

Automatyzacja procesu personalnej konsultacji kolorystycznej za pomocą AI

Łucja Całus

Uniwersytet Ekonomiczny we Wrocławiu

e-mail: 192275@student.ue.wroc.pl

ORCID: [0009-0009-1821-0907](https://orcid.org/0009-0009-1821-0907)

© 2025 Łucja Całus

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

Cytuj jako: Całus, Ł. (2025). Automatyzacja procesu personalnej konsultacji kolorystycznej za pomocą AI. W: R. Brajer-Marczak, A. Marciszewska (red.), *Procesy i projekty w doskonaleniu organizacji* (s. 11-23). Wydawnictwo Uniwersytetu Ekonomicznego we Wrocławiu.

Streszczenie: Celem opracowania jest zbadanie możliwości automatyzacji procesu personalnej konsultacji kolorystycznej przy wykorzystaniu sztucznej inteligencji, w oparciu o klasyczne koncepcje kolorystyczne, teorię czterech pór roku oraz jej rozszerzenia do 12 podtypów. Obiektem badań stał się proces personalnej analizy kolorystycznej (PCA) oraz jego potencjalna implementacja za pomocą algorytmów uczenia maszynowego i przetwarzania obrazu. W pracy zastosowano autorską metodę klasyfikacji typu urody, opartą na trójmodułowym systemie AI analizującym cechy hue, saturation i value. Najważniejsze wyniki badania wskazują, że zaproponowany model osiąga zadowalającą trafność klasyfikacji i wykazuje spójność z klasycznymi założeniami teorii kolorów. Wnioski z badania podkreślają potencjał wdrożenia tego typu rozwiązań w branży mody i stylizacji, w kontekście zarówno personalizacji doświadczeń użytkownika, jak i wspierania idei zrównoważonej konsumpcji.

Słowa kluczowe: personalna analiza kolorystyczna, sztuczna inteligencja, armocromia, klasyfikacja sezonowa, uczenie maszynowe, slow fashion

1. Wstęp

Współczesny świat mody, designu oraz marketingu coraz intensywniej czerpie z dorobku nauk o percepcji barw, psychologii koloru oraz teorii estetyki. W tym kontekście personalna analiza kolorystyczna (*Personal Colour Analysis*, PCA) zyskuje na


znaczeniu jako narzędzie umożliwiające świadome i harmonijne kształtowanie wizerunku. Tradycyjnie proces ten opierał się na doświadczeniu stylisty i jego subiektywnej ocenie cech urody klienta, co czyniło analizę skuteczną, lecz nie zawsze spójną czy powtarzalną. Rozwój technologii sztucznej inteligencji otwiera nowe możliwości w tym obszarze, umożliwia automatyzację całego procesu z wykorzystaniem zaawansowanych algorytmów przetwarzania obrazu i uczenia maszynowego. Celem opracowania jest ocena możliwości automatyzacji procesu personalnej konsultacji kolorystycznej przy wykorzystaniu sztucznej inteligencji, w oparciu o klasyczne koncepcje kolorystyczne, teorię czterech pór roku oraz jej rozszerzenia do 12 podtypów. Obiektem badań stał się proces personalnej analizy kolorystycznej (PCA) oraz jego potencjalna implementacja za pomocą algorytmów uczenia maszynowego i przetwarzania obrazu.

Niniejszy rozdział bazuje na studiach literatury przedmiotu, analizie literatury fachowej oraz na badaniach własnych. W ramach części badawczej opracowano autorskie narzędzie oparte na algorytmach sztucznej inteligencji, którego celem była automatyczna klasyfikacja typu kolorystycznego według sezonowego podziału na 12 podtypów. Model oparto na metodach uczenia maszynowego z wykorzystaniem bibliotek do przetwarzania obrazu i analizy kolorów. W badaniu zastosowano dwa niezależne zbiory danych: Deep Armocromia, zawierający obrazy oznaczone na podstawie rozszerzonej teorii Armocromii, oraz Spice Market Colour, będący ekspercką klasyfikacją typów urody w oparciu o wizerunki znanych osób (celebrytów).

