

UNIWERSYTET EKONOMICZNY W KATOWICACH

KIERUNEK INFORMATYKA I EKONOMETRIA

KATARZYNA ADAMCZYK

Nr Albumu: 141726

Skuteczność algorytmów rekomendacyjnych na platformie streamingowej Netflix

Effectiveness of recommendation algorithms on the
Netflix streaming platform

Praca licencjacka
napisana w Katedrze Informatyki
pod kierunkiem dr Artura Strzeleckiego

Oświadczam, że niniejsza praca została przygotowana pod moim kierunkiem
i stwierdzam, że spełnia wymogi stawiane pracom dyplomowym

Pracę akceptuję

.....

(data)

.....

(podpis promotora)

KATOWICE 2022

KATARZYNA ADAMCZYK

Katowice, dnia 21.09.2022

Imię i nazwisko

INFORMATYKA I EKONOMETRIA

Kierunek

141726

Nr albumu

OŚWIADCZENIE

Świadom(a) odpowiedzialności prawnej oświadczam, że złożona praca licencjacka/inżynierska/magisterska pt.: „Skuteczność algorytmów rekomendacyjnych na platformie streamingowej Netflix” została napisana przeze mnie samodzielnie.

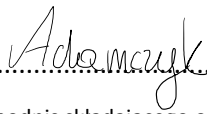
Równocześnie oświadczam, że praca ta nie narusza praw autorskich w rozumieniu ustawy z dnia 4 lutego 1994 roku o prawie autorskim i prawach pokrewnych (tj. Dz. U. z 2018 r., poz. 1191, z późn. zm.) oraz dóbr osobistych chronionych prawem.

Ponadto praca nie zawiera informacji i danych uzyskanych w sposób niedozwolony i nie była wcześniej przedmiotem innych procedur związanych z uzyskaniem dyplomów lub tytułów zawodowych uczelni wyższej.

Wyrażam zgodę na nieodpłatne udostępnienie mojej pracy w celu oceny jej oryginalności przez Jednolity System Antyplagiatowy prowadzony przez Ministra Nauki i Szkolnictwa Wyższego oraz przechowywania jej w Ogólnopolskim Repozytorium Prac Dyplomowych oraz wewnętrznej bazie prac dyplomowych Uniwersytetu Ekonomicznego w Katowicach. Zostałem poinformowany o zasadach dotyczących oceny oryginalności pracy dyplomowej przez Jednolity System Antyplagiatowy.

Oświadczam także, że ostateczna wersja pracy przesłana przeze mnie drogą elektroniczną jest zgodna z plikiem poddanym ocenie w Jednolitym Systemie Antyplagiatowym.

Jednocześnie oświadczam, że jest mi znany przepis art. 233 § 1 Kodeksu karnego określający odpowiedzialność za składanie fałszywych zeznań.


.....
(podpis składającego oświadczenie)

Spis treści

Wstęp	4
1. Wprowadzenie i przegląd literatury	5
1.1. Wprowadzenie.....	5
1.2. Netflix jako platforma strumieniowa	5
1.2.1. Platformy strumieniowe	7
1.2.2. Netflix	7
1.3. Tagi i hasła wyszukiwania	8
1.4. Budowa strony głównej.....	11
1.5. Tworzenie poszczególnych wierszy strony głównej.....	13
1.5.1. Wiersze grup tematycznych - PVR (Personalized Video Ranker)	13
1.5.2. “Wybrane dla <nazwa użytkownika>” - Top-N Video Ranker	14
1.5.3. “Popularne teraz”	14
1.5.4. „Oglądaj dalej”	15
1.5.5. “Podobne do <tytuł>” lub “Propozycje po obejrzeniu: <tytuł>”, lub “Ponieważ lubisz: <tytuł>” - Video-Video Similarity.....	16
1.5.6. “Moja lista”	16
1.5.7. “Obejrzyj ponownie”	17
1.5.8. “Top 10 w <nazwa państwa> dzisiaj”	17
1.6. Podsumowanie	17
2. Metodyka badawcza i model	18
2.1. Metodyka wykorzystana w badaniu	18
2.1.1. Korzystanie i rekomendacja	19
2.1.2. Personalizacja	19
2.1.3. Satysfakcja.....	20
2.1.4. Użyteczność strony głównej.....	20

2.1.5. Użyteczność wyszukiwarki	21
2.2. Model teoretyczny	21
2.2.1. Modelowanie dla zmiennych refleksyjnych	21
2.2.2. Modelowanie dla zmiennych kształujących	22
2.2.3. Szacowanie modelu strukturalnego	22
2.2.4. Model	23
2.2.5. Konstrukty i zmienne	24
2.3. Wyniki badania	25
2.3.1. Charakterystyka demograficzna badanej grupy	25
2.3.2. Wyniki oceny zmiennych	27
2.3.3. Wyniki oszacowania modelu	30
2.3.4. Wyniki analizy wielogrupowej	32
3. Podsumowanie	34
3.1. Dyskusja	34
3.2. Wkład	35
3.3. Praktyczne zastosowanie	35
3.4. Ograniczenia	36
Zakończenie	38
Bibliografia	39
Spis tabel	41
Spis rysunków	42
Załącznik	43

Wstęp

Wraz ze spadkiem popularności tradycyjnej telewizji, w szczególności wśród młodszych pokoleń, wzrasta zainteresowanie wciąż rozwijającymi się platformami streamingowymi takimi jak Netflix, HBO Max czy Disney+. Tą właśnie tematyką zajmuje się poniższa praca „Skuteczność algorytmów rekomendacyjnych na platformie streamingowej Netflix”. Z racji, że jest to dziedzina ciągle szybko się rozwijająca, nie jest ona dokładnie zbadana ani opisana.

Algorytmy rekomendacyjne na takich portalach są podstawą ich działania, ponieważ wpływają na zawartości, które są prezentowane użytkownikowi, a w konsekwencji wpływają również na odbiór witryny przez oglądających. Badanie zostało oparte na odpowiedziach udzielonych przez oglądających Netflix'a w ankiecie dotyczącej opinii odbiorców i przyjrano się satysfakcji z korzystania z portalu oraz funkcjonalności strony głównej i wyszukiwarki, opartych na materiałach rekomendowanych użytkownikom.

Głównym celem badania oraz całej pracy jest określenie użyteczności zastosowanych na platformie algorytmów rekomendacyjnych oraz zbadanie subiektywnej opinii użytkowników oraz sposobu i częstotliwości korzystania przez nich z platformy strumieniowej - Netflix.

Praca podzielona jest na trzy główne części:

- Pierwszy rozdział powstał na podstawie literatury i stanowi teoretyczny wstęp do pojęć badanych w kolejnych częściach. Szczegółowo opisano algorytmy rekomendacyjne, które można znaleźć na Netflixie oraz sposoby tworzenia wierszy na stronie głównej z ich podziałem w zależności od zawartości.
- Drugi rozdział opisuje przebieg badania, jego metodologię oraz zawiera dane wynikowe, które uzyskano podczas analizy. Rozpoczyna się od postawienia hipotez i scharakteryzowania poszczególnych konstruktów, które stanowią podstawę dalszych analiz.
- Trzeci rozdział rozpoczyna dyskusję oraz stanowi interpretację wyników oraz zawiera podsumowanie badania, ograniczenia napotkane podczas jego przeprowadzania, a także praktyczne zastosowanie pracy.

1. Wprowadzenie i przegląd literatury

W pierwszym rozdziale zawarto wprowadzenie do tematu pracy. Przegląd literatury pozwala na poznanie teoretycznej części działania algorytmów rekomendacyjnych w witrynie Netflix. Rozpoczynając od przybliżenia pojęcia platform streamingowych i informacji o wybranym serwisie, poprzez działanie najważniejszych elementów aplikacji związanych z wyszukiwaniem i polecaniem tytułów, kończąc na budowie i działaniu strony głównej i jej wierszy.

1.1. Wprowadzenie

Wraz z dynamicznym rozwojem technologicznym, ludzie przenoszą coraz większą część swojego życia do świata wirtualnego. Naturalne stało się czytanie informacji na stronach informacyjnych zamiast w gazetach, szukanie porad na forach internetowych, a nawet rozmowy telefoniczne z przyjaciółmi są wypierane przez pisanie wiadomości na czatach i portalach społecznościowych. W obecnych czasach także rozrywka rozwija się w internecie. Między innymi w postaci gier, krótkich żartobliwych filmików czy artykułów plotkarskich. Jednak spore zainteresowanie zdobywa telewizja internetowa. Stale wzrasta liczba portali oferujących użytkownikom szeroki wybór tytułów filmów, seriali jak również teleturniejów i programów rozrywkowych typu talk show czy reality show. Początkowo platformy streamingowe były prowadzone przez niezależne firmy oraz studia filmowe jak np. Disney, jednak z czasem na przestrzeni wirtualnej pojawiły się także portale udostępniające materiały i produkcje tradycyjnych stacji telewizyjnych.

1.2. Netflix jako platforma strumieniowa

Amerykańska firma o nazwie Netflix zajmuje się streamingiem i produkcją filmową. Na swojej aplikacji oferuje setki tytułów filmów, seriali czy programów rozrywkowych. A ich baza jest stale powiększana. Pierwotnie marka była kojarzona przede wszystkim jako platforma, na której można znaleźć wiele dzieł kinematografii w bardzo dobrej jakości, ale wraz z rozwojem firma stała się także wyznacznikiem wysokich standardów również swoich wyjątkowych produkcji.

Witryna netflix.com jest dostępna poprzez przeglądarki internetowe oraz przez aplikację na urządzeniach z dostępem do sieci - zarówno na sprzęcie mobilnym (smartfon czy

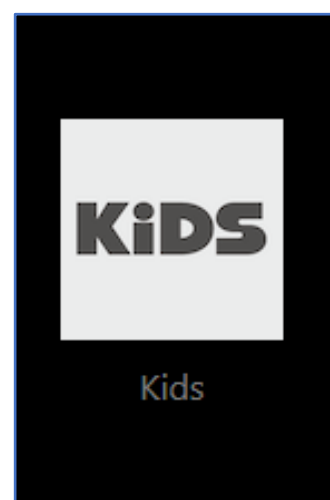
tablet), Smart TV, odtwarzaczach multimedialnych, jak i konsolach do gier. Zalogowani na swoje konta subskrybenci mają możliwość oglądania zawartości z bazy produkcji na żywo, a także offline po zapisaniu i pobraniu wybranych tytułów na urządzenie, jednak opcja oglądania programów bez dostępu do internetu jest dostępna jedynie na systemach operacyjnych iOS, Android oraz Windows 10 (Help Center, 2021).

Platforma cyfrowa oparta jest na subskrypcji miesięcznej - wykupieniu abonamentu na miesiąc. Użytkownik ma do wyboru trzy opcje planów: Podstawowy, Standard oraz Premium. Różnią się one pomiędzy sobą kosztem, a także zasadami korzystania. (Help Center, 2021).

	Podstawowy	Standard	Premium
Koszt miesięczny* (PLN)	34 PLN	43 PLN	52 PLN
Liczba ekranów, na których można jednocześnie korzystać z serwisu	1	2	4
Liczba telefonów lub tabletów, na które można pobierać pliki	1	2	4
Oglądaj filmy, seriale i programy bez ograniczeń	✓	✓	✓
Oglądaj na laptopie, telewizorze, telefonie lub tablecie	✓	✓	✓
Dostępna jakość HD		✓	✓
Dostępna jakość Ultra HD			✓

Rysunek 1 Plany subskrypcji w Netflixie. Źródło: help.netflix.com [czerwiec 2021 r.]

W ramach członkostwa w serwisie, niezależnie od wybranego planu, dostępna jest osobna sekcja przeznaczona dla dzieci. Znaleźć tam można produkcje skierowane do młodszych odbiorców tudzież filmy i seriale familijne. Sam profil chroniony jest kodem PIN w ramach kontroli rodzicielskiej, dzięki czemu uniemożliwione jest przekroczenie określonych kategorii wiekowych, jak również pozwala to na zablokowanie konkretnych tytułów (Help Center, 2021).



