

Od analizy do strategii: jak sztuczna inteligencja przekształca klasyczną analizę SWOT

Alan Pajek

Uniwersytet Warszawski

e-mail: alan@pajek.info

ORCID: [0009-0007-3353-1771](https://orcid.org/0009-0007-3353-1771)

© 2026 Alan Pajek

Praca opublikowana na licencji Creative Commons Uznanie autorstwa-Na tych samych warunkach 4.0 Międzynarodowe (CC BY-SA 4.0). Skrócona treść licencji dostępna jest online na <https://creativecommons.org/licenses/by-sa/4.0/deed.pl>

Cytuj jako: Pajek, A. (2026). Od analizy do strategii: jak sztuczna inteligencja przekształca klasyczną analizę SWOT. *Prace Naukowe Uniwersytetu Ekonomicznego we Wrocławiu*, 70(1), 11-25.

DOI: [10.15611/pn.2026.1.02](https://doi.org/10.15611/pn.2026.1.02)

JEL: M10, M15, D81

Streszczenie

Cel: Empiryczne opisanie, jak użytkownicy aplikacji SWOTmaker przechodzą przez etapy analizy SWOT/TOWS wspomaganej agentami AI, oraz operacjonalizacja i opis stopnia domknięcia procesu (rozumianego jako przejście przez kolejne etapy E1-E4) na podstawie danych telemetrycznych.

Metodyka: Badanie eksploracyjne na danych telemetrycznych z rzeczywistego użycia (2022-2025); statystyka opisowa i segmentacja zachowań (X – koniec na E2, Y – na E3, Z – pełny cykl E1-E4).

Wyniki: Dominującym punktem domknięcia jest E3 (strategie TOWS), a tylko część sesji dochodzi do E4 (rekomendacje działań). Przeważają strategie SO, a większość użytkowników akceptuje propozycje AI bez modyfikacji.

Implikacje i rekomendacje: Wyniki sugerują potrzebę projektowania interfejsów AI-SWOT z mechanizmami ograniczającymi zakotwiczenie i automatyczne domykanie (np. prezentacja kontratypów) oraz wprowadzenia „popychaczy” E3→E4 wspierających operacjonalizację strategii. Segmentacja X-Y-Z może służyć jako prosty wskaźnik domknięcia procesu w narzędziu oraz punkt wyjścia do dalszych badań nad jakością interakcji *human-in-the-loop* (HITL), w tym walidacji z użyciem metod jakościowych lub oceny eksperckiej.

Oryginalność/wartość: Artykuł dostarcza pierwszej w literaturze empirycznej analizy rzeczywistych zachowań użytkowników systemu TOWS opartego na generatywnej sztucznej inteligencji. Wprowadza

nową metrykę domknięcia procesu (segmentacja X–Y–Z) oraz pokazuje, jak AI przekształca klasyczny model SWOT w dynamiczny, interaktywny proces poznawczy.

Słowa kluczowe: SWOT, TOWS, sztuczna inteligencja, *human-in-the-loop* (HITL), analiza telemetryczna, systemy wspomagania decyzji, AI-SWOT

1. Wstęp

Analiza SWOT od dekad pozostaje jednym z najczęściej stosowanych narzędzi diagnozy strategicznej, cenionym za prostotę, elastyczność oraz zdolność do porządkowania czynników wewnętrznych i zewnętrznych organizacji (Helms i Nixon, 2010; Pickton i Wright, 1998). Pomimo swojej popularności narzędzie to bywa w praktyce wykorzystywane w sposób uproszczony – jako statyczna macierz czterech pól – bez konsekwentnego przełożenia diagnozy na wybór i operacjonalizację strategii. W literaturze wielokrotnie wskazywano na subiektywizm doboru czynników, brak ich priorytetyzacji oraz trudność domknięcia procesu decyzyjnego jako kluczowe ograniczenia klasycznej SWOT (Helms i Nixon, 2010; Hill i Westbrook, 1997).

W odpowiedzi na te słabości rozwijano różne modyfikacje metody, w tym macierz TOWS, której celem było systematyczne łączenie czynników SWOT w cztery typy strategii (SO, ST, WO, WT) (Wehrich, 1982), a także podejścia hybrydowe integrujące SWOT z metodami wielokryterialnymi, takimi jak AHP czy A'WOT (Kajanus i in., 2012; Krwawicz, 2019; Kurttila i in., 2000). Pomimo wzrostu rygoru analitycznego rozwiązania te pozostają w praktyce stosowane sporadycznie, głównie ze względu na złożoność metodologiczną oraz ograniczoną dostępność narzędzi (Ghazinoory i in., 2011; Helms i Nixon, 2010), przez co SWOT nadal funkcjonuje częściej jako narzędzie diagnostyczne niż jako element spójnego procesu decyzyjnego.

Postęp w obszarze sztucznej inteligencji, a w szczególności rozwój generatywnych modeli językowych, stworzył nowe możliwości wsparcia analizy strategicznej. Systemy te potrafią przetwarzać język naturalny, syntetyzować złożone opisy kontekstu, generować warianty strategii oraz wspierać formułowanie rekomendacji działań (Doshi i in., 2025; Mesko, 2023). Współczesne ramy odpowiedzialnego wykorzystania AI podkreślają jednak konieczność projektowania takich rozwiązań w modelu *human-in-the-loop*, w których człowiek zachowuje kontrolę interpretacyjną i decyzyjną, a sztuczna inteligencja pełni rolę poznawczego partnera, a nie autonomicznego decydenta (Amershi i in., 2019; NIST, 2023).

Punktem wyjścia niniejszego badania jest obserwacja, że analiza SWOT – pomimo swojej długiej historii – w praktyce menedżerskiej często nie prowadzi do domknięcia procesu decyzyjnego, redukując się do etapu diagnozy bez przełożenia na konkretne kierunki działania (Hill i Westbrook, 1997; Puyt i in., 2023). W tym kontekście rozwiązania oparte na sztucznej inteligencji mogą pełnić rolę narzędzi procesowych, które ułatwiają przejście między etapami analizy (od identyfikacji czynników po syntezę strategii i rekomendacje działań), przy zachowaniu zasady *human-in-the-loop* (Gomez i in., 2024). Z perspektywy empirycznej kluczowe stają się jednak nie tyle deklarowane „możliwości” AI, ile pytania: jak użytkownicy faktycznie korzystają z takiego wsparcia i na jakich etapach domykają pracę z narzędziem.

Celem artykułu jest empiryczna charakterystyka sposobu, w jaki użytkownicy aplikacji SWOTmaker przechodzą przez kolejne etapy analizy SWOT/TOWS wspomaganej przez agentów sztucznej inteligencji, oraz opis stopnia domknięcia procesu w sensie behawioralnym (tj. na podstawie przejść i zatrzymań w etapach E1–E4). Badanie opiera się na analizie danych telemetrycznych z rzeczywistego użycia aplikacji w latach 2022–2025 i ma charakter eksploracyjny. Wkład artykułu obejmuje: (1) empiryczny opis interakcji *human-in-the-loop* w analizie SWOT/TOWS, (2) propozycję segmentacji zachowań użytkowników (X–Y–Z) jako miernika domknięcia procesu oraz (3) charakterystykę wzorców strategii generowanych w środowisku AI-SWOT. Zakres wnioskowania nie obejmuje bezpośredniej oceny satysfakcji użytkowników ani jakości strategii w ujęciu rezultatów biznesowych, co może stanowić kierunek dalszych badań.

2. Przegląd literatury

2.1. Geneza i rozwój analizy SWOT i TOWS

Analiza SWOT (*Strengths, Weaknesses, Opportunities, Threats*) jest jednym z najpowszechniej stosowanych narzędzi analizy strategicznej, choć przez długi czas jej geneza pozostawała w literaturze niejednoznaczna (Szmitka, 2015). Wczesne publikacje koncentrowały się głównie na zastosowaniach praktycznych, a krytyka metody dotyczyła przede wszystkim jej uproszczonego charakteru oraz braku rygoru analitycznego (Helms i Nixon, 2010; Hill i Westbrook, 1997). Dopiero nowsze badania archiwalne pozwoliły precyzyjniej zrekonstruować historyczne źródła SWOT i pierwotne intencje jej twórców.