2. Proces personalnej analizy kolorystycznej

Teoria kolorów stanowi jeden z kluczowych fundamentów analizy kolorystycznej, której zastosowanie znajduje szerokie spektrum w modzie, designie oraz sztuce. Ten interdyscyplinarny obszar wiedzy, obejmujący zarówno aspekty fizyczne, jak i psychologiczne związane z percepcją barw, od wieków fascynował filozofów, artystów oraz naukowców, a jego rozwój pozostawał w ścisłej korelacji z postępem w optyce, fizyce oraz psychologii percepcji. Podstawy teoretyczne dotyczące natury barw miały swoje początki już w starożytności, jednakże istotny przełom w ich rozumieniu nastąpił dopiero w epoce nowożytnej (Gutiérrez, 2021, s. 46-48).

Podstawową funkcją teorii kolorów jest określenie zasad rządzących interakcją barw, ich percepcją oraz wpływem na odbiór wizualny. Jednym z jej kluczowych elementów jest podział na barwy podstawowe, czyli takie, których nie można uzyskać poprzez mieszanie innych kolorów, oraz barwy wtórne i pochodne, powstające w wyniku kombinacji barw podstawowych. W zależności od systemu opisu kolorów wyróżniamy model addytywny (RGB, Red-Green-Blue), który bazuje na mieszanii światła, oraz model subtraktywny (CMYK, Cyan-Magenta-Yellow). Oba te modele, które są oparte na absorpcji światła przez pigmenty, zostały przedstawione na rys. 1 (Kimmons, 2020, s. 104-105).



Rys. 1. Wyniki mieszania światła czerwonego, zielonego i niebieskiego (modelu addytywnego) w porównaniu z mieszaniem farby w kolorze magenty, cyjanu i żółci (modelu subtraktywnego)

Źródło: opracowanie na podstawie www.sciencelearn.org.nz (dostęp: 26.05.2025).

Jednym z najistotniejszych aspektów teorii kolorów jest określenie właściwości barw, takich jak:

- odcień (*hue*) – określający konkretną barwę w spektrum,
- nasycenie (*saturation*) – opisujące intensywność koloru,
- jasność (*brightness/value*) – będąca miarą ilości odbitego lub emitowanego światła (Kimmons, 2020, s. 106-108).

Te parametry mają kluczowe znaczenie nie tylko w analizie kolorystycznej, ale również w grafice komputerowej, projektowaniu wnętrza czy przemyśle kosmetycznym.

2.1. Teoria czterech pór roku

Analiza kolorystyczna jest jednym z podstawowych narzędzi wykorzystywanych w kreowaniu wizerunku i stylizacji, pozwalających na precyzyjne dopasowanie palety barw do indywidualnych cech urody. Odpowiednio dobrane kolory mogą podkreślić naturalne atuty, dodać harmonii wyglądowi, a nawet wpłynąć na percepcję danej osoby przez otoczenie. Jednym z najpopularniejszych systemów analizy kolorystycznej jest teoria czterech pór roku, która od dziesięcioleci cieszy się niesłabnącą popularnością w branży mody, kosmetologii i wizażu.

Podstawą tej teorii jest założenie, że najlepsze dla danej osoby barwy można przyporządkować do jednego z czterech sezonów odzwierciedlających naturalne zmiany kolorystyczne w przyrodzie. Jak podkreśla Farahat (2021, s. 133), podział ten nie tylko nawiązuje do palet barw obecnych w różnych porach roku, ale także uwzględnia ich wpływ na percepcję wizualną i harmonię wizerunkową człowieka.