Rysunek 2 Ikona dostępu do sekcji dla dzieci

1.2.1. Platformy strumieniowe

Mówiąc o telewizji internetowej mamy najczęściej na myśli platformy strumieniowe, inaczej nazywane platformami streamingowymi czy platformami VOD. Są to witryny oferujące oglądanie materiałów wideo online, bez określonego planu nadawania - ramówki programowej. Użytkownik może samodzielnie wybrać sobie tytuł i obejrzeć go w dowolnym momencie. Dostęp do platformy może być udostępniany odpłatnie (zazwyczaj bez wyświetlania reklam), częściowo odpłatnie (płatne są materiały dodatkowe) bądź całkowicie darmowo. Dodatkowym atutem jest fakt, że tytuły można oglądać bez kupowania fizycznej wersji oraz bez zajmowania miejsca w pamięci urządzenia. Ponadto subskrybent ma większą kontrolę nad wyborem materiału poprzez spersonalizowany algorytm rekomendacji i oceniania, a także czuje się swobodniej, ponieważ może zrezygnować czy zatrzymać oglądanie w każdym momencie. "Na platformach VOD liczba dostępnych materiałów jest na tyle duża, że rezygnacja z któregośkolwiek z nich nie wiąże się z odczuwalną stratą." (Sztąberek, 2018)

1.2.2. Netflix

Netflix jest amerykańską firmą, która zajmuje się udostępnianiem filmów od początku swojej działalności. Pierwotnie pod postacią strony internetowej, na której klienci mogli wypożyczyć płyty DVD i otrzymać je tradycyjną pocztą. W swojej pierwszej odsłonie wypożyczalnia posiadała system rekomendacji w postaci średniej liczby gwiazdek. Po oddaniu tytułu oglądający mógł ocenić film w skali od 1 do 5 gwiazdek. W ten sposób firma stworzyła algorytm, dzięki któremu możliwe było ocenianie produkcji z perspektywy widza, a nie tylko profesjonalnych krytyków. Jednak pozwalało to jedynie na obiektywne spojrzenie na poszczególne płyty, zaś każdy z klientów posiadał swój własny subiektywny gust, przez co oceny nie były odpowiednim wskaźnikiem. Przykładowo osoba o specyficznym guście mogła ocenić tytuł bardzo wysoko, co spowodowało podniesienie jego ogólnej oceny i zachęciło nowego widza do wypożyczenia filmu, który mimo dobrej opinii mu się nie spodobał. Tym sposobem klient był niezadowolony z usługi, a marka mogła stracić potencjalnego subskrybenta i swoją wiarygodność (Gomez-Uribe & Hunt, 2016).

Firma zmieniła sposób swojej działalności w styczniu 2007 roku, kiedy rozpoczęła streaming treści filmowych online. Klienci, korzystający wcześniej z subskrypcji usługi pocztowej, mogli korzystać z nowej formuły bezpłatnie. Wraz z przejściem na streaming Netflix zaczął konkurować z tradycyjną telewizją oraz został nazwany telewizją internetową. W 2010 roku witryna przekroczyła granice Stanów Zjednoczonych i pojawiła się w Kanadzie,

rok później w Ameryce Łacińskiej, a w 2012 roku po raz pierwszy w Europie. W 2016 roku platforma była dostępna już w 190 krajach na całym świecie (Subías et al., 2018).

Początkowo informacje o jakości i popularności filmu były kształtowane na podstawie mało dokładnej opinii w formie oddanej liczby gwiazdek po zwróceniu obejrzanego tytułu. Jednak stale rozwijający się globalny biznes stworzył potrzebę zmiany i dostosowania algorytmu rekomendacyjnego, dzięki któremu mogli nie tylko zatrzymać dotychczasowych subskrybentów, ale także zwrócić uwagę i przyciągnąć nowych użytkowników. Już na początku tworzenia (czyli w 2009 roku) Netflix otrzymał pierwszą nagrodę za swój innowacyjny algorytm do przewidywania ocen, który jest używany aż do dzisiaj. Przesyłanie strumieniowe treści do indywidualnych subskrybentów pozwoliło również na spersonalizowane polecenie tytułów. Oprócz danych o poszczególnych produkcjach filmowych, system pobiera także informacje o sposobie używania witryny, takich jak urządzenie, na którym jest wyświetlana, pora dnia, dzień tygodnia, a nawet intensywność oglądania. Dzięki czemu użytkownik posiadał spersonalizowany zestaw tytułów nie tylko ze względu na osobiste preferencje, ale także dopasowane do czasu i urządzenia, z którego korzysta. Głównym sposobem dotarcia do użytkowników jest strona główna Netflix, która jest też najważniejszym miejscem prezentacji rekomendowanych filmów, seriali czy programów rozrywkowych. Za sprawą sprawnie działającego algorytmu polecenia oraz metody przedstawiania wyników marka stała się rozpoznawalna i stale przyciąga nowych użytkowników (Gomez-Uribe & Hunt, 2016).

1.3. Tagi i hasła wyszukiwania

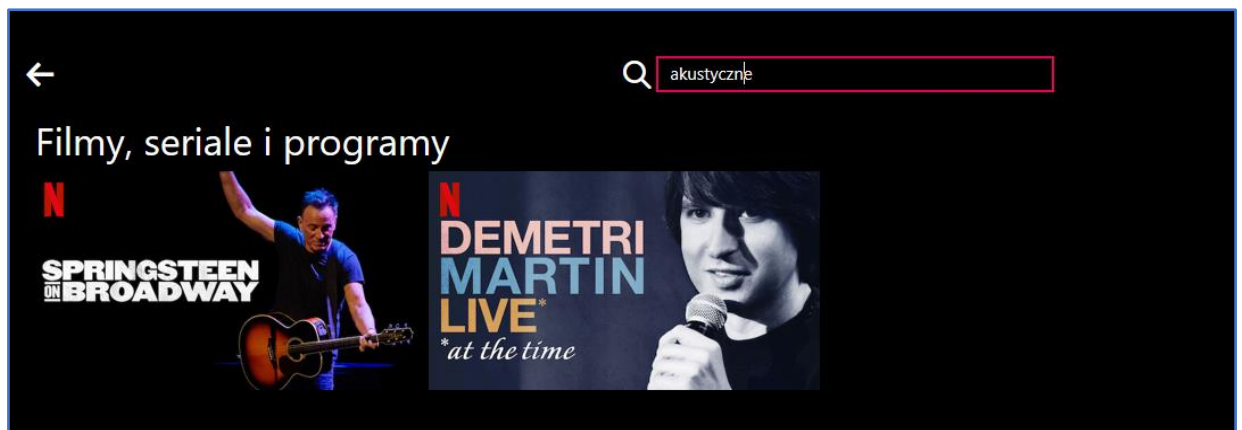
Wybór materiału do oglądania w 80% polega na odnalezieniu interesującego tytułu na stronie głównej. Pozostałe 20% to korzystanie z wbudowanej w witrynę wyszukiwarki. Drugi sposób korzysta z innych algorytmów niż tworzenie strony startowej (Gomez-Uribe & Hunt, 2016).

Hasła wyszukiwania to treść wpisywana w pasku wyszukiwarki. Mogą to być popularne tagi, sprecyzowany tytuł materiału, imię i nazwisko aktora czy gatunek filmowy.


Tagi stały się popularne na mediach społecznościowych, między innymi na Tumblr, Facebooku czy Instagramie. Najczęściej tagi odnoszą się do konkretnych cech materiału oraz ujęte są w pojedynczych słowach np. przyjaźń, supermoce, zbrodnia, rzadko opisują całość. W odróżnieniu od haseł wyszukiwania tagi posiadają charakter masowy. Nie są tworzone przez pojedynczego użytkownika, ale są popularne w sporej ich grupie. Odnosząc się do tworzenia tagów, można podzielić subskrybentów na starszych - takich, którzy dłużej korzystają z

platformy oraz nowych, których profile są dopiero w fazie początkowej analizy. Pierwsi z wymienionych należą do kreatorów tagów, natomiast drudzy są przede wszystkim korzystającymi z gotowych już wzorców.

Problemem jest stale i dynamicznie zmieniająca się baza metadanych. Inną częstą przeszkodą w poprawnym wyszukiwaniu jest fakt, że użytkownicy wielokrotnie wpisują hasła, które są niejednoznaczne, bądź nie ma ich w katalogu witryny. Przykładem mogą być słowa “akustyczne” i “akustycznie” (Rys. 3 i Rys. 4). Oba posiadają podobne problematyczne dla algorytmów znaczenia, a mimo akceptowania literówek i błędów w pisowni, platforma wyświetla kolejno dwa wyniki i ich brak.



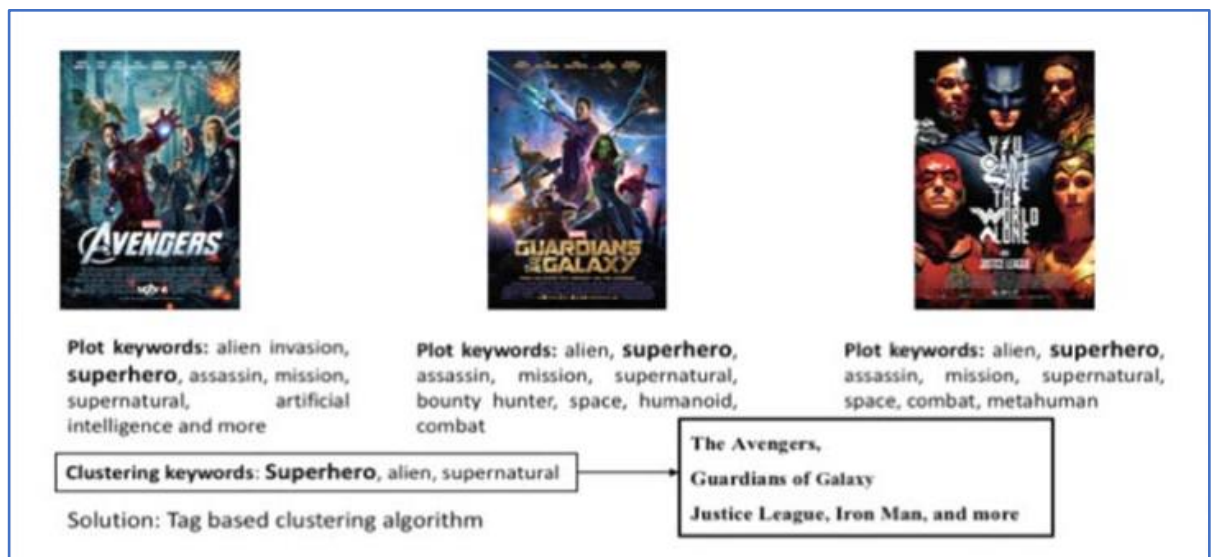
Rysunek 3 Wyniki wyszukiwania dla hasła “akustyczne”, Źródło: opracowanie własne [czerwiec 2021 r.]



Rysunek 4 Wyniki wyszukiwania dla hasła “akustycznie”, Źródło: opracowanie własne [czerwiec 2021 r.]

Kolejnym kłopotliwym aspektem jest przeciążenie witryny informacjami, ponieważ liczba haseł i tagów stale rośnie. Z powodu tego, że każdy użytkownik ma możliwość wpisania swoich osobistych preferowanych słów, są to często synonimy, słowa bliskoznaczne czy potoczne. Aby sobie z tym poradzić wprowadzono “grupowanie tagów”, które polega na połączeniu takich zwrotów w pakiety. Filmy, które posiadają przynajmniej częściowo powtarzające się tagi z poszczególnych pakietów, również są grupowane (Sharma & Kale, 2018). W tym celu można użyć trzech głównych algorytmów (Yang & Wang, 2017):

- MMSK (min-max similarity k-means),
- grupowanie tagów na podstawie analizy semantycznej,
- LMMSK (latent min-max similarity k-means).




Rysunek 5 Przykład grupowania tagów, Źródło: Design of Back-End of Recommendation Systems Using Collective Intelligence Social Tagging, Ravi S. Sharma Rati Kale, 2018

Dodatkową pomocą w rozróżnianiu tagów i haseł jest przypisywanie wag w poszczególnych grupach, w efekcie czego uzyskujemy oznaczenia pierwszo- i drugorzędne. Przykładem może być grupa filmów przedstawiona na rysunku 5. Wśród wymienionych wyrazów-kluczy najważniejszym jest “Superhero”, zatem posiada on znaczenie pierwszorzędne i po wpisaniu go wyświetlą nam się priorytetowo filmy z tego pakietu, natomiast pozostałe hasła są drugorzędne, a po ich wyszukaniu filmy z tej grupy nie będą wyświetlane w pierwszej kolejności (Sharma & Kale, 2018).

1.4. Budowa strony głównej

Fundamentalnym sposobem interakcji na drodze witryna-użytkownik, jest korzystanie ze strony głównej Netflix. To właśnie na niej występują najważniejsze algorytmy rekomendacyjne. Podstawową ich funkcją jest wyselekcjonowanie tytułów i okładek, które wpasowują się w unikalne zainteresowania subskrybenta. Strona startowa jest szczegółowo zaprojektowana tak, aby użytkownik mógł w szybki, łatwy i przejrzysty sposób odnaleźć materiały, które go najbardziej interesują. Ograniczeniem jest nie tylko zbyt obszerna baza filmów, ale także ograniczenia interfejsu, który musi być spójny i uporządkowany, a jednocześnie spersonalizowany do konkretnego konta. W związku z tym każda strona główna posiada inny zbiór materiałów filmowych, lecz ułożonych według konkretnego układu.