Jak pokazuje praca Puyta i in. (2023), SWOT wywodzi się z partycypacyjnych praktyk planowania strategicznego rozwijanych w Stanach Zjednoczonych w latach 50. i 60. XX wieku, początkowo w środowisku przemysłowym, a następnie w Stanford Research Institute. Pierwotną formą narzędzia była metoda SOFT (*Satisfactory, Opportunity, Fault, Threat*), zaprojektowana jako sposób systematycznego zbierania i porządkowania problemów oraz szans identyfikowanych przez menedżerów na różnych poziomach organizacji. Jej celem nie było jedynie stworzenie macierzy diagnostycznej, lecz wsparcie procesu zbiorowego myślenia strategicznego i przełożenie diagnozy na decyzje planistyczne.

W kolejnych latach metoda SOFT ewoluowała w kierunku SWOT, dostosowując język opisu do rozwijającego się dyskursu zarządzania strategicznego (Learned i in., 1969; Stewart, 1963). Zmiana terminologii ułatwiła popularyzację narzędzia, lecz jednocześnie sprzyjała jego uproszczeniu – SWOT stopniowo traciła charakter procesowy, stając się statyczną macierzą 2x2, wykorzystywaną głównie jako narzędzie porządkowania informacji (Hill i Westbrook, 1997).

Istotnym krokiem w kierunku przywrócenia aplikacyjnego wymiaru metody była koncepcja TOWS zaproponowana przez Weihricha (1982). Macierz TOWS umożliwia systematyczne łączenie czynników wewnętrznych i zewnętrznych w cztery klasy strategii: agresywną (SO), konserwatywną (ST), konkurencyjną (WO) oraz defensywną (WT). Autor określał TOWS jako narzędzie „mostowe” pomiędzy diagnozą a wyborem strategii, co podkreślało jej rolę w domykaniu procesu myślenia strategicznego. Koncepcja ta była rozwijana i doprecyzowywana w kolejnych pracach (Dyson, 2004; Panagiotou, 2003; Sprague, 1980).

W odpowiedzi na krytykę klasycznej SWOT/TOWS w literaturze pojawiły się także podejścia hybrydowe, integrujące macierz SWOT z metodami wielokryterialnymi, w szczególności *Analytic Hierarchy Process* (AHP) oraz jego odmianą A'WOT (Kajanus i in., 2012; Kurttila i in., 2000). Celem tych rozwiązań było nadanie wag czynnikom SWOT oraz zwiększenie spójności procesu decyzyjnego. Pomimo wzrostu rygoru analitycznego metody te pozostają stosowane głównie w badaniach akademickich i studiach przypadku, a ich praktyczna adopcja jest ograniczona ze względu na złożoność oraz wymagania kompetencyjne wobec użytkowników (Ghazinoory i in., 2011; Helms i Nixon, 2010).

Z perspektywy historycznej analiza SWOT nie była pierwotnie projektowana jako jednorazowe ćwiczenie diagnostyczne, lecz jako element szerszego, iteracyjnego procesu planowania, łączącego diagnozę, refleksję i decyzję (Puyt i in., 2023). W tym świetle współczesne próby cyfryzacji i automatyzacji analizy SWOT/TOWS – w tym z wykorzystaniem sztucznej inteligencji – można interpretować nie jako odejście od oryginalnych założeń metody, lecz jako próbę ich ponownej realizacji w warunkach współczesnych systemów informacyjnych i decyzyjnych.

2.2. Krytyka i ograniczenia klasycznej analizy SWOT/TOWS w świetle rozwoju technologii

Krytyka analizy SWOT i jej rozszerzenia TOWS w literaturze koncentruje się przede wszystkim na poznawczym i strukturalnym charakterze metody. Autorzy wskazują, że w klasycznej postaci SWOT opiera się na heurystycznym doborze czynników, bazującym głównie na pamięci, intuicji i subiektywnych

ocenach uczestników warsztatu strategicznego (Helms i Nixon, 2010; Hill i Westbrook, 1997). Taki sposób pracy sprzyja stronniczości poznawczej, myśleniu grupowemu oraz nadreprezentacji problemów łatwo dostępnych poznawczo, kosztem czynników mniej oczywistych, lecz strategicznie istotnych.

Kolejnym istotnym ograniczeniem jest brak wbudowanych mechanizmów nadawania wag oraz modelowania relacji między czynnikami SWOT. Klasyczna macierz traktuje wszystkie elementy jako równoważne, co utrudnia przejście od opisu do wyboru strategii i powoduje, że proces wnioskowania pozostaje w dużej mierze nieformalny (Ghazinoory i in., 2011; Helms i Nixon, 2010). Nawet w przypadku zastosowania macierzy TOWS, która systematyzuje łączenie czynników w cztery typy strategii, końcowa interpretacja wyników zależy w znacznym stopniu od doświadczenia i kompetencji analitycznych użytkowników.

W literaturze podkreśla się również ręczny charakter wnioskowania jako barierę powtarzalności i porównywalności wyników analiz SWOT/TOWS. Przy tym samym zestawie danych wejściowych różni analitycy mogą formułować odmienne rekomendacje strategiczne, co ogranicza możliwość traktowania SWOT jako narzędzia wspomagania decyzji w sensie systemowym (Ghazinoory i in., 2011; Hill i Westbrook, 1997). Próby redukcji tych ograniczeń podejmowane były poprzez integrację SWOT z metodami wielokryterialnymi, takimi jak *Analytic Hierarchy Process*, jednak rozwiązania te zwiększały złożoność analizy i pozostawały trudne do wdrożenia w praktyce menedżerskiej (Kajanus i in., 2012; Kurttila i in., 2000).

Rozwój technologii informacyjnych umożliwił częściowe przezwyciężenie wskazanych barier poprzez wykorzystanie systemów *Business Intelligence* oraz *Decision Support Systems* (Dziembek i Ziora, 2023), które pozwalają na agregację danych, wstępną priorytetyzację czynników oraz symulację scenariuszy decyzyjnych. Narzędzia te zwiększają obiektywność danych wejściowych, lecz nie eliminują potrzeby poznawczej interpretacji i syntezy informacji po stronie użytkownika, która w dalszym ciągu pozostaje kluczowym elementem procesu strategicznego.

Oprócz ograniczeń strukturalnych literatura wskazuje na procesowe i organizacyjne bariery skutecznego wykorzystania analizy SWOT/TOWS. Klasyczne zastosowanie tej metody ma często charakter jednorazowego ćwiczenia warsztatowego, które nie jest systematycznie integrowane z dalszymi etapami zarządzania strategicznego (wdrażanie, monitoring, kontrola), a dodatkowo przebieg rozumowania i rozważane alternatywy nie są zwykle rejestrowane w sposób umożliwiający powrót do odrzuconych wariantów i uczenie się organizacji (Ghazinoory i in., 2011; Helms i Nixon, 2010).

W odpowiedzi na te ograniczenia proponowano integrację SWOT z innymi koncepcjami zarządzania strategicznego, w tym z *Balanced Scorecard*, co miało umożliwić powiązanie diagnozy strategicznej z celami, miernikami i systemem kontroli (Kaplan i Norton, 2001). Rozwiązania te zwiększają spójność procesu zarządzania, lecz nadal wymagają wysokiego poziomu dyscypliny metodologicznej i nie rozwiązują problemu ograniczonej operacjonalizacji strategii w praktyce decyzyjnej.

