statystyce, a w szczególności w statystyce bayesowskiej, powinno stosować się wartość mediany dla oszacowanego parametru populacji z małej próby, ponieważ a) badacz automatycznie jest ostrożniejszy w wydawaniu precyzyjnych osądów co do pomiaru, b) interpretacja prawdopodobieństwa według statystyki bayesowskiej ma znacznie więcej sensu, gdy przy porównywaniu median odnoszących się do interwałów skali Likerta nie staramy się na siłę tworzyć ścisłych przewidywań dotyczących parametru populacji na podstawie danych dotyczących ludzkich opinii, w dodatku używamy predefiniowanych stopni skali (Gill & Casella, 2009; Hill & Kriesi, 2001).

Do diagnozowania kultur informacyjnych stosuje się trzy podstawowe typy skal pomiarowych:

- Typ kategoriowy – dane o charakterze nominalnym wskazujące na wystąpienie cechy w dwóch lub kilku pozycjach lub wariantach, najczęściej wykorzystywane do dzielenia zbiorowości (Płeć), ale także do uzyskania binarnego potwierdzenia obserwacji cechy (Tak/Nie). Przykład w nauce o informacji: Czy używasz

kompetencji A zdobytej w trakcie kursu w miejscu pracy? Czy bez przeszkód realizujesz proces B w miejscu pracy? Czy poszukujesz porady wśród współpracowników, gdy nie możesz dotrzeć do procedury C? Czy samodzielnie rozwiązujesz problem w sytuacji D? Wskaż swój poziom uprawnień w systemie E.

- Typ porządkowy/interwałowy – dane o charakterze pomiaru intensywności cechy w zdefiniowanych uprzednio stopniach z pozycją zera bezwzględnego, tj. braku obserwacji. Przykład: Nauczyciel w przyjętej skali ocen mierzy poziom opanowania umiejętności przetwarzania danych z modeli relacyjnych do postaci informacji w skali od 1 do 5, a badacz zbiera te dane do modelu statystycznego, gdzie zero oznacza brak ukończenia kursu. Respondent w odpowiedzi na zadane przez badacza pytania udziela odpowiedzi w skali Likerta odnośnie do stopnia akceptacji danego twierdzenia odnoszącego się do jego stanu (samoocena).
- Typ ciągły/ilorazowy – dane stanowiące najczęściej występującą podstawę dowodu naukowego w naukach ścisłych i przyrodniczych, odzwierciedlające wprost wielkość lub liczebność obiektów w każdej obserwacji z próby. W nauce o informacji w skali takiej można uwzględnić np. liczbę wyników wyszukiwania, liczbę cytowań lub czas realizacji procesu informacyjnego.

Zarówno w statystyce częstościowej, jak i statystyce bayesowskiej każda z powyższych skal może zostać wykorzystana do weryfikacji hipotezy zerowej i hipotezy badawczej. Należy jednak dobrać właściwy test statystyczny do typu danych. Dane ciągłe zwiększają szansę na pomyślne użycie testów parametrycznych. Dane porządkowe i interwałowe, nawet po przekształceniach (z wyjątkiem przekształceń logarytmicznych), wymagają użycia statystyk nieparametrycznych, a dane kategoriowe – użycia statystyk typowo częstościowych w poszukiwaniu dowodów na weryfikacje powiązań między miarami kategoriowymi, jak np. test chi-kwadrat (Goss-Sampson, 2020).

Przypadek: kontekst kompetencyjny

Cel w badaniu kultury informacyjnej dotyczy weryfikacji założenia, że w poczuciu empowermentu w miejscu pracy zachodzi statystycznie istotna różnica między absolwentami, którzy ukończyli kurs zaawansowanego przetwarzania informacji ($N = 35$) a którzy go nie ukończyli ($N = 15$). Wykorzystany został tylko fragment obserwacji z pierwotnego zestawu danych, którego użyli w badaniu Deja et al. (2021). Do odpowiedzi została wybrana losowo próba piętnastu respondentów, którzy także dokonali samooceny swojego empowermentu w miejscu pracy, byli absolwentami studiów na tym samym uniwersytecie, na kierunkach prowadzonych w dyscyplinie nauk społecznych, i wypełnili ankietę nie później niż 6 miesięcy od ukończenia studiów.