Zdecydowana większość strony składa się z tematycznie spójnych rzędów, które można przewijać zarówno w pionie jak i w poziomie. Poruszając się “w bok” można wyświetlić kolejne tytuły należące do konkretnej grupy tematycznej, natomiast przewijając stronę “w dół”, odsłaniane są kolejne wiersze. Na samym szczycie strony pojawia się najczęściej migawka - czyli zwiastun bądź wybrane sceny - jednej z polecanych produkcji (Alvino & Basilico, 2015).



Rysunek 6 Przykładowa strona główna w aplikacji Netflix, Źródło: opracowanie własne [czerwiec 2021 r.]

Kolejność wyświetlanych rzędów nie jest stała ani losowa. W pierwszej kolejności oceniane są poszczególne materiały na podstawie indywidualnych działań użytkownika na platformie, następnie tworzony jest spersonalizowany ranking grup tematycznych - rzędów, a te z kolei układane są na stronie głównej w kolejności od potencjalnie najbardziej interesujących dla klienta. Wiersze dzielą się także na:

- stałe, czyli takie, które pojawiają się każdemu subskrybentowi, choć nie zawsze składają się z takich samych tytułów. Przykładami mogą być: “Popularne teraz”, “Oglądaj dalej”, “Nowości” czy “Top 10 w Polsce”,
- o spersonalizowanej treści, czyli takie, które wyświetlają się konkretnym subskrybentom ze względu na historię korzystania z platformy. Przykładami mogą być wiersze złożone według często oglądanych gatunków filmowych, o podobnej tematyce czy “podobne do <tutaj tytuł obejrzanego filmu/serialu/programu>”

Wybór takiej budowy strony startowej ułatwia użytkownikom poruszanie się po niej, a także wyświetla wiele propozycji na małej i ograniczonej powierzchni wyświetlacza czy monitora. Pozwala również szybko pominąć produkcje, których nie chcemy w danym momencie oglądać.

Podstawowym wyznacznikiem grupowania filmów jest ich gatunek, podgatunek czy inne metadane wideo, takie jak na przykład data premiery. Grupy mogą być tworzone również na podstawie informacji behawioralnych (choćby z algorytmów wspólnego filtrowania), filmów które zdaniem witryny użytkownik prawdopodobnie odtworzy, a nawet według filmów oglądanych przez znajomego (Alvino & Basilico, 2015).

Wiersze są filtrowane, aby usunąć wcześniej obejrzone produkcje oraz oceniane według indywidualnych zainteresowań. Podobnie jak rzędy, także tytuły w nich ułożone są według spersonalizowanego rankingu, więc na początku zestawu można znaleźć potencjalnie najbardziej interesujące materiały dla subskrybenta. Po złożeniu wierszy w całość wykonywane jest ponowne filtrowanie, dzięki któremu likwidowane są powtarzające się filmy. Finalnie rzędy oraz cała strona główna są formatowane przez system do rozmiaru odpowiadającemu używanemu aktualnie urządzeniu.



Rysunek 7 Model nawigacji na stronie głównej Netflix, Źródło: (C. Alvino, J. Basilico, 2015)

Jak można przeczytać na oficjalnym blogu Netflix, wyzwaniem jest nie tylko wybranie i posegregowanie na jednej stronie od 10 do 40 wierszy z możliwych dziesiątek tysięcy, ale także połączenie pomocy w “odkrywaniu” przez użytkownika nowości i ułatwienia oglądania kolejnych odcinków rozpoczętego serialu/programu czy powrotu do dawno obejrzanych treści. Rekomendacje te powinny jednocześnie odpowiadać indywidualnym gustom subskrybenta i pokazywać zróżnicowane tematycznie materiały, żeby objąć spektrum zainteresowań, a nie jedynie skupiać się na jego pojedynczych elementach. Netflix ciągle pracuje nad ulepszaniem swoich algorytmów tworzenia strony głównej oraz rekomendacji. Między innymi rozważany jest problem, kiedy powinno się brać pod uwagę inne zmienne takie, jak pora dnia czy to, z jakiego urządzenia się korzysta (Alvino & Basilico, 2015).

1.5. Tworzenie poszczególnych wierszy strony głównej

1.5.1. Wiersze grup tematycznych - PVR (Personalized Video Ranker)

Na stronie głównej znajduje się szereg zbudowany z około 40 rzędów, w których umieszczone jest do 75 tytułów pochodzących z jednego spersonalizowanego algorytmu

rekomendacyjnego (rankingowego). Liczba wyświetlanych wierszy i tytułów może być różna w zależności od rodzaju urządzenia, z którego aktualnie korzystamy. Algorytm porządkuje grupy tematyczne produkcji (lub podzbiory wybrane według gatunku, podgatunku bądź innego filtrowania) osobno dla każdego użytkownika, co powoduje wyświetlanie innych zbiorów tytułów na różnych kontach, nawet w wierszach o tych samych nazwach. Często spersonalizowane materiały mieszane są w rankingu z produkcjami popularnymi w danej grupie, co pozwala na odkrywanie nowych treści. Ponadto zestaw wierszy odświeża się i zmienia przy każdym uruchomieniu strony głównej (Gomez-Uribe & Hunt, 2016).

1.5.2. “Wybrane dla <nazwa użytkownika>” - Top-N Video Ranker

W tym wierszu umieszczane są tytuły, które według algorytmu o nazwie ‘Top-N Video Ranker’ są najlepiej spersonalizowanymi rekomendacjami w całym katalogu Netflixa. W przeciwieństwie do PVR nie ogranicza się do wybranych podzbiorów bazy, w związku z czym rząd może składać się z treści z różnych grup tematycznych, które nie odznaczają się między sobą podobieństwem ani nie są specjalnie filtrowane. Poza tym, podobnie jak poprzedni ranker, Top-N łączy treści wybrane wyłącznie za pomocą informacji o użytkowniku z tymi najbardziej popularnymi, a także uwzględnia trendy oglądania w różnych ramach czasowych takich, jak pora roku czy dnia, a nawet urządzenie, z którego subskrybent jest połączony. W związku z tym wiersz “Wybrane dla” wyświetla inne tytuły również podczas jednoczesnego uruchomienia przez użytkownika witryny na większej liczbie urządzeń (Gomez-Uribe & Hunt, 2016).

1.5.3. “Popularne teraz”

Jest to wiersz składający się z tytułów wybranych na podstawie krótkoterminowych trendów czasowych (od kilku minut do kilku dni). Są to treści, które mogą nawiązywać do (Gomez-Uribe & Hunt, 2016):

- wyjątkowych aktualnych zdarzeń, jednorazowych wypadków, unikalnych trendów w świecie realnym, przykładami mogą być katastrofy przyrodnicze, które zwiększają oglądalność filmami dokumentalnymi i katastroficznymi czy jak w przypadku ogólnoświatowej epidemii, kiedy odnotowano wzrost zainteresowania filmami o tematyce pandemicznej oraz zdrowotnej,

- powtarzających się wzorców w czasie (np. co roku) bądź sezonowości ze względu na pory roku, tutaj możemy zwrócić uwagę między innymi na zainteresowanie filmami świątecznymi w okresie świąt bożego narodzenia, komediami romantycznymi w lutym w czasie walentynek czy filmami nawiązującymi do wakacji w lato.

1.5.4 „Oglądaj dalej”

W przeciwieństwie do większości rzędów, „oglądaj dalej” nie zawiera tytułów jeszcze nie obejrzanych ani nie sortuje ich według rankingów. Pamiętając, że na platformie Netflix poza filmami pełnometrażowymi można znaleźć także programy sezonowe (np. teleturnieje i programy typu reality show) oraz seriale, należało stworzyć wiersz, w którym użytkownik w szybki sposób będzie mógł odnaleźć rozpoczęte produkcje. Dodawane tutaj treści to zarówno oglądane aktualnie materiały w odcinkach, a także filmy, które nie zostały obejrzane w całości. W ten sposób użytkownik ma możliwość kontynuowania w miejscu, w którym skończył oglądać podczas poprzedniej sesji. Tworząc kolejność w wierszu, system kieruje się:

- algorytmem oceniającym, czy użytkownik zamierza wznowić oglądanie bądź ponownie wrócić do serialu, który otrzymał właśnie nowy sezon. Informacje, na których bazuje ten algorytm, to między innymi punkt porzucenia tytułu (np. początek/środek/koniec filmu, numer sezonu i odcinka), ile i jakie produkcje były oglądane w późniejszym czasie oraz jakie urządzenia były używane do oglądania poszczególnych tytułów,
- czasem, jaki upłynął od ostatniego oglądania. Jeśli użytkownik kontynuuje jednocześnie kilka produkcji sortowane są one w kolejności od wyświetlanych niedawno do tych, oglądanych wcześniej,
- premierą nowych sezonów obejrzanych seriali i programów rozrywkowych. W momencie, kiedy subskrybent, skończył oglądanie jakiegoś materiału, a na platformę został dodany kolejny jego sezon, to tytuł jest wyświetlany w pierwszej kolejności w wierszu „oglądaj dalej”.




Rysunek 8 Przykładowy wiersz typu „oglądaj dalej”, Źródło: opracowanie własne [czerwiec 2021 r.]

Jest to rząd korzystający z największej liczby metod matematycznych oraz statystycznych, a także analizujący znaczną ilość danych wejściowych. Wyróżnia się też wyglądem, ponieważ nie zawiera jedynie okładki tytułów, ale również punkt porzucenia tytułu w postaci paska oglądania oraz numeru sezonu i odcinka w przypadku seriali czy programów rozrywkowych (Gomez-Uribe & Hunt, 2016).

1.5.5. “Podobne do <tytuł>” lub “Propozycje po obejrzeniu: <tytuł>”, lub “Ponieważ lubisz: <tytuł>” - Video-Video Similarity

Są to wiersze skategoryzowane w zupełnie inny sposób. Wybierane są tytuły, które użytkownik oglądał w przeszłości, następnie algorytm podobieństwa wideo-wideo kieruje się rekomendacjami i poleca filmy o podobnych cechach.



Rysunek 9 Przykładowy wiersz typu Video-Video Similarity, Źródło: opracowanie własne [czerwiec 2021 r.]

Jest to typ wierszy, które nie zawierają spersonalizowanych treści, a kolejność wyświetlanych tytułów jest tworzona na podstawie ich podobieństw do obejrzanego filmu czy serialu. Mimo, że zawartość rzędu nie jest personalizowana to sam rząd ma już cechy personalizacji, ponieważ produkcja, do której algorytm szuka podobieństwa jest wybierana w drodze selekcji najbardziej lubianych przez użytkownika tytułów czy tych oglądanych aktualnie (Gomez-Uribe & Hunt, 2016).

1.5.6. “Moja lista”

Jest to wiersz zawierający tytuły, które użytkownik manualnie dodał do listy ulubionych. W ten sposób każdy subskrybent może samodzielnie wpływać na algorytm rekomendacyjny. Kolejność wyświetlania materiałów jest zgodna z ich zapisywaniem.

1.5.7. “Obejrzyj ponownie”

Jest to wiersz podobny do wiersza “moja lista”. Znaczącą różnicą jest fakt, że tytuły znajdujące się na tej liście nie są dodawane manualnie przez użytkownika, a wybierane przez system z produkcji, które zostały już obejrzone w przeszłości. Kolejność wyświetlanych okładek jest zależna od aktualnych trendów, premier, czasu, kiedy tytuł został obejrany czy aktualnych działań subskrybenta, które odnotowano na witrynie.

1.5.8. “Top 10 w <nazwa państwa> dzisiaj”

Jest to wiersz niespersonalizowany, którego algorytm tworzenia polega jedynie na wyświetleniu najczęściej oglądanych tytułów w konkretnym państwie danego dnia. W rzędzie widoczny jest stworzony ranking kolejno od pierwszego miejsca, które wyznacza najpopularniejszy (ze względu na liczbę oglądalności) tytuł, do dziesiątego miejsca. Zawartość wiersza jest dokładnie taka sama dla każdego użytkownika w danym państwie.

1.6. Podsumowanie

W powyższym rozdziale zawarto najważniejsze informacje dotyczące platform streamingowych, w szczególności Netflixa, działania algorytmów rekomendacyjnych, ich składowych oraz procesu tworzenia strony głównej.

Platformy strumieniowe stały się popularnym rodzajem rozrywki, który wypiera tradycyjną telewizję. Netflix jest firmą, będącą prekursorem w tej dziedzinie na światową skalę.