W naturze kolory zmieniają się sezonowo, od jasnych i świeżych tonów wiosny przez chłodne czy rozmyte barwy lata aż po głębokie i nasycone odcienie jesieni oraz

kontrastowe, intensywne barwy zimy. Tak samo ludzie posiadają swoje „naturalne” zestawy kolorystyczne, które najlepiej współgrają z ich fenotypem. Odpowiednie dopasowanie palety kolorów do indywidualnych cech skóry, włosów i oczu nie tylko pozwala podkreślić urodę, ale również wpływa na percepcję społeczną danej osoby. Nawiązując do poszczególnych pór roku, przyjęto się że:

- **wiosną** preferowane są jasne, pastelowe barwy, kojarzone z kwitnącymi roślinami i odrodzeniem przyrody. W tym okresie dominuje paleta ciepłych, świeżych tonów, takich jak złociste żółcie, koralowy róż czy soczysta zieleń;
- **latem** ludzie wykazują większe upodobanie do chłodnych i rozmytych odcieni, odzwierciedlających spokojne, przygaszone kolory letniego nieba i morza. To czas dominacji błękitów, chłodnych różów i fioletów;
- **jesień** to sezon ciepłych, głębokich barw, inspirowanych złotymi liśćmi, ziemistymi brązami i odcieniami czerwieni. Ludzie w tym okresie chętniej wybierają kolory takie jak musztardowy, rudy czy oliwkowy;
- **zimą** natomiast dominują kontrasty i chłodne, wyraziste barwy, takie jak głęboka czerń, śnieżna biel, królewski błękit czy intensywna fuksja, które silnie oddziałują na percepcję wizualną i wywołują efekt wyrazistego wizerunku (Seo, 2017, s. 2).

Każda z czterech przypisanych pór roku charakteryzuje się odrębną paletą kolorystyczną oraz specyficznym oddziaływaniem barw na wygląd osoby.

2.2. Istota i znaczenie personalnej analizy kolorów

Personalna analiza kolorów (*Personal Colour Analysis*, PCA) to jedno z kluczowych narzędzi wykorzystywanych w stylizacji i doradztwie wizerunkowym. Pozwala ono określić gamę barw najlepiej współgrających z naturalnym typem urody danej osoby.

PCA przeprowadzane jest najczęściej przez stylistów, analityków kolorów lub specjalistów ds. wizerunku, którzy na podstawie odcienia skóry, koloru oczu i włosów określają paletę barw harmonizujących z naturalnym wyglądem. Współcześnie metoda ta nie ogranicza się jedynie do subiektywnych ocen ludzkich, coraz częściej wykorzystuje zaawansowane technologie sztucznej inteligencji (AI), które umożliwiają automatyzację i standaryzację procesu (Park i in., 2018, s. 3).

Głównym celem PCA jest dopasowanie optymalnej palety barw, które w najkorzystniejszy sposób wpływają na percepcję wyglądu danej osoby. Analiza ta nie jest wyłącznie kwestią indywidualnych preferencji estetycznych, lecz bazuje na psychofizycznych aspektach percepcji kolorów, które mają realny wpływ na odbiór twarzy i całej sylwetki. Odpowiednie kolory mogą optycznie wygładzać skórę, minimalizować niedoskonałości, redukować widoczność cieni pod oczami czy przebarwień, a także wydobywać naturalny kontrast rysów twarzy (Farahat, 2021, s. 133).

Standardowy proces personalnej konsultacji składa się z kilku etapów:

1. **Określenie temperatury kolorystycznej (*hue*)** – klasyfikacja na odcienie ciepłe (złote, brzoskwinowe, oliwkowe) i chłodne (różowe, niebieskie, porcelanowe).

2. **Ocena kontrastu (*saturation*)** – analiza różnicy między odcieniem skóry a kolorem oczu i włosów, co wpływa na rekomendacje dotyczące natężenia barw.
3. **Podział na ciemne i jasne odcienie (*value*)** – sprawdzenie, czy dana osoba posiada jaśniejsze, czy ciemniejsze cechy: pigment skóry, kolor oczu i włosów.
4. **Dopasowanie do schematu sezonowego** – przypisanie osoby do jednego z czterech głównych typów kolorystycznych lub bardziej zaawansowanej wersji 12-sezonowej, uwzględniającej dodatkowe podziały na odcienie jasne, przytłumione, głębokie czy kontrastowe (Cassidy, 2007, s. 3-4).