Podejście do diagnozy kultury informacyjnej w przeprowadzonym badaniu (Deja et al., 2021) było kognitywne – pewien zestaw kompetencji jest czynnikiem motywującym do przejawiania postaw informacyjnych świadczących o empowermentie pracownika (Batorowska, 2009; 2013). W przeciwieństwie do pierwotnego badania, analizującego

relację poziomu kompetencji i poziomu empowermentu absolwenta, w tym eseju przedstawiona jest inna hipoteza badawcza: istnieje statystycznie istotny wpływ kompetencji zdobytych przez studenta na ostatnim roku studiów, podczas kursu w zakresie zaawansowanego przetwarzania informacji w modelach danych, na jego postawy informacyjne jako absolwenta, których samoocena odzwierciedla ogólne poczucie empowermentu w miejscu pracy. Quasi-naturalny projekt eksperymentu zakłada zatem, że grupa kontrolna nie ukończyła kursu i jej samoocena empowermentu może być statystycznie istotnie niższa niż u osób, u których zdobyte kompetencje informacyjne miały wpływ na ich samoocenę wartości na rynku pracy.

W drugim celu przeprowadzonej analizy założono weryfikację prostej hipotezy badawczej, że czynniki empowermentu są ze sobą związane w obu grupach badawczych. Cel ten został określony, aby uzupełnić przykład o analizę dwustronnej korelacji zmiennych, która odnosi się do niewielkiej próby badawczej ($N = 50$). Analiza ta jest bardzo często prowadzona w przypadku badań ilościowych kultury informacyjnej w kontekście normatywnym, gdzie współzależność zachowań informacyjnych jest elementem efektywności działania w kulturze informacji (Abrahamson & Goodman-Delahunty, 2013; Choo et al., 2006).

W opisywanym przypadku poziomy empowermentu w miejscu pracy zostały zmierzone skalami interwałowymi: skala Likerta od 1 = Nie zgadzam się do 5 = Zgadzam się; 0 = Nie wiem. Z tego względu przeprowadzono porównanie statystyk nieparametrycznych za pomocą testu U Manna-Whitneya, który koncentruje się na porównaniu wartości mediany wyników w celu uniknięcia błędnej interpretacji zmiennej jako parametrycznej. Ponadto wielkość próby jest na tyle mała i nierówno rozłożona w grupach, że uzyskanie rozkładu normalnego dla wartości średniej opisującego parametr w populacji jest bardzo niewielkie. Test ten nie przyjmuje założeń odnośnie do kształtu rozkładu odpowiedzi. W badaniu zgodnie z modelem Spreitzer (2007) zadano cztery pytania, na które respondenci odpowiadali, w skali Likerta używając trzech itemów na każdą odpowiedź – po trzy opisy postaw w miejscu pracy określające odpowiednio: „Znaczenie” wykonywanej pracy, „Kompetencja” do wykonywania pracy, „Autodeterminacja” do podejmowania samodzielnych decyzji odnośnie do wykonywanej pracy, „Wpływ” na środowisko informacyjne w miejscu pracy.

Hipoteza zerowa H_0 zakładała, że różnica w samoocenie empowermentu nie występuje w grupie właściwej i grupie kontrolnej, a hipoteza alternatywna H_1 zakładała, że istnieje różnica i zgodnie z hipotezą badawczą grupa właściwa przejawia wyższy poziom empowermentu.

Jak przedstawia tabela 1, w przypadku statystyk częstościowych rezultat wskazuje, że szanse na wystąpienie błędu statystycznego typu I są bardzo niewielkie, i można wnioskować, że istnieje statystycznie istotna różnica wartości parametru na podstawie danych ($p < 0.001$). Powszechna interpretacja wielkości efektu wyrażonego rangowo-dwuseryjnej korelacji r przedstawiona przez Kerby'ego (2014) jest taka, że statystyka ta wskazuje na stosunek różnicy proporcji par odpowiedzi w dwóch grupach badawczych,

Tabela 1. Test U Manna-Whitneya

	U	p	r
Znaczenie	448,500	< ,001	0,709
Kompetencja	474,000	< ,001	0,806
Autodeterminacja	456,000	< ,001	0,737
Wpływ	495,000	< ,001	0,886

Źródło: opracowanie własne w programie JASP 0.16, 2022

potwierdzających hipotezę badawczą, i par, które jej nie potwierdzają. Dla wszystkich czterech wskaźników empowermentu wskazuje na istnienie dużej różnicy – około 85–90% wyników w dwóch porównywanych grupach potwierdza hipotezę, że osoby, które ukończyły kurs zaawansowanego przetwarzania informacji, osiągają wyższe wyniki samooceny empowermentu w miejscu pracy.