Warto podkreślić, że nadal trwają prace nad ulepszaniem działania algorytmów. Mimo, że polecane materiały są różne dla każdego konta, to mechanizmy tworzące wiersze na stronie startowej oraz wyświetlające tytuły w wyszukiwarce są jednakowe. Algorytmy zasilane są wieloma metadanymi, które zawierają informacje dotyczące sposobu korzystania z platformy, urządzeń, na których użytkownik ogląda materiały czy pora dnia.

Ważnymi pojęciami są tagi oraz hasła wyszukiwania, ponieważ to one są podstawą do oceniania podobieństwa poszczególnych tytułów i to właśnie grupy tagów, a także wpisywane przez użytkownika teksty są głównymi zmiennymi w zaimplementowanych algorytmach.

Najwięcej algorytmów rekomendacyjnych zawartych jest na stronie głównej, która zbudowana jest z rzędów, a te z okładek poszczególnych tytułów. Można rozróżnić osiem różnych typów rzędów, które różnią się sposobem ich tworzenia oraz zawartością.

Kolejne rozdziały skupione są na ocenie skuteczności oraz użyteczności algorytmów rekomendacyjnych na Netflixie.

2. Metodyka badawcza i model

W drugim rozdziale zawarto opis przeprowadzonego badania. Zaprezentowano poszczególne konstrukty, a także stworzony model. Skorzystano również z wyników analiz, aby potwierdzić lub odrzucić postawione hipotezy. Użyto w tym celu dedykowanego dla wybranej metodyki oprogramowania – SmartPLS3, dzięki któremu uzyskano wartości poszczególnych ścieżek modelu i możliwe było stworzenie tabel i wykresów wizualizujących wyniki.

2.1. Metodyka wykorzystana w badaniu

Przedmiotem badania była subiektywna opinia użytkowników platformy streamingowej Netflix na temat użyteczności algorytmów rekomendacyjnych na wspomnianym serwisie oraz satysfakcji z wyświetlania spersonalizowanych wyników. Badanie składało się z następujących etapów:

- stworzenie modelu strukturalnego opisującego badane zjawisko,
- stworzenie pytań ankietowych zadawanych użytkownikom,
- zebranie danych ankietowych,
- analiza wyników z wykorzystaniem programu SmartPLS3.

Kwestionariusz powstał przy pomocy platformy Google Forms, a pytania ankietowe zostały stworzone w taki sposób, aby odpowiedzi można było udzielić korzystając z siedmiostopniowej skali Likerta. Pozwoliło to zebrać dane liczbowe, odnoszące się do pozornie niemierzalnych opinii oraz skwantyfikować wyniki.

W kolejnym etapie posłużono się metodologią modelowania równań strukturalnych (z ang. Structural Equation Modeling – SEM), czyli technika badań ilościowych, wykorzystująca także metody jakościowe. SEM wykorzystuje się, aby przedstawić związki przyczynowe między zmiennymi (Schumacker & Lomax, 2015). Wykonywane analizy określają stopień, w jakim stworzony model teoretyczny jest wyjaśniany przez dane empiryczne, a kiedy model potwierdza hipotezy występuje możliwość przeprowadzenia bardziej złożonych badań i wyciągnięcia wiarygodnych wniosków (Ullman & Bentler, 2003).

2.1.1. Korzystanie i rekomendacja

Charakterystyka każdego użytkownika Netflix jest zależna od sposobu oraz częstotliwości korzystania z platformy. Społeczność marki można zaobserwować na profilach w mediach społecznościowych. Jest to zbiór ludzi, których łączą wspólne zainteresowanie daną marką, tworzący wokół marki subkulturę z własnymi wartościami, mitami, hierarchią, rytuałami czy słownictwem. Przynależność do takiej społeczności powoduje większe zaangażowanie się i przywiązanie. Należy również pamiętać o istnieniu użytkowników pasywnych, którzy czytają informacje i podejmują na tej podstawie decyzje (Latiff & Safiee, 2015).

Konstrukt został stworzony w celu zbadania przywiązania ankietowanych do marki, chęci polecenia jej osobom bliskim, a także sprawdzenia czy tytuły oglądane na platformie są wybierane na podstawie ich znajomości lub zaciekawieniem okładką.

H1: Korzystanie i rekomendacja ma wpływ na personalizację wyświetlanych wyników. Wpływ ten jest istotny.

2.1.2. Personalizacja

Personalizacja to zbiór działań, które prowadzą do dostarczenia treści oraz sposobu jej prezentacji specjalnie dla danego klienta. Istnieje wiele możliwości indywidualizacji przekazywanych informacji, nabierających w zdaniu odbiorców osobistego charakteru i wpływających pozytywnie na wzrost zainteresowania adresata odbieraną informacją. Kiedy prezentowane komunikaty są dopasowane do wymogów konkretnego klienta, wzrasta jego zainteresowanie oraz ma to pozytywny wpływ na odbiór przygotowanej oferty (Jelonek, 2014).

Konstrukt został stworzony w celu zbadania wiedzy ankietowanych oraz ich odbiór w temacie personalizacji propozycji w wyniku działania algorytmów rekomendacyjnych na platformie. Sprawne działanie algorytmów powinno działać pozytywnie na użyteczność strony głównej oraz wyszukiwarki.

H2: Personalizacja ma istotny wpływ na użyteczność wyszukiwarki.

H3: Personalizacja wpływa na satysfakcję. Wpływ ten jest istotny.

H4: Personalizacja ma pozytywny i istotny wpływ na użyteczność.

2.1.3. Satysfakcja

Według definicji satysfakcja to osąd, że cecha produktu bądź usługi, a także sam produkt czy usługa, zapewnia (lub zapewnił) przyjemny poziom spełnienia związanego z konsumpcją, w tym także niedostateczne lub nadmiernie spełnienie. Ponadto satysfakcja to uczucie oraz krótkotrwała postawa, która może się łatwo zmienić, biorąc pod uwagę różne okoliczności. Poczucie satysfakcji to stan umysłu oraz nastawienie. Można mówić o „mieszanych uczuciach”, ponieważ konsument bądź użytkownik może mieć różny poziom satysfakcji z różnych części produktu czy usługi (Hom, 2000).

Konstrukt został stworzony w celu zbadania poziomu poczucia satysfakcji z możliwych opcji wyszukiwania i wybierania tytułów na platformie Netflix oraz wyświetlanych propozycji w wyniku działania algorytmów rekomendacyjnych.

H5: Satysfakcja wpływa na użyteczność strony głównej. Wpływ ten jest istotny.

H6: Satysfakcja ma istotny wpływ na użyteczność wyszukiwarki.

2.1.4. Użyteczność strony głównej

Użyteczność to własność, która wskazuje, że przedmiot rozważań ma tendencję do przynoszenia korzyści, przyjemności, dobra lub szczęścia odbiorcom. Można również wspomnieć, że jest to cecha przedmiotu, sprowadzająca się do zapobiegania wydarzeniu się krzywdy, bólu, zła lub nieszczęścia stronie, której interes jest uwzględniony. „Zasada użyteczności” mówi o tym, że należy działania oceniać na podstawie ich użyteczności, czyli skłonności do przynoszenia korzyści czy zadowolenia (Broome, 1991).

Konstrukt powstał w celu zbadania użyteczności strony głównej, w tym użyteczności algorytmów rekomendacyjnych, które działają podczas tworzenia strony głównej oraz wyświetlania propozycji użytkownikom platformy streamingowej.

2.1.5. Użyteczność wyszukiwarki

Użyteczność wyszukiwarki tak, jak i poprzedni konstrukt został stworzony w celu zbadania użyteczności wyszukiwarki, a dokładniej wyniku działania algorytmów rekomendacyjnych odpowiedzialnych za wyświetlanie spersonalizowanej kolejności tytułów podczas korzystania z wbudowanej wyszukiwarki na platformie streamingowej Netflix.

2.2. Model teoretyczny

Modelowanie równań strukturalnych zostało przeprowadzone w programie SmartPLS3, zatem rezultaty są wynikami algorytmów PLS-SEM. Metoda ta składa się z kilku kluczowych etapów: w pierwszej kolejności należy ocenić słuszność wykorzystanych konstruktów i zmiennych, następnie można przystąpić do szacowania modelu strukturalnego. W pracy wykorzystano następujące opcje: algorytm PLS z domyślnymi ustawieniami konfiguracji (schemat ważenia: centroidalny, maksymalna ilość iteracji: 300, kryterium zatrzymania: 10^{-X} z wybraną 7), bootstrap z 5000 podpróbkami dla wersji pełnej ze skorygowanym odchyleniem i przyspieszeniem w rozkładzie dwustronnym oraz blindfolding w wersji domyślnej (pominięcie odległości: 7). Ostatnim etapem jest analiza wielogrupowa, która w badaniu została przeprowadzona dla grup odpowiadającej płci ankietowanych oraz z podziałem użytkowników ze względu na częstotliwość korzystania z platformy.

2.2.1. Modelowanie dla zmiennych refleksyjnych

Kiedy pracujemy ze zmiennymi typu refleksyjnego należy rozpocząć pracę od sprawdzenia ładunków wskaźników. Kiedy wartość ładunku jest powyżej 0,7, oznacza to, że konstrukt odpowiada na przynajmniej 50% wariancji wskaźnika oraz że charakteryzuje się odpowiednim poziomem wiarygodności. Możemy wtedy powiedzieć, że zmienna jest trafna. W tym celu sprawdza się również średnią wyjaśnioną wariancję (AVE), pomaga to w określeniu czy konstrukt tłumaczy 50% wariancji danych, a jej wartość powinna być większa od 0,50 (Sarstedt et al., 2021).

Kolejny krok to oszacowanie rzetelności spójności wewnętrznej, której wartości powinny się znaleźć w przedziale między 0,6 a 0,95. Należy także sprawdzić czy wartości nie są zbyt wysokie, ponieważ wyniki powyżej górnej granicy uznaje się za problematyczne, gdyż sugerują identyczność danych oraz nadmiarowość konstruktów. Rzetelność zmiennych jest sprawdzana na podstawie alfy Cronbacha – dolna granica, rzetelności kompozytowej – górna granica, a

także współczynnika rzetelności - którego wartości są pomiędzy alfą Cronbacha i rzetelnością kompozytową (Sarstedt et al., 2021).

Ostatnim krokiem jest oszacowanie współczynnika HTMT, czyli stosunek cech niejednorodnych do jednorodnych. Wskaźnik ten pokazuje czy konstrukt jest wystarczająco różny od pozostałych. Dla podobnych konstruktów modelu wartością graniczną jest 0,90, natomiast dla różnych konstruktów 0,85 (Sarstedt et al., 2021).

2.2.2. Modelowanie dla zmiennych kształtujących

Podczas pracy przy zmiennych kształtujących należy podjąć inne kroki niż przy pracy ze zmiennymi refleksyjnymi. Rozpoczynamy od zbadania trafności zbieżnej, która jest ustalana na podstawie korelacji zmiennej kształtującej ze zmiennymi refleksyjnymi. Wartość ta informuje czy wskaźniki konstruktów są z nim skorelowane czy z innym. Następnym etapem jest ocena kolinearności, którą dokonuje się za pomocą wartości współczynnika inflacji wariancji (VIF). Im wyższe wartości VIF, tym wskaźniki charakteryzują się wyższym poziomem współliniowości. Wyniki przekraczające granicę równą 5 są niepożądane, ponieważ oznaczają to, że zbyt wiele zmiennych jest zbędnych (Sarstedt et al., 2021).

W odróżnieniu do zmiennych refleksyjnych zamiast ładunków należy sprawdzić wagi. Wartości bliższe zeru oznaczają słabe relacje, natomiast te bliżej +1 lub -1 – silne relacje pozytywne lub negatywne. Wskaźniki o słabej relacji należy odrzucić z modelu, aby poprawić jego precyzję, wyjątkiem są wskaźniki których ładunek wynosi powyżej 0,5 (Sarstedt et al., 2021).