Z perspektywy rozwoju technologii wskazane bariery tworzą przestrzeń dla rozwiązań cyfrowych, które wspierają nie tylko analizę danych, lecz także strukturę i ciągłość procesu decyzyjnego. Szczególne znaczenie zyskują systemy umożliwiające rejestrację interakcji użytkownika, śledzenie ścieżki decyzyjnej oraz iteracyjne powracanie do wcześniejszych etapów analizy. W tym kontekście pojawia się potencjał zastosowań sztucznej inteligencji, która może wspierać zarówno poznawczy, jak i procesowy wymiar analizy SWOT/TOWS, zachowując przy tym rolę człowieka jako ostatecznego decydenta.

2.3. AI w analizie strategicznej: od automatyzacji do współpracy HITL

Dynamiczny rozwój sztucznej inteligencji w ostatnich latach istotnie wpłynął na sposób projektowania systemów wspomagania decyzji w zarządzaniu. Szczególną rolę odegrały generatywne modele językowe (LLM), zdolne do przetwarzania i generowania tekstu w języku naturalnym, co umożliwiło ich

zastosowanie w zadaniach wymagających interpretacji kontekstu, syntezy informacji oraz formułowania wariantów decyzyjnych (Doshi i in., 2025; Mesko, 2023). W odróżnieniu od klasycznych systemów *Business Intelligence* i *Decision Support Systems*, modele te operują bezpośrednio na języku, który stanowi podstawowy nośnik wiedzy strategicznej w organizacjach.

Zastosowanie LLM w analizie strategicznej otwiera możliwość częściowej automatyzacji wybranych czynności poznawczych, takich jak identyfikacja kluczowych czynników otoczenia, porządkowanie informacji czy generowanie wariantów strategii. Jednocześnie literatura podkreśla, że systemy te nie powinny być projektowane jako autonomiczni decydenci, lecz jako narzędzia wspierające proces myślenia strategicznego człowieka (Amershi i in., 2019). Klasyczne badania nad automatyzacją wskazują, że użytkownicy mogą zarówno nadmiernie polegać na rekomendacjach systemu (*misuse/abuse*), jak i unikać jego użycia po doświadczeniu błędu (*disuse*), co uzasadnia projektowanie mechanizmów kalibracji zaufania i utrzymania aktywnej roli człowieka (Parasuraman i Riley, 1997). Ryzyka związane z halucynacjami modeli, brakiem transparentności oraz podatnością na artefakty danych treningowych wymagają zachowania kontroli interpretacyjnej po stronie użytkownika. Problem halucynacji w generowaniu języka naturalnego jest szeroko opisywany jako istotne ryzyko w zastosowaniach decyzyjnych, ponieważ wiarygodnie brzmiące treści mogą być niezgodne z faktami i prowadzić do błędnych przesłanek analizy (Ji i in., 2023).

W tym kontekście ugruntowała się koncepcja *human-in-the-loop* (HITL), zgodnie z którą człowiek pozostaje integralnym elementem systemu decyzyjnego, nadzorując, korygując i zatwierdzając wyniki generowane przez algorytmy (Amershi i in., 2019). Ramy odpowiedzialnego wykorzystania AI, takie jak *NIST AI Risk Management Framework* (NIST, 2023) oraz jego profil dla generatywnej AI, podkreślają konieczność zapewnienia przejrzystości, rozliczalności i możliwości ingerencji użytkownika na każdym etapie cyklu życia systemu. Współpraca człowieka i AI powinna być zatem postrzegana jako partnerstwo poznawcze, w którym system rozszerza zdolności analityczne użytkownika, nie zastępując jego odpowiedzialności decyzyjnej.

W analizie SWOT/TOWS modele językowe mogą wspierać kolejne etapy procesu decyzyjnego: od interpretacji opisu kontekstu i generowania wstępnych list czynników SWOT, poprzez syntezę tych czynników w strategię TOWS, aż po formułowanie rekomendacji działań. Kluczowe znaczenie ma jednak sposób integracji AI z procesem – system powinien umożliwiać użytkownikowi wgląd w logikę generowanych propozycji, ich modyfikację oraz świadome podjęcie decyzji o dalszym przebiegu analizy. Tak zaprojektowane rozwiązania odpowiadają pierwotnej idei SWOT jako procesu prowadzącego od diagnozy do strategii, a nie jedynie statycznej macierzy analitycznej.

Rozwój koncepcji architektury agentowej stanowi dodatkowy krok w kierunku strukturyzacji współpracy człowieka z AI. Podział systemu na wyspecjalizowane moduły lub agentów, odpowiadających za poszczególne etapy analizy (np. interpretację kontekstu, analizę czynników, syntezę strategii), pozwala lepiej odwzorować sekwencyjny charakter procesu decyzyjnego oraz ograniczyć ryzyko nadmiernej automatyzacji. W takim ujęciu użytkownik pełni rolę moderatora i decydenta, natomiast agenci AI realizują wybrane zadania analityczne w ramach jasno zdefiniowanego przepływu.

Z perspektywy badań nad zarządzaniem strategicznym kluczowym wyzwaniem pozostaje empiryczna ocena, w jaki sposób użytkownicy faktycznie korzystają z rozwiązań AI-SWOT oraz na ile wspierają one domknięcie procesu decyzyjnego. Dotychczasowe prace koncentrowały się głównie na koncepcjach i studiach przypadków, natomiast brakuje analiz opartych na rzeczywistych danych behawioralnych użytkowników systemów wspomaganych AI. Luka ta stanowi bezpośredni punkt wyjścia dla niniejszego badania.

2.4. Luka badawcza i pytanie badawcze

Dotychczasowe badania nad analizą SWOT i jej rozszerzeniem TOWS koncentrowały się przede wszystkim na aspektach metodycznych, takich jak konstrukcja macierzy, sposoby priorytetyzacji czynników oraz integracja z metodami wielokryterialnymi. Równolegle w literaturze zarządzania

strategicznego rozwijane są koncepcje wykorzystania sztucznej inteligencji i systemów opartych na modelach generatywnych jako narzędzi wspierających analizę i podejmowanie decyzji. Prace te mają jednak w przeważającej mierze charakter konceptualny, przeglądowy lub studialny i rzadko opierają się na empirycznej obserwacji rzeczywistego przebiegu procesu decyzyjnego użytkowników (Amershi i in., 2019; Ghazinoory i in., 2011; Helms i Nixon, 2010).

W szczególności brakuje badań ilościowych opisujących, w jaki sposób użytkownicy faktycznie korzystają z narzędzi analizy SWOT/TOWS wspomaganych sztuczną inteligencją w warunkach rzeczywistego użycia. Literatura nie dostarcza odpowiedzi na pytania dotyczące tego, na których etapach procesu decyzyjnego użytkownicy kończą analizę, jakie są czasy przejść pomiędzy kolejnymi fazami, w jakim stopniu akceptują oni rekomendacje generowane przez AI, a w jakim je modyfikują lub pomijają. Luka ta dotyczy zatem nie projektowanych funkcjonalności systemów AI-SWOT, lecz faktycznych zachowań użytkowników w modelu *human-in-the-loop* oraz stopnia domknięcia procesu decyzyjnego w praktyce.

Brak empirycznej wiedzy na temat rzeczywistego przebiegu interakcji człowieka z systemami AI wspierającymi analizę strategiczną utrudnia projektowanie i ocenę przebiegu procesu korzystania z narzędzi oraz identyfikację etapów wymagających wsparcia interfejsowego. Bez danych dotyczących faktycznego wykorzystania poszczególnych funkcji niemożliwe jest określenie, które elementy procesu wspierane przez AI rzeczywiście ułatwiają przejście od diagnozy do strategii, a które stanowią bariery wymagające interwencji projektowej. Z tego względu analiza danych telemetrycznych, rejestrujących ścieżki interakcji użytkowników z systemem w warunkach produkcyjnych, stanowi uzasadnione podejście badawcze umożliwiające wypełnienie zidentyfikowanej luki.