Tabela 2. Bayesowski test U Manna-Whitneya

	BF ₁₀	U	Rhat
Znaczenie	12,007	448,500	1,004
Kompetencja	29,281	474,000	1,009
Autodeterminacja	27,316	456,000	1,009
Wpływ	69,168	495,000	1,009

Wynik oparty na algorytmie augmentacji danych z 5 łańcuchami po 1000 iteracji.

Źródło: opracowanie własne w programie JASP 0.16, 2022

Interpretacja bayesowska wyników jest nieco dokładniejsza, bo dla każdego wskaźnika uzyskano wyniki wskazujące na inny poziom dowodu na większe prawdopodobieństwo potwierdzenia hipotezy alternatywnej – badawczej w stosunku do hipotezy zerowej. Statystyka BF₁₀ określa, ile razy bardziej prawdopodobne jest potwierdzenie hipotezy badawczej w stosunku do hipotezy zerowej, że na 525 par odpowiedzi 85–90% odpowiedzi przemawia za hipotezą badawczą, a 10–15% za jej negacją. Zaletą takiej prezentacji jest to, że jeżeli hipotezą badawczą byłaby hipoteza zerowa, to można to prawdopodobieństwo odwrócić w statystyce BF₀₁. Mamy zatem dwunastokrotnie większe prawdopodobieństwo na to, że potwierdzimy zmierzoną różnicę w populacji dla wskaźnika „Znaczenia”; dwudziestodwukrotnie większe prawdopodobieństwo na potwierdzenie różnicy wyników w przypadku wskaźnika samooceny „Kompetencji”; dwudziestosiedmiokrotnie większe prawdopodobieństwo uzyskania wyższych wyników „Autodeterminacji” w miejscu pracy i sześćdziesięciokrotnie większe

prawdopodobieństwo, że osoby, które ukończyły kurs zaawansowanego przetwarzania informacji będą miały wyższą samoocenę „Wpływu” na swoje środowisko informacyjne w pracy. Według interpretacji van Doorna (2021) są to trzy silne dowody i jeden bardzo silny dowód potwierdzające uznanie hipotezy badawczej. W obu przypadkach interpretacji dane odnoszą się do poniższych statystyk opisowych.

Tabela 3. Statystyki opisowe

Grupa	N	Średnia	Mediana	SD	SE
1	35	4,386	4	0,708	0,120
2	15	3,400	3	0,471	0,121
1	35	4,400	4	0,684	0,116
2	15	3,067	3	0,863	0,223
1	35	4,171	4	0,618	0,104
2	15	2,867	3	0,954	0,246
1	35	4,457	4	0,586	0,099
2	15	2,800	3	0,819	0,212

1 – grupa właściwa; 2 – grupa kontrolna

Źródło: opracowanie własne w programie JASP 0.16, 2022

Grupa kontrolna na ogół nie była pewna odnośnie do tego, jaki ma wpływ na swoje otoczenie i czy zdobyte kompetencje ułatwiają im samodzielne osiągnięcie celów w znaczącym dla nich kierunku rozwoju kariery ($Me = 3$). W grupie właściwej respondenci mieli o jeden próg w skali większą pewność w zakresie tych wskaźników ($Me = 4$), a największą przeciętną pewność grupa właściwa osiągnęła co do zgodności, czy kompetencje w zakresie użycia modeli danych dają im swobodę wpływania na ich środowisko informacyjne ($\bar{S}r. = 4,457$; $SD = 0,586$). Jest to jednocześnie największa zmierzona rozbieżność wartości średnich, wskazująca na to, że zdobyte kompetencje modelowania danych najmocniej oddziałują na empowerment absolwenta w miejscu pracy pod względem jego potencjalnego wpływu na wykonywane zadania.