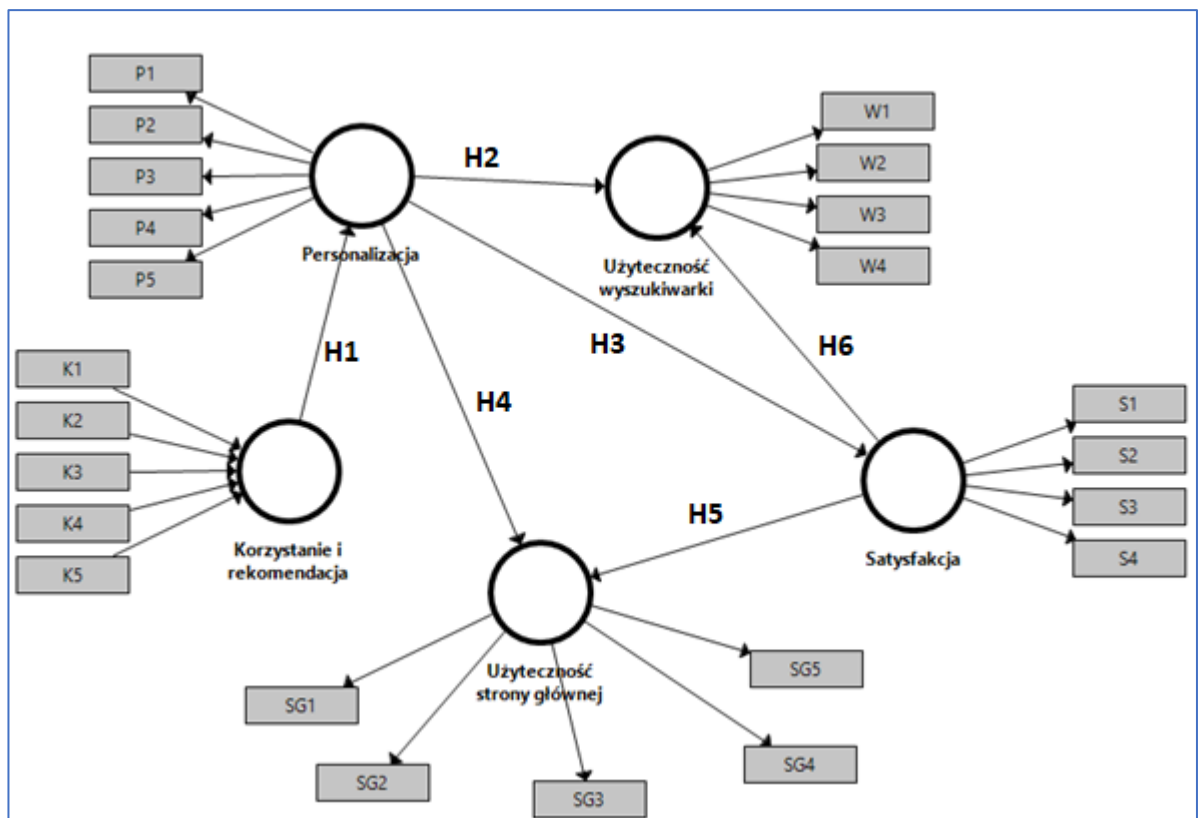
2.2.3. Szacowanie modelu strukturalnego

Po zakończeniu modelowania dla zmiennych refleksyjnych oraz kształtujących należy przejść do oszacowania modelu strukturalnego. Rozpoczynamy od zbadania możliwości predykcyjnych modelu za pomocą współczynnika determinacji R^2 , współczynnika krzyżowej redundancji Q^2 i współczynników ścieżek (Sarstedt et al., 2021).

Współczynnik determinacji zawiera się w granicach od 0 do 1, a od 0,75 uważa się go za istotny, zaś od 0,5 umiarkowany – im wyższa wartość, tym wyższa precyzja modelu. Natomiast współczynnik krzyżowej redundancji pozwala na analizę jakości miar w równaniach. Wartość powyżej zera jest ważna dla predykcji modelu oraz wraz z jej wzrostem, wzrasta także dokładność predykcji (Sarstedt et al., 2021).

Ostatnim wskaźnikiem są współczynniki ścieżek, które odwzorowują relacje pomiędzy konstruktami modelu. Wartości zawierają się w przedziale od -1 do +1, a im wartość jest bliżej granic przedziału tym zachodzi większy związek – bliżej -1 jest on negatywny, zaś bliżej +1 pozytywny (Sarstedt et al., 2021).

2.2.4. Model



Rysunek 10 Model teoretyczny zależności czynników wpływających na użyteczność i efektywność algorytmów rekomendacyjnych na Netflixie.

Stworzony podczas przeprowadzania badania model składa się z 5 konstrukcyjnych, opisanych dokładniej w poprzednim podrozdziale: korzystanie i rekomendacja, personalizacja, satysfakcja oraz użyteczność wyszukiwarki i strony głównej.

Powstały model teoretyczny ma pomóc przy badaniu satysfakcji użytkowników z wyświetlanych propozycji na platformie, co przekłada się na użyteczność i efektywność zastosowanych algorytmów rekomendacyjnych. Założono, że korzystanie i rekomendacja ma wpływ na personalizację wyników, a ta wraz z odczuwaną satysfakcją oddziałuje na użyteczność strony głównej oraz wyszukiwarki.

2.2.5. Konstrukty i zmienne

W poniższej tabeli zawarto konstrukty wraz z opisującymi je zmiennymi, a także akronimy, które pojawiły się w przeprowadzanej podczas badania ankiecie.

Konstrukt	Zmienna	Akronim zmiennej
Korzystanie i rekomendacja	K1	Chętniej oglądam tytuły, które mają ciekawą okładkę.
	K2	Śledzę nowości dodawane na Netflixu.
	K3	Oglądam tylko tytuły, które znam lub kojarzę.
	K4	Śledzę informacje dodawane na social mediach Netflixu.
	K5	Chętnie polecę Netflixu znajomemu lub rodzinie.
Personalizacja	P1	Uważam, że wyniki w wyszukiwarce Netflixu są spersonalizowane do konta, z którego korzystam.
	P2	Uważam, że strona główna ma wiersze wybrane indywidualnie dla każdego użytkownika.
	P3	Uważam, że kolejność tytułów w poszczególnych wierszach strony głównej NIE jest taka sama dla każdego użytkownika.
	P4	Uważam, że zawartość wierszy na stronie głównej NIE jest taka sama dla każdego użytkownika.
	P5	Uważam, że dużo wiem o algorytmach polecenia na Netflixie.
Satysfakcja	S1	Uważam, że propozycje na stronie głównej są trafione.
	S2	Uważam, że wyniki wyszukiwania w wyszukiwarce są trafione.
	S3	Jestem zadowolony/a ze sposobów wyszukiwania i wybierania tytułów na Netflixie.
	S4	Uważam, że Netflix posiada wszystkie funkcjonalności wyszukiwania, których bym oczekiwał(a).
Użyteczność strony głównej	SG1	Najczęściej szukuję tytułów na stronie głównej.
	SG2	Najwięcej czasu spędzam na stronie głównej (poza oglądaniem materiałów).
	SG3	Podoba mi się budowa strony głównej Netflixu.
	SG4	Uważam, że strona główna Netflixu wyróżnia się w porównaniu do innych platform streamingowych.
	SG5	Korzystanie ze strony głównej jest intuicyjne i przyjemne.
Użyteczność wyszukiwarki	W1	Najczęściej szukuję tytuły za pomocą wyszukiwarki na platformie.
	W2	Podoba mi się działanie wyszukiwarki Netflixu.
	W3	Uważam, że wyszukiwarka Netflixu działa szybko i skutecznie.
	W4	Uważam, że sposób prezentacji wyników wyszukiwania jest czytelny.

Tabela 1 Konstrukty, zmienne oraz akronimy zmiennych użyte w badaniu

2.3. Wyniki badania

Kolejne podrozdziały opisują charakterystykę demograficzną badanej grupy użytkowników platformy streamingowej Netflix oraz wyniki badania zrealizowanego za pomocą programu SmartPLS 3. W trakcie pracy użyto opcji: algorytm PLS z domyślnymi ustawieniami początkowymi (centroidalny schemat ważenia, maksymalna ilość iteracji równa 300 i kryterium zatrzymania równe 10^{-7}), bootstrap wykonany na 500 próbkach z poziomem istotności równym 0,05, blindfolding z dystansem między pominięciami równym 7 oraz algorytm MGA (Multigroup Analysis).

2.3.1. Charakterystyka demograficzna badanej grupy

Aby dotrzeć do użytkowników Netflixa, opublikowano utworzoną wcześniej ankietę na grupach tematycznych w serwisie społecznościowym Facebook, które gromadzą społeczność zainteresowaną materiałami dostępnymi na Netflixie. Dodatkowo ankietę rozesłano osobom znajomym, posiadającym swoje konta na tej platformie streamingowej. Jedynym warunkiem wzięcia udziału w badaniu było korzystanie z usług dostępnych na Netflixie.

Ostatecznie odpowiedzi udzieliły 274 osoby, w tym 173 osoby (63,1%) posiadające własne konto na platformie oraz 101 osób (36,9%) korzystających z konta osoby znajomej. Ponad połowa ankietowanych, bo aż 64,2%, to kobiety. A badaniu wzięły udział osoby należące do każdej z wyodrębnionych grup wiekowych, a zdecydowana większość grupy (75,6%) to osoby młode – poniżej 27 lat. Znając wiek ankietowanych, nie jest dziwne, że ponad połowa (68,6%) posiada wykształcenie średnie lub podstawowe.

Ostatnią część ankiety stanowiły pytania dotyczące częstotliwości użytkowania oraz rodzaju oglądanych treści. Okazuje się, że zdecydowana większość osób (64,6%) korzysta z Netflixa tylko 1-3 razy w tygodniu, natomiast liczba użytkowników, oglądających tytuły na platformie 4-6 razy w tygodniu (18,2%) jest niewiele większa od liczby osób robiących to codziennie (17,2%). Najczęściej oglądane na platformie są seriale fabularne (49,3%) oraz filmy fabularne (23%).

Dokładną charakterystykę badanej grupy przedstawia poniższa tabela.

Płeć	Liczba ankietowanych	Procent
Kobieta	176	64,2%
Mężczyzna	92	33,6%
Nie chcę podawać	6	2,2%
Wykształcenie	Liczba ankietowanych	Procent
Podstawowe	28	10,2%
Zasadnicze zawodowe	3	1,1%
Średnie	160	58,4%
Wyższe	83	30,3%
Wiek	Liczba ankietowanych	Procent
Poniżej 18 lat	35	12,8%
18-27 lat	172	62,8%
28-37 lat	19	6,9%
38-47 lat	26	9,5%
48-57 lat	17	6,2%
Powyżej 57 lat	5	1,8%
Własne konto	Liczba ankietowanych	Procent
Tak	173	63,1%
Korzysta z konta osoby znajomej	101	36,9%
Najczęściej oglądane	Liczba ankietowanych	Procent
Filmy fabularne	63	23%
Seriale fabularne	135	49,3%
Filmy i seriale dokumentalne	28	10,2%
Inne	48	17,5%
Częstotliwość oglądania	Liczba ankietowanych	Procent
1-3 razy w tygodniu	177	64,6%
4-6 razy w tygodniu	50	18,2%
codziennie	47	17,2%

Tabela 2 Charakterystyka demograficzna badanej grupy

2.3.2. Wyniki oceny zmiennych

Pierwszym etapem badania jest analiza trafności zmiennych refleksyjnych. W tym celu sprawdzono wartości ich ładunków:

Konstrukt	Zmienna	Ładunek
Personalizacja	P1	0,830
	P2	0,794
	P3	0,643
	P4	0,675
	P5	0,625
Satysfakcja	S1	0,751
	S2	0,737
	S3	0,899
	S4	0,784
Użyteczność strony głównej	SG1	0,487
	SG2	0,524
	SG3	0,846
	SG4	0,722
	SG5	0,844
Użyteczność wyszukiwarki	W1	0,459
	W2	0,900
	W3	0,905
	W4	0,843

Tabela 3 Wartości ładunków zmiennych refleksyjnych

Na podstawie wyników można zauważyć, że dla pięciu zmiennych refleksyjnych ładunki są zbyt niskie. Są to zmienne P3, P5, SG1, SG2 oraz W1. Dla zmiennej P4 ładunek również jest niższy od przyjętego 0,7, jednak wartość ta jest wystarczająco bliska progu wejścia, aby zmienna mogła pozostać w modelu.

Kolejnym krokiem jest ocena rzetelności spójności wewnętrznej oraz średniej wyjaśnionej wariancji (AVE):

Konstrukt	Alfa Cronbacha	Rho_A	Rzetelność kompozytowa	AVE
Personalizacja	0,771	0,815	0,840	0,516
Satysfakcja	0,804	0,817	0,872	0,632
Użyteczność strony głównej	0,745	0,801	0,822	0,492
Użyteczność wyszukiwarki	0,797	0,874	0,869	0,637

Tabela 4 Wartości rzetelności zmiennych refleksyjnych

Jak widać wartości średniej wyjaśnionej wariancji (AVE) za wyjątkiem wyniku dla użyteczności strony głównej są na zadowalającym poziomie. Można zakładać, że przyczyną tego są zmienne SG1 oraz SG2, których ładunki były zbyt niskie, co skłania do usunięcia ich z modelu dla poprawienia precyzji. Ponadto wszystkie wartości wskaźników rzetelności dla każdego z konstruktów są na zadowalającym poziomie, dlatego mimo niskich ładunków zmienne P3, P5 oraz W1 pozostają w modelu.