W tym kontekście zasadnicze pytanie badawcze niniejszego artykułu brzmi: **jak użytkownicy aplikacji SWOTmaker przechodzą przez kolejne funkcjonalności odzwierciedlające etapy analizy SWOT przy wsparciu agentów sztucznej inteligencji?** Pytanie to zostało uszczegółowione poprzez następujące zagadnienia badawcze: (a) ile czasu zajmuje użytkownikom przechodzenie pomiędzy kolejnymi etapami procesu (E1–E4), (b) jakie typy strategii TOWS (SO, ST, WO, WT) są najczęściej generowane na etapie syntezy strategicznej, (c) w jakim zakresie użytkownicy korzystają z funkcji opartych na sztucznej inteligencji w porównaniu do działań manualnych oraz (d) który etap procesu najczęściej stanowi punkt domknięcia korzystania z aplikacji SWOTmaker. W niniejszym ujęciu „wsparcie przejścia od diagnozy do strategii” jest mierzone pośrednio poprzez zachowania w aplikacji (przejścia E1→E4), a nie poprzez deklaracje użytkowników lub ocenę jakości decyzji.

3. Metodyka (badań własnych)

3.1. Projekt badania i źródła danych

Badanie ma charakter eksploracyjny i opiera się na analizie danych telemetrycznych pochodzących z rzeczywistego użycia aplikacji SWOTmaker, wspierającej analizę SWOT/TOWS z wykorzystaniem agentów sztucznej inteligencji. Zastosowanie danych telemetrycznych umożliwia obserwację faktycznych zachowań użytkowników w naturalnym środowisku pracy, bez ingerencji badacza w przebieg procesu decyzyjnego. Badanie obejmuje okres od 2022 do 2025 roku i dotyczy użytkowników korzystających z aplikacji w warunkach produkcyjnych.

SWOTmaker jest aplikacją webową zaprojektowaną jako system wspomagania analizy strategicznej w modelu *human-in-the-loop*. Narzędzie umożliwia użytkownikom przechodzenie przez kolejne etapy analizy SWOT, począwszy od opisu kontekstu i identyfikacji czynników, poprzez ich syntezę w strategię TOWS, a skończywszy na formułowaniu rekomendacji działań. Interakcje użytkowników z aplikacją są rejestrowane w postaci zdarzeń telemetrycznych, obejmujących m.in. czas trwania poszczególnych etapów, przejścia pomiędzy funkcjonalnościami oraz zakres wykorzystania komponentów opartych na sztucznej inteligencji.

Zbiór danych obejmuje zapisy sesji użytkowników, przy czym pojedyncza sesja odpowiada ciągowi interakcji prowadzących od rozpoczęcia analizy do jej zakończenia lub przerwania. Dane zostały poddane anonimizacji i agregacji w sposób uniemożliwiający identyfikację użytkowników. Ze względu na eksploracyjny charakter badania nie formułowano hipotez statystycznych, koncentrując się na opisowej analizie wzorców zachowań i przebiegu procesu decyzyjnego.

3.2. Procedura badawcza i etapy analizy

Procedura badawcza została oparta na sekwencyjnym modelu analizy SWOT/TOWS, odzwierciedlonym w architekturze aplikacji SWOTmaker. Proces analizy podzielono na cztery etapy funkcjonalne (E1–E4), odpowiadające kolejnym fazom pracy użytkownika z narzędziem.

Etap E1 obejmuje opis kontekstu organizacyjnego oraz identyfikację czynników SWOT, przy wsparciu agentów AI generujących wstępne propozycje na podstawie danych wejściowych dostarczonych przez użytkownika. Etap E2 polega na porządkowaniu i selekcji czynników, w tym ich modyfikacji, uzupełnianiu lub odrzucaniu przez użytkownika. W etapie E3 następuje synteza czynników w strategię TOWS, generowane przez system jako zestawy wariantów strategicznych. Etap E4 dotyczy wyboru i doprecyzowania rekomendowanych kierunków działania, stanowiąc potencjalny punkt domknięcia procesu decyzyjnego.

Na podstawie danych telemetrycznych użytkowników sklasyfikowano według miejsca zakończenia procesu analizy, wyróżniając trzy segmenty zachowań: X – użytkownicy kończący analizę na etapie identyfikacji czynników (E1–E2), Y – użytkownicy przechodzący do syntezy strategicznej (E3) oraz Z – użytkownicy domykający proces na etapie rekomendacji działań (E4). Segmentacja ta stanowi operacjonalizację stopnia domknięcia procesu decyzyjnego w analizie SWOT/TOWS wspomaganą przez AI.

3.3. Metody analizy danych

Analiza danych miała charakter ilościowo-opisowy i koncentrowała się na identyfikacji wzorców zachowań użytkowników w kolejnych etapach procesu analizy SWOT/TOWS. Podstawowymi miarami były czas trwania poszczególnych etapów (E1–E4), liczba przejść pomiędzy etapami oraz częstość wykorzystania funkcji opartych na sztucznej inteligencji w porównaniu do działań manualnych użytkownika.

Dla każdej sesji obliczono czasy trwania etapów oraz moment zakończenia analizy, co umożliwiło przypisanie użytkowników do segmentów X, Y lub Z. Dodatkowo analizowano rozkład typów strategii TOWS (SO, ST, WO, WT) generowanych na etapie syntezy strategicznej. Ze względu na eksploracyjny charakter badania wyniki prezentowane są w postaci statystyk opisowych oraz zestawień porównawczych, bez wnioskowania statystycznego.

3.4. Ograniczenia metody telemetrycznej i trafność wnioskowania

Dane telemetryczne pozwalają obserwować przebieg procesu analizy w warunkach rzeczywistego użycia, jednak mają istotne ograniczenia interpretacyjne. Rejestrują one zachowania (np. przejścia między etapami, czas, zakres edycji), lecz nie ujawniają bezpośrednio intencji użytkownika ani przyczyn przerwania sesji. Zatrzymanie na etapie E2 lub E3 może oznaczać zarówno zadowolenie z uzyskanego wyniku, jak i brak akceptacji treści, potrzebę dodatkowych danych, ograniczenia czasowe czy przerwanie zadania z powodów niezwiązanych z narzędziem.


Z tego względu wyniki należy interpretować jako opis behawioralnych wzorców domknięcia procesu w aplikacji, a nie jako miarę satysfakcji, użyteczności w sensie deklaratywnym ani jakości strategii w ujęciu *outcome*. Ograniczenie to stanowi przesłankę do dalszych badań łączących telemetrię z metodami jakościowymi (wywiady/ankiety) lub oceną ekspercką wytworzonych strategii, zgodnie z rekomendacjami literatury *human-in-the-loop* i *AI Risk Management*.

4. Rezultaty badań

4.1. Charakterystyka aktywności użytkowników

Badanie oparto na danych telemetrycznych pochodzących z rzeczywistego wykorzystania aplikacji SWOTmaker, będącej narzędziem wspomagającym analizę SWOT/TOWS w modelu współpracy człowieka z wyspecjalizowanymi agentami sztucznej inteligencji. Architektura systemu odzwierciedla sekwencyjny przebieg procesu decyzyjnego, obejmującego cztery etapy funkcjonalne (E1–E4), od identyfikacji kontekstu po formułowanie rekomendacji działań.

Etap **E1** obejmuje opis kontekstu decyzyjnego inicjowany przez użytkownika i wspierany przez agenta *Researcher*, generującego wstępną listę czynników SWOT. W etapie **E2** użytkownik analizuje i selekcjonuje czynniki SWOT przy wsparciu agenta *Analityka*, co prowadzi do wyznaczenia wariantów strategii TOWS. Etap **E3** polega na zapoznaniu się z wygenerowaną strategią, natomiast w etapie **E4**, realizowanym z udziałem agenta *Stratega*, formułowane są rekomendacje działań odpowiadające danemu kontekstowi i typowi strategii (rys. 1). Tak zdefiniowany przepływ obejmuje pełny cykl współpracy człowieka z systemem AI – od diagnozy problemu do planowania działań.



Rys. 1. Model współpracy użytkownika z agentem SWOTmaker (schemat przepływu działań użytkownika i AI w czterech etapach E1–E4)

Źródło: opracowanie własne.