W tabelach 4 i 5 przedstawione zostały wyniki analizy korelacji dwustronnej czynników empowermentu w miejscu pracy. Wyniki analizy częstościowej w tabeli 4 wskazują, że mamy bardzo niewielkie szanse na fałszywą negację hipotezy zerowej $p < 0,001$, więc miara efektu τ B jest wskazaniem, że mamy istotne podstawy do przyjęcia założenia o istnieniu przeciętnej korelacji wszystkich zmiennych w modelu.

Analiza bayesowska jest bardziej konserwatywna i oznacza istotność efektu τ B tylko wtedy, gdy dowody są mocne, tj. $BF > 10$. Czynniki Bayesa przedstawiają

Tabela 4. Korelacje dwustronne dla małej próby

		tau B Kendalla		p
Znaczenie	- Kompetencje	0,481	***	< ,001
Znaczenie	- Autodeterminacja	0,468	***	< ,001
Znaczenie	- Wpływ	0,536	***	< ,001
Kompetencje	- Autodeterminacja	0,456	***	< ,001
Kompetencje	- Wpływ	0,559	***	< ,001
Autodeterminacja	- Wpływ	0,475	***	< ,001

* $p < ,05$; ** $p < ,01$; *** $p < ,001$

Źródło: opracowanie własne w programie JASP 0.16, 2022

Tabela 5. Korelacje dwustronne dla małej próby z czynnikiem bayesowskim

		tau B Kendalla		BF ₁₀
Znaczenie	- Kompetencje	0,481	***	25772,512
Znaczenie	- Autodeterminacja	0,468	***	13431,881
Znaczenie	- Wpływ	0,536	***	437013,526
Kompetencje	- Autodeterminacja	0,456	***	7876,616
Kompetencje	- Wpływ	0,559	***	1,614e+6
Autodeterminacja	- Wpływ	0,475	***	19259,292

* BF₁₀ > 10, ** BF₁₀ > 30, *** BF₁₀ > 100

Źródło: opracowanie własne w programie JASP 0.16, 2022

ekstremalnie mocne dowody na korzyść alternatywnej hipotezy (tj. związku między zmiennymi), co oznacza, że mamy wyraźny dowód na istnienie przeciętnej zależności zachodzącej między wszystkimi czterema wskaźnikami apofermentu w miejscu pracy. W odniesieniu do wcześniejszych rezultatów jest to o tyle istotne odkrycie, że daje badaczowi pewność, że zwiększenie się empowermentu w miejscu pracy po odbytych kursach w zakresie przetwarzania informacji wzrasta w powiązanych ze sobą aspektach, a nie niezależnie od siebie. W tym przykładzie przeciętnie jest od 13 431 do $1,614 \times 10^6$ razy bardziej prawdopodobne, że badane wskaźniki są ze sobą powiązane, niż że nie są. Na podstawie tego prawdopodobieństwa *a posteriori* możemy bardzo precyzyjnie określić, że dowód z danych jest wiele tysięcy razy bardziej prawdopodobny w zakresie hipotezy alternatywnej niż zerowej.

Podsumowanie

Różnica między statystyką częstościową a bayesowską jest wyraźna, gdy weźmiemy pod uwagę założenia *a priori*, które każdy badacz definiuje przed rozpoczęciem badania, kiedy określa jego cel i ugruntowuje go w analizie literatury. Statystyka częstościowa ma w tym zakresie zapewnić bezstronność analizy i potwierdzić, że istnieją bardzo niewielkie szanse na wystąpienie błędu statystycznego i fałszywego potwierdzenia lub negacji hipotezy zerowej (która nie jest równoznaczna z hipotezą badawczą) w odniesieniu do szerszej populacji zainteresowania, której dotyczy zoperacjonalizowany cel badania (Western, 1999). Jest to absolutnie zasadne podejście w praktyce opartej na faktach, w której bez pewności odnośnie do prawdziwości i braku stronniczości w dostarczonym dowodzie nie można podjąć działania, jak np. w medycynie. Inaczej jest jednak, gdy badacz lub analityk ma przedstawić rekomendacje dotyczące warunków pracy w wyniku samooceny pracowników, np. dotyczącej empowermentu w miejscu pracy, etyki w zachowaniach informacyjnych, kompetencji informacyjnych lub badań opinii klientów. W takiej sytuacji bezsprzeczny i niepodważalny dowód naukowy najczęściej nie jest możliwy do uzyskania, a rekomendacja musi powstać na podstawie niekompletnych danych i innych rodzajów projektów badawczych.