W analizie PCA uwzględnia się sześć głównych cech kolorystycznych:

- *Value* (jasność) – czy osoba ma cechy jasne (*light*), czy ciemne (*dark*)?
- *Saturation/Chroma* (nasycenie) – czy kolory są bardziej intensywne i wyraziste (*bright*), czy przygaszone i stonowane (*muted*)?
- *Hue* (temperatura) – czy skóra, włosy i oczy mają tonację ciepłą (*warm*) czy chłodną (*cool*)?

Dzięki zastosowaniu odpowiednich kroków możliwe jest określenie zarówno dominującej cechy kolorystycznej, jak i tej, która pełni funkcję drugorzędną. Można wskazać następujące etapy:

Krok 1: Obserwacja głównych cech kolorystycznych

Proces rozpoczyna się od dokładnej obserwacji włosów, skóry i oczu. Jeśli dwie z trzech tych cech można przypisać do jednej grupy kolorystycznej, staje się ona dominującą w analizie PCA.

Krok 2: Określenie drugorzędnej cechy kolorystycznej

Po ustaleniu dominującej cechy następuje określenie drugorzędnej cechy. Jeśli dominującą cechą jest jasność lub ciemność (*light/dark*), następnym krokiem jest określenie temperatury barwnej. Jeśli dominująca cecha to ciepło lub chłód (*warm/cool*), wówczas określa się nasycenie barw (*muted/bright*).

3. Modelowanie algorytmu sztucznej inteligencji dla personalnej analizy kolorystycznej

3.1. Charakterystyka zbiorów danych służących do przeprowadzenia automatycznej analizy kolorystycznej

W kontekście trenowania modeli sztucznej inteligencji w celu przeprowadzenia personalnej analizy kolorystycznej wybór oraz jakość zbiorów danych stanowi podstawowy warunek powodzenia tego zadania. Modele oparte na metodach uczenia głębokiego wymagają starannie oznaczonych (*labeled*) przykładów, lecz także muszą uwzględniać trudność odczytania koloru na obrazach twarzy. Niniejsza praca opiera się na dwóch odrębnych i niezależnych źródłach danych: zbiorze Deep Armocromia

oraz autorsko zbudowanej bazie celebrytów, wyselekcjonowanej na podstawie eksperckiej klasyfikacji dostępnej na platformie Spice Market Colour. Oba zestawy są traktowane jako równorzędne zbiory danych, służące do porównania skuteczności klasyfikatorów w zróżnicowanych warunkach wizualnych i adnotacyjnych.

Zbiór Deep Armocromia został opracowany przez zespół naukowców z Uniwersytetu Macerata we współpracy z profesjonalnymi kolorystami, co czyni go jednym z pierwszych szeroko dostępnych akademickich zbiorów twarzy opisanych zgodnie z zasadami teorii Armocromii (Stacchio i in., 2024, s. 2). Każdy obraz przypisany jest do jednej z dwunastu kategorii sezonowych, będących wynikiem rozwiniętej Teorii Przepływu Kolorów (*Armocromia Flow Theory*)¹, a etykiety te zostały przypisane zgodnie z rygorystycznym, kilkufazowym protokołem wizualnym, naśladującym fizyczny proces przeprowadzany przez analityków koloru. Dane zawierają segmentacje twarzy, metadane dotyczące pochodzenia (np. CelebA), podziału na zbiory treningowe i testowe oraz adnotacje dotyczące głównych i podrzędnych klas sezonowych.

Drugą częścią analizy jest stworzona na potrzeby niniejszego opracowania autorska baza zdjęć osób publicznych, przypisanych do sezonów kolorystycznych na podstawie klasyfikacji opublikowanej na stronie internetowej Spice Market Colour ([b.d.](#)). Portal ten, prowadzony przez profesjonalnych kolorystów, udostępnia zestawienia celebrytów przypisanych do konkretnych typów kolorystycznych; np. *bright winter*, *dark autumn*, *light spring*, z adnotacją, że są to przyporządkowania oparte na analizach przeprowadzonych w warunkach naturalnego światła przez doświadczonych analityków kolorów.