Ostatnim krokiem podczas sprawdzania trafności zmiennych refleksyjnych jest analiza współczynnika HTMT, który pozwala na ocenę trafności różnicowej:

	Personalizacja	Satysfakcja	Użyteczność strony głównej
Satysfakcja	0,615		
Użyteczność strony głównej	0,425	0,694	
Użyteczność wyszukiwarki	0,381	0,820	0,463

Tabela 5 Macierz wartości HTMT

Jak można zauważyć żadna z wartości nie osiągnęła wartości krytycznej 0,85, co oznacza, że wszystkie konstrukty są od siebie niezależne.

Po usunięciu zmiennych SG1 oraz SG2 przystępuję do ponownej analizy modelu.

Konstrukt	Alfa Cronbacha	Rho_A	Rzetelność kompozytowa	AVE
Personalizacja	0,771	0,815	0,840	0,516
Satysfakcja	0,804	0,817	0,872	0,632
Użyteczność strony głównej	0,779	0,783	0,873	0,697
Użyteczność wyszukiwarki	0,797	0,874	0,869	0,637

Tabela 6 Wartości rzetelności zmiennych refleksyjnych po usunięciu zmiennych

Na podstawie ponownie przeprowadzonych algorytmów można zauważyć, że po usunięciu dwóch zmiennych wartość średniej wyjaśnionej wariancji (AVE) dla użyteczności strony głównej uległ poprawie i jest na zadowalającym poziomie. Trzy zmienne posiadają ładunek poniżej progu 0,7 (co widać w tabeli 7), jednak nie wpływa to na rzetelność konstruktów, zatem pozostają w modelu.

Konstrukt	Zmienna	Ładunek
Personalizacja	P1	0,832
	P2	0,795
	P3	0,643
	P4	0,674
	P5	0,622
Satysfakcja	S1	0,748
	S2	0,738
	S3	0,899
	S4	0,785
Użyteczność strony głównej	SG3	0,872
	SG4	0,749
	SG5	0,877
Użyteczność wyszukiwarki	W1	0,459
	W2	0,900
	W3	0,905
	W4	0,843

Tabela 7 Wartości ładunków zmiennych refleksyjnych po usunięciu zmiennych

W ostatnim etapie sprawdzamy ponownie jak rozkładają się wartości w macierzy współczynnika HTMT.

	Personalizacja	Satysfakcja	Użyteczność strony głównej
Satysfakcja	0,615		
Użyteczność strony głównej	0,434	0,752	
Użyteczność wyszukiwarki	0,381	0,820	0,549

Tabela 8 Macierz wartości HTMT po usunięciu zmiennych

Jak widać nadal żadna z wartości nie przekroczyła granicy 0,85, co świadczy o tym, że konstrukty są od siebie niezależne.

Na końcu przeanalizowano wartości współczynnika VIF dla zmiennych kształtujących, w celu zbadania poziomu kolinearności.

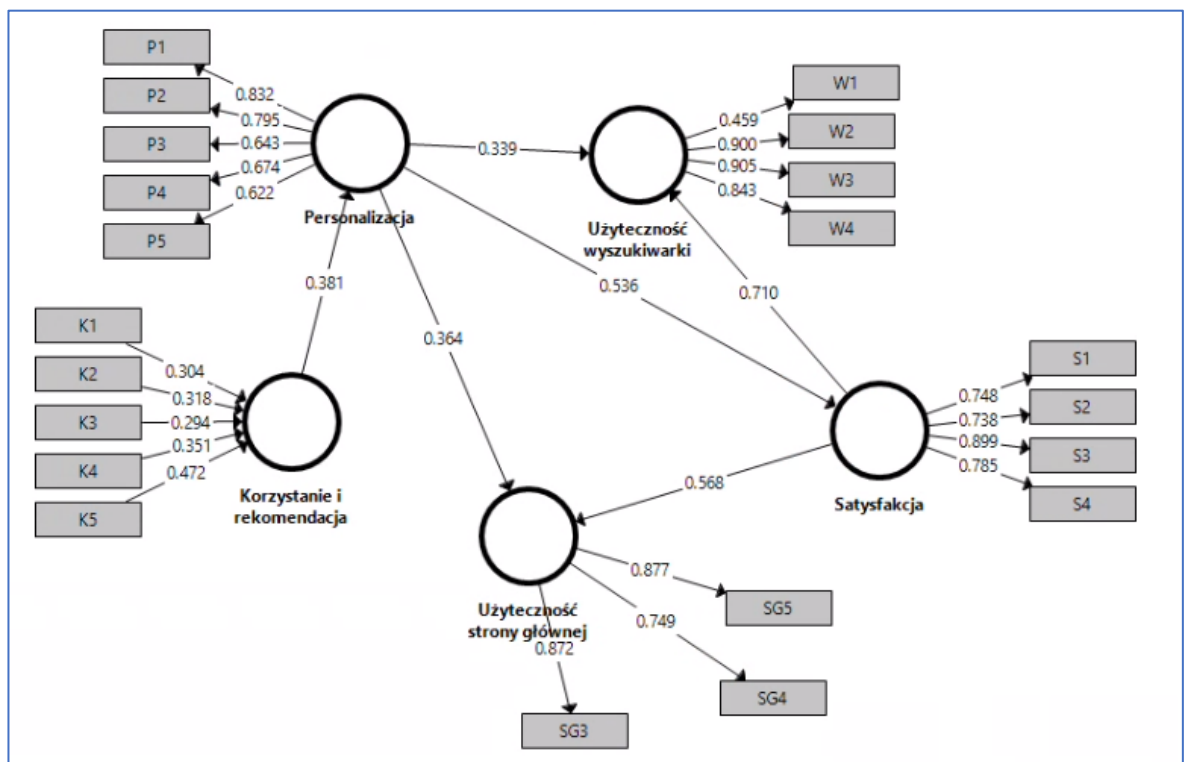
Konstrukt	Zmienna	VIF
Korzystanie i rekomendacja	K1	1,116
	K2	1,289
	K3	1,038
	K4	1,218
	K5	1,332

Tabela 9 Wartości VIF dla zmiennych kształtujących

Jak można zauważyć wszystkie wartości współczynnika VIF dla zmiennych kształtujących są poniżej 5, co oznacza, że nie zachodzi kolinearność – nie ma zbędnych zmiennych w modelu.

2.3.3. Wyniki oszacowania modelu

Po usunięciu zbędnych zmiennych model wraz z oszacowanymi współczynnikami prezentuje się następująco:



Rysunek 11 Model z oszacowanymi współczynnikami

Na rysunku 11 możemy zauważyć, że najsilniejsze związki występują pomiędzy odczuwaną satysfakcją a użytecznością wyszukiwarki i strony głównej, natomiast najslabszy związek zachodzi pomiędzy personalizacją a użytecznością wyszukiwarki.

Kolejnym etapem w badaniu jest analiza wyników oszacowania na podstawie ścieżek w modelu oraz ocena hipotez odwzorowanych za pomocą konkretnych ścieżek:

Hipoteza	Ścieżka	Współczynnik ścieżki	Odchylenie standardowe	Statystyki T	Wartość p	Potwierdzenie hipotezy
H1	K → P	0,381	0,054	7,106	<0,05	TAK
H2	P → W	0,339	0,553	10,153	<0,05	TAK
H3	P → S	0,536	0,069	0,868	>0,05	NIE
H4	P → SG	0,364	0,058	0,723	>0,05	NIE
H5	S → SG	0,568	0,055	10,278	<0,05	TAK
H6	S → W	0,710	0,048	14,701	<0,05	TAK

Tabela 10 Wyniki potwierdzające hipotezy dla ścieżek

Dwie wartości p, dla ścieżki P → S oraz P → SG, są większe od zakładanej wartości 0,05, więc można wywnioskować, że hipotezy oparte na tych ścieżkach nie są potwierdzone.

W ostatniej tabeli zawarto wartości współczynnika determinacji R² oraz krzyżowej redundancji konstruktów Q². Analiza tych wskaźników pozwala na sprawdzenie czy poszczególne konstrukty są istotne.

Konstrukt	R ²	Q ²
Personalizacja	0,145	0,055
Satysfakcja	0,287	0,174
Użyteczność strony głównej	0,363	0,243
Użyteczność wyszukiwarki	0,474	0,289

Tabela 11 Współczynniki oceniające możliwości prognostyczne modelu

Wartości współczynnika determinacji R² są dosyć niskie, co świadczyłoby o słabym lub umiarkowanym dopasowaniu do modelu, jednak statystyki t mieszczą się w dopuszczalnych granicach, zatem można uznać, że wartości R² są znaczące.

Natomiast wszystkie wartości krzyżowej redundancji konstruktów Q² są dodatnie – z przedziału od 0,055 do 0,289, czyli większe od progu wejścia równego 0. Oznacza to, że dla wszystkich konstruktów istnieją istotne możliwości predykcyjne modelu.

2.3.4. Wyniki analizy wielogrupowej

W celu wykonania dokładniejszego badania zdecydowano się przeprowadzić analizy wielogrupowe za pomocą algorytmu MGA. Porównano wyniki według dwóch kryteriów: płci oraz częstotliwości oglądania Netflix'a.

Ścieżka	Współczynnik ścieżki kobiet	Współczynnik ścieżki mężczyźni	Wartość p kobiet	Wartość p mężczyźni
K → P	0,429	0,385	0,000	0,000
P → W	0,565	0,496	0,000	0,000
P → S	0,043	0,069	>0,05	>0,05
P → SG	-0,009	-0,104	>0,05	>0,05
S → SG	0,536	0,608	0,000	0,000
S → W	0,705	0,746	0,000	0,000

Tabela 12 Współczynniki ścieżek i istotności w grupach kobiet i mężczyzn

Można zauważyć, że wartości p dla obu płci są porównywalne do wyników, które osiągnięto podczas oszacowywania modelu. Zarówno w grupie kobiet, jak i mężczyzn hipotezy odpowiadające ścieżkom P → S oraz P → SG nie są potwierdzone.

Ścieżka	Różnica współczynników ścieżek kobiety - mężczyźni	Wartość p różnicy
K → P	-0.044	0.685
P → W	-0.095	0.447
P → S	-0.069	0.520
P → SG	0.025	0.862
S → SG	0.072	0.533
S → W	0.040	0.662

Tabela 13 Różnice między odpowiedziami mężczyzn i kobiet

Wartości p różnicy między kobietami i mężczyznami są znacznie większe od przyjętego progu 0,05 dla wszystkich ścieżek, co oznacza, że nie występują istotne różnice pomiędzy wybranymi grupami.

To samo badanie przeprowadzono na podstawie informacji o częstotliwości oglądania materiałów na platformie streamingowej. Użytkowników podzielono na trzy grupy ankietowanych korzystających z usług 1-3 razy w tygodniu, 4-6 razy w tygodniu oraz codziennie.

Ścieżka	Współczynnik ścieżki „1-3 razy w tygodniu”	Współczynnik ścieżki „4-6 razy w tygodniu”	Współczynnik ścieżki „Codziennie”	Wartość p „1-3 razy w tygodniu”	Wartość p „4-6 razy w tygodniu”	Wartość p „Codziennie”
K → P	0.358	0.431	0.555	0.000	0.000	0.000
P → W	-0.025	-0.015	-0.089	0.000	0.000	0.000
P → S	0.531	0.528	0.552	>0,05	>0,05	>0,05
P → SG	0.126	-0.081	-0.026	>0,05	>0,05	>0,05
S → SG	0.512	0.718	0.554	0.000	0.000	0.000
S → W	0.744	0.661	0.683	0.000	0.000	0.000

Tabela 14 Współczynniki ścieżek i istotności w grupach użytkowników wg częstotliwości oglądania

Można zauważyć, że podobnie jak w poprzedniej analizie wartości p dla wszystkich grup według częstotliwości oglądania materiałów na Netflixie są porównywalne do wyników, które osiągnięto podczas oszacowywania modelu. Zarówno w grupie użytkowników, którzy korzystają z usług 1-3 razy w tygodniu, jak również wśród użytkowników robiących to częściej hipotezy odpowiadające ścieżkom P → S oraz P → SG nie są potwierdzone.