W analizowanym okresie badawczym (12.06.2022-30.10.2025) z aplikacji SWOTmaker skorzystało 236 unikalnych użytkowników, którzy zrealizowali łącznie 315 sesji analitycznych (tab. 1). Stosunek liczby sesji do liczby użytkowników przekraczający 1 wskazuje, że część osób korzystała z aplikacji wielokrotnie, realizując analizy dla różnych kontekstów decyzyjnych.

Tabela 1. Statystyka sesji użytkowników

Statystyka		
liczba użytkowników	236	
liczba wszystkich sesji (analiz SWOT)	315	
start badania	12.06.2022	
koniec badania	30.10.2025	
dni	1236	udział
użytkownicy, którzy zrobili 1 analizę	209	89%
użytkownicy, którzy zrobili więcej niż 1 analizę	27	11%

Źródło: opracowanie własne na podstawie danych telemetrycznych SWOTmaker.

Dane telemetryczne obejmują informacje dotyczące czasu trwania sesji oraz przejść użytkowników pomiędzy kolejnymi etapami procesu (E1–E4), co umożliwia identyfikację zarówno częstotliwości

wykorzystania poszczególnych funkcji systemu, jak i momentów zakończenia pracy z aplikacją. Analiza aktywności użytkowników (tab. 2) wskazuje, że większość sesji przebiega sekwencyjnie od etapu identyfikacji kontekstu i czynników SWOT, przy czym istotna część analiz kończy się na etapach E1–E2. Jednocześnie wyodrębnia się grupa użytkowników przechodzących pełny cykl analizy aż do etapu rekomendacji działań (E4), co pozwala odróżnić skrócone ścieżki wykorzystania aplikacji od pełnych procesów decyzyjnych.

Tabela 2. Aktywność użytkowników i liczba sesji

	Liczba	Udział		E1	E2	E3	E4
Etap E1 – opis kontekstu	315	100%					
– sesje, w których wprowadzono kontekst dla AI	273	87%	E1	(n = 315) E1 →	75%	51%	23%
– sesje, w których rekordy wprowadzone były manualnie	42	13%					
Etap E2 – burza mózgów	236	75%					
– sesje z ingerencją użytkownika w rekordy AI	40	17%	E2	(n = 236) E2 →		69%	30%
– sesje bez ingerencji użytkownika	196	83%					
etap E3 – przeliczenie strategii dla sesji	162	51%					
<i>aggressive strategy</i>	90	56%	E3			(n = 162) E3 →	44%
<i>conservative strategy</i>	14	9%					
<i>competitive strategy</i>	12	7%					
<i>defensive strategy</i>	22	14%					
<i>not defined</i>	24	15%					
Etap E4 – rekomendacja	71	23%	E4				=

Źródło: opracowanie własne na podstawie danych telemetrycznych SWOTmaker.

Zgromadzone dane telemetryczne stanowią podstawę do dalszej analizy wzorców zachowań użytkowników w odniesieniu do pytań badawczych, umożliwiając ilościową ocenę czasu trwania poszczególnych etapów, częstotliwości przejść pomiędzy nimi oraz punktów domknięcia procesu analizy SWOT wspomaganej przez sztuczną inteligencję.

4.2. Przebieg procesu decyzyjnego i punkty zatrzymania

Analiza danych telemetrycznych umożliwia identyfikację etapów procesu analizy SWOT/TOWS, na których użytkownicy najczęściej kończą swoje sesje. Choć niemal wszyscy użytkownicy inicjują pracę od etapu E1 (opis kontekstu), wraz z przechodzeniem do kolejnych etapów obserwowany jest systematyczny spadek liczby aktywnych sesji, szczególnie wyraźny po zakończeniu etapu E2, obejmującego analizę czynników SWOT.

Tabela 3. Segmentacja sesji użytkowników według etapu zakończenia procesu

Segmentacja sesji użytkowników					
Grupa	Liczba sesji (n)	Udział (%)	Opis zachowania		Etap zakończenia procesu
Grupa X	74	23%	Użytkownicy, którzy zakończyli proces na etapie E2 („burza mózgów”), nie przechodząc do generacji strategii		E2
Grupa Y	91	29%	Użytkownicy, którzy ukończyli etap przeliczenia strategii (E3), ale nie przeszli do etapu rekomendacji działań (E4)		E3
Grupa Z	71	23%	Najbardziej zaawansowani użytkownicy, otrzymują i przeglądają rekomendacje AI, kończąc proces w pełnym cyklu <i>human–AI loop</i>		E4
Grupa 0	79	25%	Użytkownicy, którzy nie dotarli do burzy mózgów		E1
Suma:	315	100%			

Źródło: opracowanie własne na podstawie danych telemetrycznych SWOTmaker.

Na podstawie logów systemowych wyodrębniono trzy segmenty sesji użytkowników, zróżnicowane według etapu zakończenia procesu, z pominięciem sesji kończących się na etapie E1. **Segment X** obejmuje użytkowników, którzy zakończyli pracę po etapie E2 ($n = 74$, ok. 23%), wykorzystując aplikację głównie do uporządkowania czynników SWOT bez przechodzenia do syntezy strategicznej. **Segment Y** stanowią użytkownicy kończący analizę na etapie E3 ($n = 91$, ok. 29%), dla których wygenerowanie strategii TOWS stanowi wystarczający rezultat procesu decyzyjnego. **Segment Z** obejmuje użytkowników przechodzących przez wszystkie etapy aż do etapu rekomendacji działań E4 ($n = 71$, ok. 23%), realizujących pełny cykl decyzyjny od diagnozy do planowania działań (tab. 3).

Rozkład sesji przedstawiony w tabeli 3 wskazuje, że najczęstszym punktem domknięcia procesu jest etap E3, co oznacza, że synteza strategiczna stanowi dla większości użytkowników kluczowy rezultat pracy z aplikacją. Mniejsza część użytkowników kończy analizę na etapie E2, traktując SWOTmaker przede wszystkim jako narzędzie diagnostyczne, natomiast pełny cykl decyzyjny realizowany jest przez relatywnie wąską, lecz wyraźnie wyodrębnioną grupę użytkowników.

Zaobserwowany spadek liczby sesji na kolejnych etapach jest zjawiskiem typowym dla narzędzi analitycznych wymagających rosnącego zaangażowania poznawczego. Jednocześnie fakt, że istotna część użytkowników kończy analizę na etapie strategii TOWS, wskazuje na wysoką częstość wykorzystania wsparcia oferowanego przez agentów AI w procesie syntezy danych SWOT. Wyniki te odpowiadają na pytanie badawcze (d), potwierdzając, że etap E3 stanowi dominujący punkt zakończenia korzystania z aplikacji SWOTmaker.

4.3. Dynamika i czas trwania procesu (intensywność interakcji)

Dane telemetryczne umożliwiają analizę czasów przejść pomiędzy kolejnymi etapami procesu analizy SWOT/TOWS (E1–E4) oraz porównanie intensywności interakcji użytkowników w segmentach X, Y i Z. Pozwala to na ilościowe opisanie tempa pracy użytkowników w aplikacji SWOTmaker oraz identyfikację etapów wymagających największego zaangażowania poznawczego.

Tabela 4. Dynamika przejść między etapami procesu oraz analiza czasów w grupach X–Y–Z

Zakres czasu (min)	E1 → E2 ($n = 236$)	E2 → E3 ($n = 162$)	E3 → E4 ($n = 71$)	Grupa X ($n = 74$)	Grupa Y ($n = 91$)	Grupa Z ($n = 71$)
od 0 do 1 min	32%	28%	69%	24%	15%	69%
od 2 do 5 min	32%	33%	26%	49%	42%	26%
od 6 do 15 min	13%	19%	5%	14%	20%	5%
od 16 do 30 min	6%	6%	0%	5%	7%	0%
od 31 do 60 min	5%	4%	0%	3%	4%	0%
od 61 do 120 min	5%	3%	0%	2%	3%	0%
od 121 do 240 min	1%	3%	0%	0%	4%	0%
od 241 do 1440 min	3%	3%	0%	0%	4%	0%
> 1441 min	3%	3%	0%	3%	0%	0%

Źródło: opracowanie własne na podstawie danych telemetrycznych SWOTmaker.