Statystyki bayesowskie opisane powyżej w skróconym, czysto prezentacyjnym wnioskowaniu przejawiają jedną szczególną wartość w procesie decyzyjnym w organizacji – pozwalają na wsparcie wnioskowania statystycznego obliczonym prawdopodobieństwem powodzenia działań, np. związanych z inwestowaniem w rozwój kompetencji pracowników. Przedstawiona analiza dostarczyła silnego dowodu na to, aby poprzeć rekomendację dotyczącą inwestycji w szkolenie rozwijające kompetencje informacyjne, które z dużym prawdopodobieństwem przełoży się na wyższy empowerment pracowniczy i efektywność pracy. W kontekście normatywnym natomiast, czysto hipotetycznie, tak interpretowane prawdopodobieństwo wystąpienia silnych zależności między zachowaniami informacyjnymi w kulturze informacji organizacji byłoby szczególnie istotne w procesie planowania polityki informacyjnej organizacji, np. „Mamy ponad 100 razy większe szanse na to, że jeżeli pracownicy będą zobligowani do samodzielnego poszukiwania informacji o klientach i kontrahentach, to będą także bardziej kreatywnie i skutecznie prowadzić negocjacje na podstawie samodzielnie opracowanych informacji, niż na to, że taka pozytywna zależność nie wystąpi”.

W szczególności jednak warto podkreślić niewątpliwą zaletę statystyk bayesowskich w pracy analityka danych lub analityka biznesowego. Obecnie wzrasta liczba badań weryfikująca pozytywnie użyteczność statystyk bayesowskich we wspieraniu decyzji. Jak zauważyli Insua et al. (2020), uwzględnienie założeń teoretycznych lub intuicji we wnioskowaniu statystycznym odnośnie do podejmowania decyzji jest z powodzeniem stosowane w różnych kontekstach, takich jak testy żywotności, projektowanie eksperymentów, certyfikacja niezawodności, ocena gwarancji itd. Od wielu lat jest to też element rozwijania praktyk opartych na faktach (Ashby & Smith, 2000). W nauce o informacji coraz większą wartość mają również eksperymenty kontrolowane, tj. testy A/B, które

w firmach stały się standardem podejmowania decyzji opartych na danych, bo dają możliwość taniej i szybkiej oceny nowych pomysłów w kampaniach internetowych lub testach *user experience*. Także w kontekście tego typu danych, istotnych dla analityków biznesowych wspierających decyzje w firmach, wnioskowanie bayesowskie zyskuje na wartości, bo prawdopodobieństwo bycia lepszym, efektywniejszym lub uzyskania wyższych zysków jest podstawą podejmowania skutecznych decyzji (Kamalbash & Eugster, 2021).

Rosnąca popularność analizy bayesowskiej nie dotyczy jednak badań w nauce o informacji, a w szczególności badań kultury informacyjnej. Dotychczasowe badania kultury informacyjnej trudno jest pozytywnie ocenić pod względem ich przydatności w praktyce zarządzania informacją, a ich quasi-eksperymentalne projekty nie sprzyjają włączaniu ich rezultatów do praktyk opartych na faktach. Jeżeli badacze dostarczają już ogólnorozumianych dowodów naukowych i wniosków statystycznych odnoszących się do kultury informacyjnej, to ich przełożenie na wsparcie decyzji jest niezwykle trudne, gdy weźmie się pod uwagę unikatowość kontekstu organizacyjnego obserwacji. Statystyki bayesowskie, dzięki łatwości ich zrozumienia i możliwości bezpośredniego przełożenia na proces decyzyjny, należy postrzegać jako potencjalne rozwiązanie tego problemu i nową drogę transferu rezultatów badań z tej dyscypliny do różnych obszarów społecznych.