Ścieżka	Różnica współczynników ścieżek 1-3 razy – 4-6 razy	Różnica współczynników ścieżek 1-3 razy – codziennie	Różnica współczynników ścieżek 4-6 razy – codziennie	Wartość p różnicy 1-3 razy – 4-6 razy	Wartość p różnicy 1-3 razy – codziennie	Wartość p różnicy 4-6 razy – codziennie
K → P	-0.074	-0.197	-0.124	0.516	0.107	0.373
P → W	-0.010	0.064	0.073	0.933	0.800	0.781
P → S	0.003	-0.022	-0.025	0.990	0.849	0.869
P → SG	0.207	0.152	-0.056	0.217	0.449	0.845
S → SG	-0.206	-0.042	0.164	0.130	0.710	0.297
S → W	0.083	0.061	-0.022	0.564	0.688	0.947

Tabela 15 Różnice między odpowiedziami użytkowników wg częstotliwości oglądania tytułów na Netflixie

Wartości p różnicy między użytkownikami w zależności od częstotliwości korzystania z usług na platformie streamingowej są znacznie większe od przyjętego progu 0,05 dla wszystkich ścieżek, co oznacza, że nie występują istotne różnice pomiędzy wybranymi grupami.

3. Podsumowanie

W trzecim rozdziale zawarto podsumowanie opisanego badania, a także wkład w jego przeprowadzenie oraz zaprezentowano jego praktyczne zastosowanie i ograniczenia przy zastosowaniu wybranej metodologii.

3.1. Dyskusja

Netflix jako serwis streamingowy jest stosunkowo nowym przedsięwzięciem, który na polskim rynku, na którym przeprowadzone było badanie, jest dostępny zaledwie od 2016 roku. Dodatkowo usługa ta jest dosyć młodą formą rozrywki, z powodu czego istnieje niewiele dostępnej literatury w tej dziedzinie. Warto jednak zaznaczyć, że firma prowadzi swojego oficjalnego bloga, na którym publikuje zawartości dotyczące działania zaimplementowanych w serwisie algorytmów rekomendacyjnych, co pozwoliło na przedstawienie wiarygodnych informacji w teoretycznym wstępie do przeprowadzonego badania.

Badanie opierało się na subiektywnych odczuciach użytkowników wybranego serwisu streamingowego, zatem konieczne było kwestionariusza ankietowego, który składał się z pięciu sekcji, reprezentujących poszczególne konstrukty oraz metryczki, pozwalającej na scharakteryzowanie badanej grupy. Ankieta została udostępniona na grupach tematycznych, które gromadzą społeczność zainteresowaną materiałami dostępnymi na Netflixie oraz rozesłano osobom znajomym, posiadającym swoje konta na tej platformie, a jedynym warunkiem wzięcia udziału w badaniu było korzystanie z usług dostępnych na Netflixie. W celu przeprowadzenia analizy postawiono sześć hipotez, a następnie sprawdzono ich słusność za pomocą opcji dostępnych w programie SmartPLS. Analizę oparto na algorytmie PLS, bootstrapie oraz blindfoldingu, a analizę grupową na algorytmie MGA.

Po sprawdzeniu słusności konstruktyw i zmiennych, można było zauważyć, że zmienne SG1 oraz SG2 należało usunąć z modelu. Zmienne te odnosiły się do konstruktów „użyteczność strony głównej” oraz informowały o wyszukiwaniu przez użytkownika tytułów na stronie głównej oraz o ilości spędzanego na niej czasu. Następnie, ponownie sprawdzono trafność utworzonego modelu. Tym razem wszystkie wyniki były zadowalające, a oszacowany model potwierdził cztery z sześciu hipotez. Oznacza to, że przynależność do społeczności marki i wynikający z tego sposób korzystania z platformy streamingowej Netflix ma istotny wpływ na personalizację wyświetlanych wyników, ta zaś wpływa istotnie jedynie na użyteczność wyników wyświetlanych w wyszukiwarce, natomiast użyteczność strony głównej oraz

satysfakcja nie zależą znacząco od personalizacji. Satysfakcja istotnie wpływa zarówno na użyteczność strony głównej oraz wyszukiwarki.

Podczas badania przeprowadzono także analizy grupowe – pomiędzy grupą mężczyzn a kobiet oraz zrobiono także podział na trzy grupy ze względu na częstotliwość korzystania z platformy streamingowej (1-3 razy w tygodniu, 4-6 razy w tygodniu oraz codziennie). Wyniki działania algorytmu MGA pokazały, że nie istnieją istotne różnice pomiędzy grupami użytkowników. Ponadto hipotezy dla każdej z grup zostały potwierdzone i odrzucone w taki sam sposób, jak w oszacowanym modelu.

3.2. Wkład

Netflix, usługi VOD oraz platformy streamingowe są stosunkowo krótko dostępne na rynku rozrywkowym, dlatego też przeprowadzono niewiele badań w tym temacie. Ogólnodostępne informacje pozwoliły na zdefiniowanie konstruktów istotnych w subiektywnym odbiorze działania platformy streamingowej.

Analiza grupowa opinii użytkowników Netflixa pokazała, że płeć oraz częstotliwość korzystania z usług nie ma znaczącego wpływu na zależności pomiędzy poszczególnymi konstruktami, co może być podstawą do tworzenia nowych działań marketingowych oraz pomocą przy określeniu grupy docelowej produktu, jakim jest serwis streamingowy. Praca może się przyczynić do dalszych badań związanych z rozwojem tego rodzaju spędzania czasu wolnego, wpływu na odbiorców udostępnianych treści czy związków między elementami platformy.

Dodatkowo praca pozwala na poznanie zastosowanej metodyki. Modelowanie równań strukturalnych nie jest powszechnie znaną metodą, zatem dokładny opis każdego z etapów analizy wraz z przedstawionym przykładem zastosowania zwiększa zasięg oraz rozumienie tej metodologii.

3.3. Praktyczne zastosowanie

Zarówno część teoretyczna jak i praktyczna badania nawiązuje do ciągle rozwijającej się marki, jaką jest Netflix, a dokładniej mówiąc do jej algorytmów rekomendacyjnych, które zastosowano podczas tworzenia strony głównej serwisu streamingowego oraz w wbudowanej wyszukiwarce tytułów. Warto zwrócić uwagę na to, że firmie zależy na poznaniu opinii użytkowników, co można zaobserwować na stale aktualizowanych profilach w serwisach społecznościowych, gdzie wiele z publikowanych treści motywuje odbiorców do stałej

interakcji. Ponadto jednymi z rodzajów pasków na stronie głównej są paski typu „Popularne teraz” oraz „Top 10 w <nazwa państwa> dzisiaj”, opierające się na najczęściej oglądanych tytułach czy są odpowiedzią na aktualne wydarzenia, dlatego też wyniki badania mogą posłużyć jako wsparcie podczas kolejnych aktualizacji algorytmów rekomendacyjnych oraz pomóc przedstawicielom marki zrozumieć zależności pomiędzy wyszczególnionymi konstruktami.

Warto tutaj wspomnieć także o społeczności, która jest odbiorcą treści na platformie. Użytkownicy Netflix'a mogą poszerzyć swoją wiedzę na temat algorytmów działających w serwisie, co pozwoli na bardziej świadome korzystanie z takiej formy rozrywki. Oglądający, który jest zaznajomiony z zasadami działania wyszukiwarki ma możliwość poznać jej ograniczenia oraz skuteczniej wybierać frazy, odpowiadające intencji podczas poszukiwania tytułu. Dodatkowo znajomość algorytmów tworzących stronę główną pozwala na szybki przegląd materiałów.

Praca może być także źródłem wiedzy dla innych platform streamingowych oraz wszystkich branż pokrewnych, ponieważ wskazuje ona nie tylko działanie algorytmów rekomendacyjnych na obecnie (czerwiec 2022 rok) największym serwisie streamingowym na świecie, ale także wskazuje na subiektywny odbiór wyników ich działania. Wyniki badania mogą zatem stanowić podstawę podczas pracy programistów oraz podczas budowania pozytywnego postrzegania usługi oraz marki przez zgromadzoną społeczność użytkowników.

Warto wspomnieć, że budowanie pozytywnej relacji z użytkownikiem oraz dbanie o satysfakcję i użyteczność widżetów dostępnych w serwisie niesie ze sobą zyski finansowe dla firmy, ponieważ zadowolony klient nie będzie chciał zrezygnować z subskrypcji, a co za tym idzie spełniania obowiązku comiesięcznego płacenia wyznaczonej za to opłaty. W takiej sytuacji marka staje się rozpoznawalna, buduje, rozszerza i stabilizuje swoją docelową społeczność, a także jest w stanie na tym osiągać dobre wyniki sprzedażowe, natomiast użytkownicy mogą się cieszyć z dostępu do satysfakcjonującej oraz użytecznej formy rozrywki.

3.4. Ograniczenia

Pierwszym ograniczeniem, które pojawiło się podczas przygotowań do przeprowadzenia badania była niewielka ilość dostępnej literatury. Zdecydowana większość materiałów była nierzetelna i nie nadawała się do dalszego cytowania. Po wpisaniu w wyszukiwarce haseł dotyczących platform streamingowych oraz algorytmów rekomendacyjnych na nich dostępnych można zobaczyć wiele artykułów lub filmików, które nie są pracami naukowymi. Najwięcej merytorycznych informacji było dostępnych na oficjalnym blogu Netflix'a.

Kolejnym ograniczeniem była duża zmienność rynku jak również samej platformy. Rozrywka polegająca na udostępnianiu materiałów na portalach streamingowych lub udostępniających wideo na żądanie (z ang. Video on Demand, VoD) jest stosunkowo nowym sposobem spędzania wolnego czasu. Dodatkowo dotyczy rynku rozrywki wirtualnej, która wraz z szybkim rozwojem technologicznym również stale się rozwija i wiele informacji staje się nieaktualnych.

Badanie opierało się na danych zebranych dzięki stworzonej ankiecie. Przetłumaczenie kwestionariusza na języki obce oraz udostępnienie go dla użytkowników z innych państw pozwoliłoby na uzyskanie bardziej precyzyjnych i wiarygodnych wyników, dzięki większemu zróżnicowaniu charakterystyki demograficznej grupy.

Warto również podkreślić, że wybór materiału do oglądania nie musi polegać na działaniu algorytmów rekomendacyjnych na portalu streamingowym. Często zdarza się, że wybór użytkownika jest motywowany poleceniami znajomych czy wynika z ocen jakie przyznano tytułowi na stronach takich jak na przykład imdb, filmweb czy rotten tomatoes.

Zakończenie

Powyższa praca rozwija temat ciągle rozwijającej się dziedziny rozrywki, jaką są dostępne w sieci platformy streamingowe oferujące użytkownikom szeroką gamę tytułów filmów, seriali oraz programów rozrywkowych i dokumentalnych. Głównym celem badania było określenie użyteczności zastosowanych na nich algorytmów rekomendacyjnych oraz zbadanie subiektywnej opinii odbiorców takich treści.

Badanie zostało przeprowadzone drogą elektroniczną za pomocą kwestionariusza utworzonego w Google Forms, a następnie otrzymane dane zostały przeanalizowane dzięki metodyce modelowania równań strukturalnych (SEM) w programie SmartPLS 3. Dzięki takiemu działaniu można było zweryfikować postawione wcześniej hipotezy.

Przeprowadzone badanie pozwoliło na potwierdzenie czterech z sześciu twierdzeń. Prawdziwe okazały się hipotezy dotyczące wpływu korzystania i rekomendacji na personalizację, personalizacji na wyszukiwarkę oraz satysfakcji na stronę główną i wyszukiwarkę, natomiast fałszywe są założenia odnośnie istotnego wpływu personalizacji na satysfakcję oraz stronę główną. Oznacza to, że wyświetlanie spersonalizowanych wyników na stronie głównej Netflix'a nie jest znaczące, w kontekście użyteczności algorytmów rekomendacyjnych na etapie tworzenia strony głównej oraz w kontekście ogólnej satysfakcji z korzystania z platformy. Można zatem uznać, że kierunek analiz wraz z postawionymi założeniami były właściwe, tym samym dochodzę do wniosku, że osiągnięto cel pracy.

Warto zauważyć, że ważnym aspektem jest przynależność użytkowników do społeczności marki i wynikający z tego sposób korzystania z platformy streamingowej, ponieważ ma istotny wpływ na działanie algorytmów, a tym samym na ich skuteczność, użyteczność i satysfakcję z wyświetlanych oraz personalizowanych wyników. Dlatego też, użytkownicy korzystający z konta innej osoby mogą mieć zaburzony odbiór działania algorytmów rekomendacyjnych, co ma efekt w odczuwaniu satysfakcji z ich działania, a także z użyteczności strony głównej, gdzie zdecydowana większość wierszy opiera się na obejrzanych już tytułach czy najczęściej oglądanych gatunkach filmowych i serialowych.

Temat nie był łatwy, przede wszystkim z powodu ciągłej zmienności algorytmów rekomendacyjnych oraz samej platformy, jednak praca może stanowić podstawę do dalszych rozważań i badań w tej dziedzinie.