Zestawienie czasów przejść pomiędzy etapami (tab. 4) wskazuje na wyraźne zróżnicowanie dynamiki interakcji w zależności od fazy procesu. Najdłuższe czasy odnotowano dla przejścia z etapu E1 do E2, które obejmuje formułowanie kontekstu oraz identyfikację i weryfikację czynników SWOT. Wysoka zmienność czasów w tej fazie sugeruje zróżnicowany poziom interakcji użytkowników z agentem AI – od szybkiej akceptacji propozycji po ich intensywną modyfikację lub przerwanie sesji.

Czasy przejścia z etapu E2 do E3 ulegają wyraźnemu skróceniu, co można wiązać z bardziej ustrukturyzowanym charakterem syntezy strategicznej. W tej fazie użytkownicy dokonują oceny

wygenerowanych strategii TOWS, a różnice w czasie realizacji odzwierciedlają indywidualne style pracy – od szybkiego wyboru strategii po porównywanie wariantów (SO, ST, WO, WT). Najkrótsze czasy zaobserwowano dla przejścia z E3 do E4, co wynika z wysokiego poziomu automatyzacji etapu rekomendacji działań i ograniczonej roli użytkownika do przeglądu wyników.

Analiza statystyk opisowych (tab. 5) potwierdza, że wraz z postępem procesu średnie i mediany czasów przejść maleją, a jednocześnie zmniejsza się ich zróżnicowanie. Oznacza to, że końcowe etapy analizy przebiegają szybciej i w bardziej jednorodny sposób, co można interpretować jako efekt automatyzacji oraz utrwalenia schematu pracy z narzędziem. W segmentach X i Y czasy realizacji są krótsze, lecz bardziej rozproszone, natomiast w segmencie Z – obejmującym użytkowników realizujących pełny cykl (E1–E4) – całkowity czas sesji jest dłuższy, przy jednoczesnej stabilizacji czasów w końcowej fazie procesu.

Tabela 5. Statystyki opisowe dla czasu przejść między etapami i w grupach

Przejście / Grupa	Mediana	Średnia	SD	MIN	MAX
E1 → E2	3,00	6917,00	89255,35	1,00	1314658,00
E2 → E3	3,00	212,24	1193,14	1,00	12959,00
E3 → E4	1,00	1,68	1,42	1,00	7,00
Grupa X	3,00	2767,20	17636,21	1,00	132570,00
Grupa Y	5,00	54,93	203,34	1,00	1390,00
Grupa Z	1,00	1,68	1,42	1,00	7,00

Źródło: opracowanie własne na podstawie danych telemetrycznych SWOTmaker.

Większość sesji realizowana jest w sposób ciągły, bez długich przerw pomiędzy etapami, co sugeruje, że analiza SWOTmaker postrzegana jest jako proces możliwy do przeprowadzenia w ramach jednej sesji roboczej. Jedynie nieliczne przypadki obejmują przerwy przekraczające godzinę, wskazujące na powrót do wcześniej rozpoczętej analizy. Uzyskane wyniki bezpośrednio odpowiadają na pytanie badawcze (a), pokazując, że ukończenie pełnego cyklu analizy wymaga największego zaangażowania czasowego w początkowych fazach, podczas gdy etapy końcowe przebiegają szybciej i bardziej schematycznie.

4.4. Syntetyczne ujęcie wyników

Analiza danych telemetrycznych z wykorzystania aplikacji SWOTmaker pokazuje, że proces analizy SWOT/TOWS wspomagany przez agentów sztucznej inteligencji ma w praktyce charakter selektywny i etapowy. Choć większość użytkowników inicjuje analizę od opisu kontekstu i identyfikacji czynników SWOT, tylko część z nich przechodzi przez pełny cykl decyzyjny obejmujący również formułowanie rekomendacji działań. Dominującym punktem domknięcia procesu jest etap syntezy strategii TOWS (E3), który dla wielu użytkowników stanowi wystarczający rezultat pracy z narzędziem.

Wyniki analizy czasów przejść pomiędzy etapami wskazują, że największe zaangażowanie czasowe i poznawcze występuje w początkowych fazach procesu (E1–E2), związanych z formułowaniem kontekstu i analizą czynników SWOT. W kolejnych etapach obserwowany jest spadek średnich czasów oraz ich zróżnicowania, co sugeruje rosnącą automatyzację procesu i większą jednorodność sposobu interakcji użytkowników z systemem.

Segmentacja sesji użytkowników (X–Y–Z) pozwala odróżnić skrócone ścieżki wykorzystania aplikacji, skoncentrowane na diagnozie lub syntezie strategicznej, od pełnych procesów decyzyjnych prowadzących do planowania działań. Uzyskane wyniki dostarczają empirycznego obrazu sposobu, w jaki użytkownicy faktycznie korzystają z narzędzi AI-SWOT w modelu *human-in-the-loop*, tworząc punkt wyjścia do dalszej interpretacji w kontekście projektowania systemów wspomagania decyzji i roli sztucznej inteligencji w analizie strategicznej.

5. Dyskusja i wnioski

5.1. Dyskusja wyników w świetle literatury

Wyniki analizy telemetrycznej wskazują, że dominującym punktem domknięcia procesu analizy SWOT/TOWS w aplikacji SWOTmaker jest etap syntezy strategii TOWS (E3), natomiast pełny cykl decyzyjny obejmujący również rekomendacje działań (E4) realizuje jedynie mniejszość użytkowników. Obserwacja ta jest spójna z pierwotnym rozumieniem TOWS jako narzędzia „mostowego” pomiędzy diagnozą a wyborem kierunku działania, przy czym w praktyce użytkowej most ten często kończy się na poziomie strategii, a nie jej operacjonalizacji (Weihrich, 1982).

Dominacja strategii typu SO w etapie E3 sugeruje preferencję scenariuszy ofensywnych, co można wiązać zarówno z pozytywną orientacją danych wejściowych dostarczanych przez użytkowników, jak i z heurystykami generatywnych modeli AI wzmacniającymi logikę „wykorzystania atutów wobec szans”. Literatura wskazuje, że TOWS nie zakłada neutralnego rozkładu typów strategii, a ich profil może odzwierciedlać zarówno biasy poznawcze użytkowników, jak i właściwości algorytmiczne systemu. Podobne tendencje obserwowane są również w innych zastosowaniach generatywnej AI w analizie SWOT, gdzie przeważają strategie pozytywnie zorientowane (Klophaus, 2025).

Z perspektywy interakcji *human-in-the-loop* istotny jest wysoki poziom akceptacji propozycji generowanych przez AI, szczególnie w początkowych etapach procesu (E1–E2). Wynik ten jest zgodny z obserwacjami, że modele językowe redukują barierę rozpoczęcia analizy i ułatwiają przejście od opisu do strukturyzacji problemu (Shneiderman, 2020). Jednocześnie literatura zwraca uwagę, że nadmierna automatyczna akceptacja może prowadzić do zakotwiczenia poznawczego i przedwczesnego domykania procesu decyzyjnego, co podkreśla znaczenie mechanizmów kontroli po stronie użytkownika (Bansal i in., 2019; Bućnica i in., 2021).

Analiza dynamiki czasowej potwierdza, że największe obciążenie poznawcze występuje w początkowej fazie procesu (E1→E2), natomiast kolejne etapy cechują się skróceniem i stabilizacją czasów przejść. Wysoka jednorodność przejścia E3→E4 wskazuje na silną automatyzację końcowej fazy procesu, co sprzyja efektywności, lecz jednocześnie może ograniczać refleksyjność użytkownika w fazie planowania działań.