Bibliografia

- Abrahamson, Douglas Edward; Goodman-Delahunty, Jane (2013). The impact of organizational information culture on information use outcomes in policing: an exploratory study. *Information Research*, vol. 18, no. 4, paper 598. <http://informationr.nect.ir/18-4/paper598.html#.Y1V8H3ZBY3A> (odczyt: 12.04.2022).
- Ashby, Deborah; Smith, Adrian F.M. (2000). Evidence-based medicine as Bayesian decision-making. *Statistics in Medicine*, vol. 19, issue 23, pp. 3291–3305.
- Batorowska, Hanna (2009). *Kultura informacyjna w perspektywie zmian w edukacji*. Warszawa: Wydaw. Stowarzyszenia Bibliotekarzy Polskich.
- Batorowska, Hanna (2013). *Od alfabetyzacji informacyjnej do kultury informacyjnej. Rozważania o dojrzałości informacyjnej*. Warszawa: Wydaw. Stowarzyszenia Bibliotekarzy Polskich.
- Bishop, Phillip A.; Herron, Robert L. (2015). Use and misuse of the Likert item responses and other ordinal measures. *International Journal of Exercise Science*, vol. 8, no. 3, pp. 297–302. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC4833473/> (odczyt: 12.04.2022).
- Choo, Chun Wei et al. (2006). Working with information: information management and culture in a professional services organization. *Journal of Information Science*, vol. 32, no. 6, pp. 491–510.

- Choo, Chun Wei; Bergeron, Pierrette; Detlor, Brian; Heaton, Lorna (2008). Information culture and information use: an exploratory study of three organizations. *Journal of the American Society for Information Science and Technology*, vol. 59, issue 5, pp. 792–804. doi:10.1002/asi.20797
- Cleveland, William S. (2001). Data science: an action plan for expanding the technical areas of the field of statistics. *International Statistical Review*, vol. 69, no. 1, pp. 21–26.
- Deja, Marek (2021). *Model diagnostyczny kultury informacyjnej instytucji szkolnictwa wyższego*. Kraków: Uniwersytet Jagielloński w Krakowie. Biblioteka Jagiellońska.
- Deja, Marek; Januszko-Szakiel, Aneta; Korycińska, Paloma; Deja, Paulina (2021). The impact of basic data literacy skills on work-related empowerment: the alumni perspective. *College & Research Libraries*, vol. 82, no. 5, pp. 708–729.
- Deja, Marek; Rak, Dorota (2019). Knowledge management and academic information behaviour: a preliminary study of metaliteracy among junior faculty staff in the digital environment. *Aslib Journal of Information Management*, vol. 71, no. 4, pp. 480–499.
- Deja, Marek; Wójcik, Magdalena (2021). Information culture and academic empowerment: developing a collective mindfulness strategy for embedded librarianship. *The Journal of Academic Librarianship*, vol. 47, issue 2, article 102276. doi:10.1016/j.acalib.2020.102276
- van Doorn, Johnny et al. (2021). The JASP guidelines for conducting and reporting a Bayesian analysis. *Psychonomic Bulletin & Review*, vol. 28, no. 3, pp. 813–826. doi:10.3758/s13423-020-01798-5.
- Gill, Jeff; Casella, George (2009). Nonparametric priors for ordinal Bayesian social science models: specification and estimation. *Journal of the American Statistical Association*, vol. 104, no. 486, pp. 453–454. doi:10.1198/jasa.2009.0039
- Good, Phillip I. (2006). Estimating population parameters. In: Phillip I. Good ed. *Resampling methods: a practical guide to data analysis*. Boston, MA: Birkhäuser, pp. 5–30. doi:10.1007/0-8176-4444-X_2.
- Goss-Sampson, Mark A. (2020). *Statistical analysis in JASP 0.14: a guide for students. JASP v 0.14*. London: University of Greenwich.
- Hill, Jennifer L.; Kriesi, Hanspeter (2001). Classification by opinion-changing behavior: a mixture model approach. *Political Analysis*, vol. 9, no. 4, pp. 301–324.
- Insua, David Rios; Ruggeri, Fabrizio; Soyer, Refik; Wilson, Simon (2020). Advances in Bayesian decision making in reliability. *European Journal of Operational Research*, vol. 282, issue 1, pp. 1–18. doi:10.1016/j.ejor.2019.03.018.
- Kamalbasha, Shafi; Eugster, Manuel J.A. (2021). Bayesian A/B testing for business decisions. In: Peter Haber et al. eds. *Data science – analytics and applications*. Wiesbaden: Springer Vieweg, pp. 50–57. doi:10.1007/978-3-658-32182-6_9.
- Kaplan, David (2014). *Bayesian statistics for the social sciences*. New York, London: Guilford Publications.
- Kerby, Dave S. (2014). The simple difference formula: an approach to teaching non-parametric correlation. *Comprehensive Psychology*, vol. 3, article 1. doi:10.2466/11.IT.3.1