Tabela 1. Porównanie baz danych służących PCA od Deep Armocromia oraz bazy własnej na podstawie Spice Market

Właściwość	Deep Armocromia	Baza własna (Spice Market)
Źródło	CelebA, ekspercki zbiór uczelniany	zdjęcia celebrytów z mediów i blogów
Liczba przykładów	4920 zdjęć	720 zdjęć
Liczba klas	12	12
Etykietowanie	rygorystyczny protokół ekspercki	eksperska klasyfikacja zewnętrzna (Spice Market Colour)
Styl wizualny	eksperska klasyfikacja zewnętrzna (Spice Market Colour)	rzeczywiste zdjęcia, z tłem
Przeznaczenie	benchmark naukowy	praktyczne odwzorowanie realnych warunków

Źródło: opracowanie własne.

¹ Rozszerzona teoria analizy kolorystycznej, która zakłada, że dana osoba może przejawiać cechy dwóch sąsiadujących pór roku, co prowadzi do płynnego przechodzenia między sezonami i podziału każdego z nich na trzy podgrupy, tworząc 12 bardziej precyzyjnych typów kolorystycznych opartych na temperaturze, kontraście i intensywności (Stacchio i in., 2024, s. 5).

Oba zbiory, reprezentujące dwa różne podejścia, będą istotną bazą dla dalszych badań porównawczych. Zestawienie baz danych zostało przedstawione w tab. 1.

Porównanie wyników osiąganych na obu zbiorach stworzy przestrzeń do oceny odporności modeli na zmienność źródeł danych, jakość i ilość obrazów, poziom stylizacji oraz potencjalne zaburzenia oświetleniowe, co w perspektywie wdrożeniowej (deploymentu modelu) ma kluczowe znaczenie dla dalszych etapów budowy zautomatyzowanego systemu personalnej analizy kolorystycznej.

3.2. Proces wstępnego przetwarzania danych (*preprocessing*)

Zanim dane trafią do modelu uczenia maszynowego, konieczne jest ich odpowiednie przygotowanie, tak by system był w stanie skutecznie rozpoznawać cechy charakterystyczne dla poszczególnych kategorii kolorystycznych. Ten etap, określany jako wstępne przetwarzanie danych (*preprocessing*), obejmuje wiele operacji, które nie tylko standaryzują obrazy, ale też wzmacniają te właściwości, które mają dla modelu największe znaczenie badawcze.

Pierwszym krokiem była konwersja wszystkich plików graficznych do jednolitego formatu jpg oraz ujednolicenie ich rozmiaru, co zapewniło spójność podczas dalszych etapów przetwarzania. Dodatkowo wszystkie obrazy zostały ponownie nazwane według struktury bazującej na sezonie kolorystycznym i trafiły do odpowiednich katalogów zorganizowanych osobno dla każdego z trzech zaplanowanych modeli klasyfikacyjnych: *Saturation* (nasycenie), *Value* (jasność) i *Hue* (temperatura). Każdy z tych modeli operuje na własnym, przekształconym zestawie danych, który zawiera około 238 zdjęć (zbiór Spice Market) w ramach dwóch klas (np. *bright vs muted*, *light vs dark*, *warm vs cool*).




Fot. 1. Przetwarzanie zdjęcia za pomocą modelu detekcji twarzy Haar Face Cascade

Źródło: opracowanie własne.

Kolejnym kluczowym etapem było wyodrębnienie twarzy z obrazów. Jest to operacja pozwalająca modelowi skupić się wyłącznie na tych fragmentach obrazu, które faktycznie niosą informację kolorystyczną istotną dla analizy Armocromii, jak cera, włosy i oczy. Do tego celu wykorzystano algorytm detekcji twarzy Haar Cascade Classifier, który posługuje się takimi bibliotekami jak OpenCV, numpy, PIL

i os (Madan, 2021, s. 86). Działanie modelu zostało przedstawione na fot. 1. Etap detekcji twarzy wdrożono wyłącznie na zbiorze danych Spice Market, zbiór Deep Armocromia zawiera zdjęcia masek RGB z wyodrębnionymi włosami i twarzą bez tła. Segmentacja drugiego zestawu danych nie była intensywna, pozostawiono tło, jednak twarz stanowiła centralny obiekt obróbki.