5.2. Implikacje teoretyczne

Po pierwsze, zaproponowana segmentacja X–Y–Z stanowi prosty, empirycznie osadzony na danych telemetrycznych wskaźnik stopnia domknięcia procesu decyzyjnego w narzędziach AI-SWOT, umożliwiający analizę „lejka decyzyjnego” od diagnozy do działań.

Po drugie, wyniki empiryczne uzupełniają literaturę dotyczącą TOWS, pokazując, że domknięcie procesu w praktyce ma charakter dwustopniowy: synteza strategii (E3) jest relatywnie łatwa do osiągnięcia, natomiast translacja strategii na działania (E4) generuje dodatkowe tarcie poznawcze.

Po trzecie, dominacja strategii SO sugeruje, że profil TOWS w środowiskach wspieranych przez AI należy traktować jako efekt interakcji danych wejściowych i mechanizmów generatywnych, a nie jako neutralne odzwierciedlenie kontekstu strategicznego.

5.3. Implikacje praktyczne

Po pierwsze, w celu ograniczenia ryzyka zakotwiczenia poznawczego rekomenduje się wprowadzanie alternatywnych wariantów strategii (kontratypów) oraz transparentnych wyjaśnień logiki łączy TOWS przed akceptacją wyników.

Po drugie, w przejściu E3→E4 wskazane jest zastosowanie „delikatnych popychaczy” w postaci szablonów działań powiązanych z typem strategii oraz informacji o wysiłku wdrożeniowym, co może zmniejszać barierę operacjonalizacji strategii.

Po trzecie, monitorowanie wskaźników domknięcia (np. E3→E4) oraz poziomu edycji wyników przez użytkownika może pełnić rolę KPI jakości interakcji *human-in-the-loop*, wykraczając poza ocenę samej skuteczności generowania strategii. Wyniki badań nad korzystaniem z algorytmicznych rekomendacji sugerują, że nawet ograniczona możliwość modyfikacji propozycji systemu zwiększa akceptację rozwiązań algorytmicznych i poczucie sprawczości użytkownika, co wzmacnia zasadność projektowania narzędzi SWOTmaker w logice HITL (Dietvorst i in., 2016).

Badania nad *AI-assisted decision-making* wskazują, że samo wyświetlanie rekomendacji może sprzyjać zjawisku *overreliance*, natomiast skuteczne bywają tzw. mechanizmy wymuszonej refleksji (*cognitive forcing functions*) – krótkie rozwiązania interfejsowe zachęcające użytkownika do weryfikacji lub kontroli przed akceptacją propozycji AI. W praktyce mogą one przyjmować formę np. obowiązkowego wskazania jednego ryzyka, krótkiego uzasadnienia wyboru lub porównania z kontratypem, co wzmacnia aktywną rolę użytkownika i ogranicza ryzyko przedwczesnego „domykania” analizy na podstawie pierwszej sugestii systemu (Bućnica i in., 2021).

5.4. Ograniczenia i kierunki dalszych badań

Analiza SWOT/TOWS oraz rozwiązania oparte na generatywnej sztucznej inteligencji mają liczne ograniczenia, które należy uwzględniać przy interpretacji wyników i projektowaniu narzędzi AI-SWOT. Po stronie SWOT/TOWS kluczowe są: subiektywność doboru czynników, brak wbudowanej priorytetyzacji/wag oraz ryzyko „pozornego domknięcia” procesu w formie list, które nie przekładają się na wybór i wdrożenie działań. Po stronie generatywnej AI istotne są m.in.: halucynacje, tendencyjność (*bias*), wrażliwość na sposób sformułowania kontekstu oraz ryzyko zakotwiczenia i nadmiernego polegania na sugestiach modelu (*automation bias*). W konsekwencji rola *human-in-the-loop* pozostaje krytyczna: użytkownik powinien weryfikować propozycje AI, uzupełniać dane i świadomie wybierać dalsze kroki. Wskazane ryzyka są dobrze udokumentowane zarówno w literaturze generowania języka naturalnego (halucynacje), jak i w klasycznych badaniach nad interakcją człowiek–automatyzacja (*misuse/disuse*), co wzmacnia zasadność triangulacji metod i walidacji rezultatów (Ji i in., 2023; Parasuraman i Riley, 1997).

Badanie ma charakter opisowy i telemetryczny, co uniemożliwia wnioskowanie przyczynowe. Dodatkowym ograniczeniem jest zmienność systemu i populacji użytkowników w czasie, a także brak bezpośredniej oceny jakości i skuteczności biznesowej generowanych strategii.

Dalsze badania powinny obejmować eksperymenty kontrolowane (np. testy A/B interfejsu), podejścia mieszane łączące dane telemetryczne z wywiadami jakościowymi oraz ocenę merytoryczną strategii z udziałem ekspertów. Obiecującym kierunkiem jest również analiza wpływu kompozycji czynników SWOT i jakości promptów na profil TOWS w systemach generatywnych.

5.5. Wnioski

Badanie wykazało, że w praktyce korzystania z aplikacji SWOTmaker dominującym punktem domknięcia procesu jest etap syntezy strategicznej (E3), natomiast operacjonalizacja strategii (E4) pozostaje dla części użytkowników barierą wymagającą dodatkowego wsparcia projektowego. Segmentacja X–Y–Z stanowi obiecującą propozycję opisu stopnia domknięcia procesu decyzyjnego w narzędziach AI-SWOT oraz punkt wyjścia do dalszych badań ilościowych (w tym walidacji statystycznej) i triangulacji metod (np. z wywiadami lub oceną ekspercką).

Dominacja strategii SO potwierdza wrażliwość wyników generatywnych na sposób formułowania kontekstu oraz wzorce interakcji człowiek–model (Rahman i in., 2025). Zaproponowane kierunki usprawnień, obejmujące kontratypy, popychacze decyzyjne oraz metryki domknięcia, mogą zwiększyć odsetek pełnych analiz bez naruszania kluczowej zasady *human-in-the-loop*, zgodnie z którą człowiek pozostaje ostatecznym decydem w procesie wspomagany przez AI.