Bibliografia

1. Alvino, C., & Basilico, J. (2015). *Learning a Personalized Homepage*.
<https://netflixtechblog.com/learning-a-personalized-homepage-aa8ec670359a>
2. Broome, J. (1991). Utility. *Economics and Philosophy*, 7(1), 1–12.
<https://doi.org/10.1017/S0266267100000882>
3. Gomez-Uribe, C. A., & Hunt, N. (2016). The Netflix Recommender System. *ACM Transactions on Management Information Systems*, 6(4), 1–19.
<https://doi.org/10.1145/2843948>
4. Help Center, N. (2021). *Centrum pomocy*. Help.Netflix.Com. help.netflix.com
5. Hom, W. (2000). *An Overview of Customer Satisfaction Models*.
6. Jelonek, D. (2014). Personalizacja jako determinanta sukcesu współpracy z klientem w przestrzeni internetowej. *Prace Naukowe Wałbrzyskiej Wyższej Szkoły Zarządzania i Przedsiębiorczości*, 27, 267–278.
7. Latiff, Z. Abd., & Safiee, N. A. S. (2015). New Business Set Up for Branding Strategies on Social Media – Instagram. *Procedia Computer Science*, 72, 13–23.
<https://doi.org/10.1016/j.procs.2015.12.100>
8. Sarstedt, M., Ringle, C. M., & Hair, J. F. (2021). Partial Least Squares Structural Equation Modeling. In *Handbook of Market Research* (pp. 1–47). Springer International Publishing. https://doi.org/10.1007/978-3-319-05542-8_15-2
9. Schumacker, R. E., & Lomax, R. G. (2015). *A Beginner's Guide to Structural Equation Modeling*. Routledge. <https://doi.org/10.4324/9781315749105>
10. Sharma, R. S., & Kale, R. (2018). Design of back-end of recommendation systems using collective intelligence social tagging. *Proceedings of the International Conference on Electronic Business (ICEB), 2018-Decem*, 204–220.
11. Subías, M. H., Laverón, M. M., & Molina, A. M. U. (2018). Online recommendation systems in the spanish audiovisual market: Comparative analysis between atresmedia, movistar+ and netflix. *UCJC Business and Society Review*, 15(4), 54–89. <https://doi.org/10.3232/UBR.2018.V15.N4.02>

12. Sztąberek, M. (2018). Platforma strumieniowa Netflix – domena VOD czy nowa forma telewizji jakościowej? Historia i sposoby dystrybucji. *Panoptikum*, 20, 10–32. <https://doi.org/10.26881/pan.2018.20.01>
13. Ullman, J. B., & Bentler, P. M. (2003). Structural Equation Modeling. In *Handbook of Psychology*. John Wiley & Sons, Inc. <https://doi.org/10.1002/0471264385.wei0224>
14. Yang, J., & Wang, J. (2017). Tag clustering algorithm LMMSK: improved K-means algorithm based on latent semantic analysis. *Journal of Systems Engineering and Electronics*, 28(2), 374. <https://doi.org/10.21629/JSEE.2017.02.18>

Spis tabel

Tabela 1 Konstrukty, zmienne oraz akronimy zmiennych użyte w badaniu	24
Tabela 2 Charakterystyka demograficzna badanej grupy	26
Tabela 3 Wartości ładunków zmiennych refleksyjnych	27
Tabela 4 Wartości rzetelności zmiennych refleksyjnych.....	27
Tabela 5 Macierz wartości HTMT	28
Tabela 6 Wartości rzetelności zmiennych refleksyjnych po usunięciu zmiennych.....	28
Tabela 7 Wartości ładunków zmiennych refleksyjnych po usunięciu zmiennych	29
Tabela 8 Macierz wartości HTMT po usunięciu zmiennych.....	29
Tabela 9 Wartości VIF dla zmiennych kształujących	30
Tabela 10 Wyniki potwierdzające hipotezy dla ścieżek	31
Tabela 11 Współczynniki oceniające możliwości prognostyczne modelu.....	31
Tabela 12 Współczynniki ścieżek i istotności w grupach kobiet i mężczyzn	32
Tabela 13 Różnice między odpowiedziami mężczyzn i kobiet	32
Tabela 14 Współczynniki ścieżek i istotności w grupach użytkowników wg częstotliwości oglądania	33
Tabela 15 Różnice między odpowiedziami użytkowników wg częstotliwości oglądania tytułów na Netflixie	33

Spis rysunków

Rysunek 1 Plany subskrypcji w Netflixie.	6
Rysunek 2 Ikona dostępu do sekcji dla dzieci	6
Rysunek 3 Wyniki wyszukiwania dla hasła “akustyczne”	9
Rysunek 4 Wyniki wyszukiwania dla hasła “akustycznie”	9
Rysunek 5 Przykład grupowania tagów.....	10
Rysunek 6 Przykładowa strona główna w aplikacji Netflix	11
Rysunek 7 Model nawigacji na stronie głównej Netflix	13
Rysunek 8 Przykładowy wiersz typu “oglądaj dalej”	15
Rysunek 9 Przykładowy wiersz typu Video-Video Similarity	16
Rysunek 10 Model teoretyczny zależności czynników wpływających na użyteczność i efektywność algorytmów rekomendacyjnych na Netflixie.....	23
Rysunek 11 Model z oszacowanymi współczynnikami	30

Załącznik

Skuteczność algorytmów rekomendacyjnych na platformie streamingowej Netflix

Szanowni Państwo,

jestem studentką III roku kierunku Informatyka i Ekonometria na Uniwersytecie Ekonomicznym w Katowicach. W ramach mojej pracy licencjackiej przeprowadzam analizę działania i skuteczności algorytmów rekomendacyjnych platformy streamingowej Netflix wśród osób korzystających z jej usług.

W związku z tym zwracam się do Państwa z prośbą o wypełnienie poniższej ankiety na temat własnych doświadczeń z algorytmami rekomendacyjnymi na Netflixie (wyboru i wyświetlania tytułów użytkownikowi).

Ankieta skierowana jest do użytkowników platformy Netflix. Jest ona w pełni anonimowa, a jej wyniki zostaną wykorzystane wyłącznie w celach naukowych.

Prosiłabym o rzetelne odpowiedzi na poniższe pytania. Wypełnienie ankiety powinno zająć około 5 minut.

Z góry dziękuję za wypełnienie ankiety i pomoc w przeprowadzeniu badania.

Korzystanie z platformy i jej rekomendacja

Poniżej znajdują się pytania dotyczące korzystania z platformy streamingowej Netflix oraz chęci rekomendowania jej. Proszę się zapoznać z ich treścią i odpowiedzieć w skali liniowej od 1 do 7.

- Chętniej oglądam tytuły, które mają ciekawą okładkę.

Siedmiostopniowa skala Likerta od „Zdecydowanie się nie zgadzam” do „Zdecydowanie się zgadzam”

- Śledzę nowości dodawane na Netflixu.

Siedmiostopniowa skala Likerta od „Nigdy” do „Zawsze”

- Oglądam tylko tytuły, które znam lub kojarzę.

Siedmiostopniowa skala Likerta od „Zdecydowanie się nie zgadzam” do „Zdecydowanie się zgadzam”

- Śledzę informacje dodawane na social mediach Netflixu.

Siedmiostopniowa skala Likerta od „Zdecydowanie się nie zgadzam” do „Zdecydowanie się zgadzam”

- Chętnie polecę Netflixu znajomemu lub rodzinie.

Siedmiostopniowa skala Likerta od „Zdecydowanie nie” do „Zdecydowanie tak”

Użyteczność strony głównej

Poniżej znajdują się pytania dotyczące korzystania ze strony głównej Netflixu. Proszę się zapoznać z ich treścią i odpowiedzieć w skali liniowej od 1 do 7.

- Najczęściej wyszukuję tytułów na stronie głównej.

Siedmiostopniowa skala Likerta od „Zdecydowanie się nie zgadzam” do „Zdecydowanie się zgadzam”

- Najwięcej czasu spędzam na stronie głównej (poza oglądaniem materiałów).

Siedmiostopniowa skala Likerta od „Zdecydowanie się nie zgadzam” do „Zdecydowanie się zgadzam”

- Podoba mi się budowa strony głównej Netflixu.

Siedmiostopniowa skala Likerta od „Bardzo mi się nie podoba” do „Bardzo mi się podoba”

- Uważam, że strona główna Netflixu wyróżnia się w porównaniu do innych platform streamingowych.

Siedmiostopniowa skala Likerta od „Zdecydowanie nie” do „Zdecydowanie tak”

- Korzystanie ze strony głównej jest intuicyjne i przyjemne.

Siedmiostopniowa skala Likerta od „Zdecydowanie nie” do „Zdecydowanie tak”

Użyteczność wyszukiwarki platformy

Poniżej znajdują się pytania dotyczące korzystania z wyszukiwarki Netflix. Proszę się zapoznać z ich treścią i odpowiedzieć w skali liniowej od 1 do 7.

- Najczęściej wyszukuję tytuły za pomocą wyszukiwarki na platformie.

Siedmiostopniowa skala Likerta od „Zdecydowanie się nie zgadzam” do „Zdecydowanie się zgadzam”

- Podoba mi się działanie wyszukiwarki Netflix.

Siedmiostopniowa skala Likerta od „Bardzo mi się nie podoba” do „Bardzo mi się podoba”

- Uważam, że wyszukiwarka Netflix działa szybko i skutecznie.

Siedmiostopniowa skala Likerta od „Zdecydowanie się nie zgadzam” do „Zdecydowanie się zgadzam”

- Uważam, że sposób prezentacji wyników wyszukiwania jest czytelny.

Siedmiostopniowa skala Likerta od „Zdecydowanie się nie zgadzam” do „Zdecydowanie się zgadzam”

Satysfakcja wyszukiwania

Poniżej znajdują się pytania dotyczące satysfakcji z wyszukiwania tytułów. Proszę się zapoznać z ich treścią i odpowiedzieć w skali liniowej od 1 do 7.

- Uważam, że propozycje na stronie głównej są trafione.

Siedmiostopniowa skala Likerta od „Zdecydowanie się nie zgadzam” do „Zdecydowanie się zgadzam”

- Uważam, że wyniki wyszukiwania w wyszukiwarce są trafione.

Siedmiostopniowa skala Likerta od „Zdecydowanie się nie zgadzam” do „Zdecydowanie się zgadzam”

- Jestem zadowolony/a ze sposobów wyszukiwania i wybierania tytułów na Netflixie.

Siedmiostopniowa skala Likerta od „Zdecydowanie się nie zgadzam” do „Zdecydowanie się zgadzam”

- Uważam, że Netflix posiada wszystkie funkcjonalności wyszukiwania, których bym oczekiwał(a).

Siedmiostopniowa skala Likerta od „Zdecydowanie się nie zgadzam” do „Zdecydowanie się zgadzam”

Personalizacja wyników wyszukiwania

Poniżej znajdują się pytania dotyczące personalizacji wyświetlanej zawartości. Proszę się zapoznać z ich treścią i odpowiedzieć w skali liniowej od 1 do 7.

- Uważam, że wyniki w wyszukiwarce Netflix są spersonalizowane do konta, z którego korzystam.

Siedmiostopniowa skala Likerta od „Zdecydowanie się nie zgadzam” do „Zdecydowanie się zgadzam”

- Uważam, że strona główna ma wiersze wybrane indywidualnie dla każdego użytkownika.
Siedmiostopniowa skala Likerta od „Zdecydowanie się nie zgadzam” do „Zdecydowanie się zgadzam”

- Uważam, że kolejność tytułów w poszczególnych wierszach strony głównej NIE jest taka sama dla każdego użytkownika.
Siedmiostopniowa skala Likerta od „Zdecydowanie się nie zgadzam” do „Zdecydowanie się zgadzam”

- Uważam, że zawartość wierszy na stronie głównej NIE jest taka sama dla każdego użytkownika.
Siedmiostopniowa skala Likerta od „Zdecydowanie się nie zgadzam” do „Zdecydowanie się zgadzam”

- Uważam, że dużo wiem o algorytmach polecania na Netflixie.
Siedmiostopniowa skala Likerta od „Zdecydowanie się nie zgadzam” do „Zdecydowanie się zgadzam”

Metryczka

- Płeć

Kobieta

Mężczyzna

Nie chcę podawać

- Wykształcenie

Podstawowe

Zasadnicze zawodowe

Średnie

Wyższe

- Wiek

Poniżej 18 lat

18-27 lat

28-37 lat

38-47 lat

48-57 lat

Powyżej 57 lat

- Czy posiadasz własne konto w serwisie Netflix?

Tak

Nie, korzystam z konta osoby znajomej (rodzina, przyjaciele itp.)

- Co najczęściej oglądasz w serwisie Netflix?

Filmy fabularne

Seriale fabularne

Filmy i seriale dokumentalne

Inne

- Jak często oglądasz Netflix'a?

1-3 razy w tygodniu

4-6 razy w tygodniu

Codziennie