Szczególne uwagę poświęcono dostosowaniu przekształceń obrazu do rodzaju klasyfikatora. W przypadku modelu *Value*, który odpowiada za rozpoznawanie jasności skóry (*light vs dark*), obrazy zostały skonwertowane do skali szarości i przedstawione na fot. 2. Takie uproszczenie pozwala skupić uwagę modelu wyłącznie na różnicach tonalnych, eliminując rozpraszające informacje kolorystyczne. Podejście to znajduje potwierdzenie w literaturze naukowej, gdzie, jak wykazano w pracy Seo (2017, s. 3), wartość luminancji jest istotnym czynnikiem w rozróżnianiu typów cery.



Fot. 2. Przetwarzanie zdjęć dwóch klas cechy *value* (*light/dark*) za pomocą modelu Haar Face Cascade i procesowania zdjęcia za pomocą OpenCV do skali szarości

Źródło: opracowanie własne.


Dla modelu *Hue*, mającego za zadanie klasyfikować odcienie kolorystyczne jako chłodne lub ciepłe, zastosowano bardziej złożoną metodę. Obrazy zostały przekształcone przy użyciu funkcji `cv2.COLOR_BGR2HSV` oraz `cv2.COLOR_BGR2YUV`, a następnie zapisane jako wykresy kolorystyczne w formacie graficznym z wykorzystaniem biblioteki Matplotlib.

Wykorzystane w tym celu przekształcenia kolorystyczne `cv2.COLOR_BGR2HSV` oraz `cv2.COLOR_BGR2YUV` odnoszą się do dwóch odmiennych przestrzeni barw, z których każda eksponuje inne właściwości koloru. Pierwsze z nich HSV (*hue, saturation, value*), jest szczególnie przydatne w kontekście rozpoznawania temperatury barwowej, ponieważ parametr *hue* reprezentuje odcień koloru w formie kąta na kole barw (gdzie np. czerwony to 0°, niebieski 240°, a zielony 120°). Ta reprezentacja ułatwia oddzielenie ciepłych i chłodnych tonów w sposób bardziej intuicyjny niż

klasyczne RGB, które nie rozdziela barwy, nasycenia i jasności (Rahil i Singh, 2022, s. 169, 175, 177).

Z kolei przekształcenie `cv2.COLOR_BGR2YUV` konwertuje obraz do przestrzeni, w której Y oznacza luminancję (jasność), a U i V to składniki chrominancji (czyli różnice barwne względem luminancji). Ta przestrzeń jest wykorzystywana [m.in.](#) w telewizji cyfrowej i kompresji wideo, ale w kontekście analizy kolorystycznej ma jeszcze inną zaletę: pozwala lepiej oddzielić kontrast i głębię barwy od intensywności światła. Połączenie obu transformacji – HSV i YUV – umożliwia uzyskanie złożonego obrazu, który uwypukla różnice w odcieniach ciepłych i zimnych bez nadmiernego wpływu czynników takich jak cień czy przeświecenie (Rahil i Singh, 2022, s. 175).

Dzięki połączeniu tych dwóch przestrzeni barw (HSV i YUV) udało się uzyskać reprezentację, która wyraźnie uwidacznia różnice w temperaturze kolorystycznej skóry, czego nie da się osiągnąć jedynie poprzez standardowy zapis w RGB. Działanie zostało zaprezentowane na fot. 3. To autorskie rozwiązanie znajduje teoretyczne wsparcie w pracach poświęconych modelom widzenia barw (Jetsu i in., 2008, s. 228), gdzie podkreśla się znaczenie różnorodnych modeli przetwarzania sygnału koloru i ich wpływu na zdolności klasyfikacyjne.