Bibliografia

- Amershi, S., Weld, D., Vorvoreanu, M., Fourney, A., Nushi, B., Collisson, P., Suh, J., Iqbal, S., Bennett, P. N., Inkpen, K., Teevan, J., Kikin-Gil, R. i Horvitz, E. (2019). Guidelines for Human-AI Interaction. *CHI '19: Proceedings of the 2019 CHI Conference on Human Factors in Computing Systems*, (3), 1-13. <https://doi.org/10.1145/3290605.3300233>
- Bansal, G., Nushi, B., Kamar, E., Lasecki, W. S., Weld, D. S. i Horvitz, E. (2019). Beyond Accuracy: The Role of Mental Models in Human-AI Team Performance. *Proceedings of the AAAI Conference on Human Computation and Crowdsourcing*, 7(1), 2-11. <https://doi.org/10.1609/hcomp.v7i1.5285>
- Buçinca, Z., Malaya, M. B. i Gajos, K. Z. (2021). To Trust or to Think: Cognitive Forcing Functions Can Reduce Overreliance on AI in AI-Assisted Decision-Making. *Proceedings of the ACM on Human-Computer Interaction*, 5(CSCW1), 1-21. <https://dl.acm.org/doi/10.1145/3449287>
- Dietvorst, B. J., Simmons, J. P. i Massey, C. (2016). Overcoming Algorithm Aversion: People Will Use Imperfect Algorithms If They Can (Even Slightly) Modify Them. *Management Science*, 64(3), 983-1476. <https://doi.org/10.1287/mnsc.2016.2643>
- Doshi, A. R., Bell, J. J., Mirzayev, E. i Vanneste, B. S. (2025). Generative Artificial Intelligence and Evaluating Strategic Decisions. *Strategic Management Journal*, 46(3), 583-610. <https://doi.org/10.1002/smj.3677>
- Dyson, R. G. (2004). Strategic Development and SWOT Analysis at the University of Warwick. *European Journal of Operational Research*, 152(3), 631-640. [https://doi.org/10.1016/S0377-2217\(03\)00062-6](https://doi.org/10.1016/S0377-2217(03)00062-6)
- Dziembek, D. i Ziora, L. (2023). Cloud-Based Business Intelligence Solutions in the Management of Polish Companies. W: G. C. Silaghi, R. A. Buchmann, V. Niculescu, G. Czibula, C. Barry, M. Lang, H. Linger i C. Schneider (red.), *Advances in Information Systems Development. ISD 2022. Lecture Notes in Information Systems and Organisation* (t. 63). Springer. https://doi.org/10.1007/978-3-031-32418-5_3
- Ghazinoory, S., Abdi, M. i Azadegan-Mehr, M. (2011). SWOT Methodology: A State-of-the-Art Review for the Past, a Framework for the Future. *Journal of Business Economics and Management*, 12(1), 24-48. <https://doi.org/10.3846/16111699.2011.555358>
- Gomez, C., Cho, S. M., Ke, S., Huang, C.-M. i Unberath, M. (2024). Human-AI Collaboration Is Not Very Collaborative Yet: A Taxonomy of Interaction Patterns in AI-Assisted Decision Making from a Systematic Review. *arXiv*. <https://doi.org/10.48550/arXiv.2310.19778>
- Helms, M. M. i Nixon, J. (2010). Exploring SWOT Analysis: Where Are We Now? A Review of Academic Research from the Last Decade. *Journal of Strategy and Management*, 3(3), 215-251. <https://doi.org/10.1108/17554251011064837>
- Hill, T. i Westbrook, R. (1997). SWOT Analysis: It's Time for a Product Recall. *Long Range Planning*, 30(1), 46-52. [https://doi.org/10.1016/S0024-6301\(96\)00095-7](https://doi.org/10.1016/S0024-6301(96)00095-7)
- Ji, Z., Lee, N., Frieske, R., Yu, T., Su, D., Xu, Y., Ishii, E., Bang, Y. J., Madotto, A. i Fung, P. (2023). Survey of Hallucination in Natural Language Generation. *ACM Computing Surveys*, 55(12), 1-38. <https://dl.acm.org/doi/10.1145/3571730>
- Kajanus, M., Leskinen, P., Kangas, J. i Kurttila, M. (2012). Making Use of MCDS Methods in SWOT Analysis—Lessons Learnt in Strategic Natural Resources Management. *Forest Policy and Economics*, 20, 1-9. <https://doi.org/10.1016/j.forpol.2012.03.005>
- Kaplan, R. S. i Norton, D. P. (2001). *The Strategy-Focused Organization: How Balanced Scorecard Companies Thrive in the New Business Environment*. Harvard Business School Press.
- Klophaus, R. (2025). AI-Generated SWOT Analysis of Emerging Technologies in Air Transportation: Potential and Limitations. *Research in Transportation Business & Management*, 59, 101316. <https://doi.org/10.1016/j.rtbm.2025.101316>
- Krwawicz, M. (2019). Metoda SWOT Plus jako rozwinięcie metody SWOT. *Nowoczesne Systemy Zarządzania*, 14(4), 111-124.
- Kurttila, M., Pesonen, M., Kangas, J. i Kajanus, M. (2000). Utilizing the Analytic Hierarchy Process (AHP) in SWOT Analysis – A Hybrid Method and Its Application to a Forest-Certification Case. *Forest Policy and Economics*, 1(1), 41-52. [https://doi.org/10.1016/S1389-9341\(99\)00004-0](https://doi.org/10.1016/S1389-9341(99)00004-0)
- Learned, E. P., Christensen, C. R., Andrews, K. R. i Guth, W. D. (1969). *Business Policy: Text and Cases*. Homewood, IL: Richard D. Irwin.
- Mesko, B. (2023). The ChatGPT (Generative Artificial Intelligence) Revolution Has Made Artificial Intelligence Approachable for Medical Professionals. *Journal of Medical Internet Research*, 25. <https://doi.org/10.2196/48392>
- National Institute of Standards and Technology [NIST]. (2023). *Artificial Intelligence Risk Management Framework (AI RMF 1.0)*. <https://doi.org/10.6028/NIST.AI.100-1>
- Panagiotou, G. (2003). Bringing SWOT into Focus. *Business Strategy Review*, 14(2), 8-10. <https://doi.org/10.1111/1467-8616.00253>
- Parasuraman, R. i Riley, V. (1997). Humans and Automation: Use, Misuse, Disuse, Abuse. *Human Factors: The Journal of the Human Factors and Ergonomics Society*, 39(2), 230-253. <https://doi.org/10.1518/001872097778543886>
- Pickton, D. W. i Wright, S. (1998). What's SWOT in Strategic Analysis? *Strategic Change*, 7(2), 101-109.
- Puyt, R. W., Lie, F. B. i Wilderom, C. P. M. (2023). The Origins of SWOT Analysis. *Long Range Planning*, 56(3), 102304. <https://doi.org/10.1016/j.lrp.2023.102304>

- Rahman, M. A., Hossain, M. S., Minto, A. A. i Islam, S. (2025). A Systematic Review of Intelligent Support Systems for Strategic Decision-Making Using Human-AI Interaction in Enterprise Platforms. *American Journal of Advanced Technology and Engineering Solutions*, 1(1), 506-543. <https://doi.org/10.63125/a5yh1293>
- Shneiderman, B. (2020). Human-Centered Artificial Intelligence: Reliable, Safe & Trustworthy. *International Journal of Human-Computer Interaction*, 36(6), 495-504. <https://doi.org/10.1080/10447318.2020.1741118>
- Sprague, R. H. (1980). A Framework for the Development of Decision Support Systems. *MIS Quarterly*, 4(4), 1-26. <https://doi.org/10.2307/248957>
- Stewart, R. F. (1963). A Framework for Business Planning. *Long Range Planning Service*, (162).
- Szmitka, S. (2015). Analiza SWOT jako narzędzie oceny innowacyjności przedsięwzięcia biznesowego. *Warmińsko-Mazurski Kwartalnik Naukowy. Nauki Społeczne*, (4), 79-97.
- Wehrich, H. (1982). The TOWS Matrix—A Tool for Situational Analysis. *Long Range Planning*, 15(2), 54-66. <https://www.sciencedirect.com/science/article/abs/pii/0024630182901200?via%3Dihub>

From Analysis to Strategy: AI-Enhanced Transformation of Traditional SWOT

Abstract

Aim: To empirically describe how users of the SWOTmaker application progress through the stages of AI-agent-supported SWOT/TOWS analysis, and to operationalize and characterize the degree of process completion (understood as progression through successive stages E1–E4) based on telemetry data.

Methodology: An exploratory study using telemetry data from real user sessions (2022–2025). Descriptive statistics and behavioral segmentation were applied (X – ended at E2, Y – at E3, Z – full E1–E4).

Results: Most sessions end at E3 (TOWS strategy generation), while only a minority reach E4 (action recommendations). SO strategies dominate and users largely accept AI suggestions without edits.

Implications and recommendations: The findings suggest a need to design AI-SWOT interfaces with mechanisms that mitigate anchoring and premature closure (e.g., presenting counter-types/alternative strategy variants) and to introduce E3→E4 “nudges” that support translating strategy into actionable steps. The X–Y–Z segmentation can serve as a simple indicator of process completion within the tool and as a starting point for further research on the quality of human-in-the-loop (HITL) interaction, including validation using qualitative methods or expert evaluation.

Originality/value: This study provides the first empirical evidence on real user behaviors within an AI-driven TOWS system. It introduces a new process completion metric (X–Y–Z segmentation) and demonstrates how generative AI transforms the classical SWOT model into a dynamic, interactive cognitive process.

Keywords: SWOT, TOWS, artificial intelligence, human-in-the-loop (HITL), telemetry analysis, decision support systems, AI-SWOT