- Kisilowska, Małgorzata (2016). *Kultura informacji*. Warszawa: Wydaw. Stowarzyszenia Bibliotekarzy Polskich.
- Lumley, Thomas; Diehr, Paula; Emerson, Scott; Chen, Lu (2002). The importance of the normality assumption in large public health data sets. *Annual Review of Public Health*, vol. 23, pp. 151–169. doi:10.1146/annurev.publhealth.23.100901.140546.
- Lupia, Arthur; Alter, George (2014). Data access and research transparency in the quantitative tradition. *PS: Political Science & Politics*, vol. 47, no. 1, pp. 54–59. doi:10.1017/S1049096513001728.
- Lynch, Scott M. (2007a). Basics of Bayesian statistics. In: Scott M. Lynch ed. *Introduction to Applied Bayesian Statistics and Estimation for Social Scientists*. New York: Springer, pp. 47–75. doi:10.1007/978-0-387-71265-9_3.
- Lynch, Scott M. (2007b). Probability theory and classical statistics. In: Scott M. Lynch ed. *Introduction to Applied Bayesian Statistics and Estimation for Social Scientists*. New York: Springer, pp. 9–45. doi:10.1007/978-0-387-71265-9_2
- Materska, Katarzyna (2007). *Informacja w organizacjach społeczeństwa wiedzy*. Warszawa: Wydaw. Stowarzyszenia Bibliotekarzy Polskich. <http://bbc.uw.edu.pl/dlibra/docmetadata?id=470&dirids=1&tab=2>
- Moher, David; Liberati, Alessandro; Tetzlaff, Jennifer; Altman, Douglas G. (2009). Preferred reporting items for systematic reviews and meta-analyses: the PRISMA statement. *PLOS Medicine*, vol. 6, no. 7, pp. 1–6. doi:10.1371/journal.pmed.1000097
- Morey, Richard D.; Rouder, Jeffrey N.; Pratte, Michael S.; Speckman, Paul L. (2011). Using MCMC chain outputs to efficiently estimate Bayes factors. *Journal of Mathematical Psychology*, vol. 55, issue 5, pp. 368–378. doi:10.1016/j.jmp.2011.06.004.
- Spreitzer, Gretchen M. (2007). Toward the integration of two perspectives: a review of social-structural and psychological empowerment at work. In: Cary Cooper; Julian Barling eds. *The handbook of organizational behavior*. Thousand Oaks, CA: Sage, pp. 54–72.
- Stamey, James; Sherr, Michael E.; Williams, Nathaniel J. (2011). Bayesian analysis for evidence-based practice in social work. *Social Work Research*, vol. 35, no. 1, pp. 46–52.
- Stroup, Donna F. et al. (2000). Meta-analysis of observational studies in epidemiology: a proposal for reporting. *JAMA*, vol. 283, no. 15, pp. 2008–2012. doi:10.1001/jama.283.15.2008
- Virkus, Sirje; Salman, Anmar (2021). Effective leadership behaviours and information culture in the higher education institution. *Global Knowledge, Memory, and Communication*, vol. 70, no. 4–5, pp. 418–441. doi:10.1108/GKMC-08-2020-0106
- Western, Bruce (1999). Bayesian analysis for sociologists: an introduction. *Sociological Methods & Research*, vol. 28, issue 1, pp. 7–34. doi:10.1177/0049124199028001002
- Ziemia, Zdzisław (1961). Racjonalna wiara i prawdopodobieństwo a zasadność wnioskowania indukcyjnego. *Studia Logica*, t. 12, nr 1, s. 99–120.
- Zych, Magdalena (2020). Education for business analysts in Poland. *Education for Information*, vol. 36, no. 4, pp. 347–370. doi:10.3233/EFI-200391