Fot. 3. Przetwarzanie zdjęć dwóch klas cechy *hue* (*cool/warm*) za pomocą dwóch sposobów konwersji zdjęć OpenCV z RGB do HSV oraz z RGB do YUV

Źródło: opracowanie własne.

Z kolei model *Saturation*, którego zadaniem jest rozpoznawanie intensywności koloru (*muted vs bright*), operuje na zdjęciach bez dużych ingerencji. Wstępnie rozważono zastosowanie medianowego rozmycia oraz manipulacji kanałem S (*Saturation*) w przestrzeni HSV, jednak ostatecznie model został wdrożony na bazowych obrazach, bez dodatkowych transformacji. Wynika to z założenia, że nasycenie jako cecha może być najlepiej reprezentowane na poziomie wizualnym, bez sztucznego podbijania tego aspektu, a dodatkowe transformacje nie poprawiają jakości modelu.

4. Testowanie modelu

Testowanie polegało na ocenie jakości predykcji nie poprzez porównanie nazw sezonów, ale na poziomie dopasowania cech – niezależnie od nazewnictwa klasy. Oceniano zatem, czy przewidziane przez model wartości *saturation*, *hue* i *value* odpowiadały cechom zdefiniowanym dla danego zdjęcia w adnotacji. Tego typu podejście pozwalało skupić się na jakości wyodrębnienia kluczowych cech chromatycznych. W tym celu wykorzystano autorską macierz dopasowania, uwzględniającą siłę występowania każdej cechy HSV, bazując na 12 równaniach kolorów zgodnie z ich występowaniem na kole sezonowym. Wyniki przedstawiono w tab. 2.

Tabela 2. Macierz dopasowania siły cechy HSV do sezonu

Sezon/Cechy	<i>Saturation</i>	<i>Hue</i>	<i>Value</i>
<i>Bright winter</i>	<i>brigth +2</i>	<i>cold +1</i>	<i>neutral</i>
<i>True winter</i>	<i>bright +1</i>	<i>cold +2</i>	<i>dark +1</i>
<i>Dark winter</i>	<i>neutral</i>	<i>cold +1</i>	<i>dark +2</i>
<i>Dark autumn</i>	<i>neutral</i>	<i>warm +1</i>	<i>dark +2</i>
<i>True autumn</i>	<i>muted +1</i>	<i>warm +2</i>	<i>dark +1</i>
<i>Soft autumn</i>	<i>muted +2</i>	<i>warm +1</i>	<i>neutral</i>
<i>Soft summer</i>	<i>muted +2</i>	<i>cold +1</i>	<i>neutral</i>
<i>True summer</i>	<i>muted +1</i>	<i>cold +2</i>	<i>light +1</i>
<i>Light summer</i>	<i>neutral</i>	<i>cold +1</i>	<i>light +2</i>
<i>Light spring</i>	<i>neutral</i>	<i>warm +1</i>	<i>light +2</i>
<i>True spring</i>	<i>bright +1</i>	<i>warm +2</i>	<i>light +1</i>
<i>Bright spring</i>	<i>brigth +2</i>	<i>warm +1</i>	<i>neutral</i>

Źródło: opracowanie własne na podstawie Style Coaching Ltd., 2005-2020.

Za pomocą macierzy uzyskano miary precyzji przyporządkowania każdej cechy niezależnie oraz tzw. *average feature match score*, czyli średnią z dopasowania trzech parametrów łącznie. Wyniki zestawiono w tab. 3, odpowiednio dla każdego z 12 sezonów. Analiza pokazała istotne różnice w skuteczności modelu w zależności od zbioru danych. Średni wskaźnik pełnego dopasowania cech (wszystkie trzy jednocześnie) wyniósł dla Deep Armocromia 37%, natomiast dla Spice Market – 39%. Różnice w rozkładzie między sezonami pozostawały jednak istotne. Przykładowo, model dla Deep Armocromia osiągnął bardzo wysokie dopasowanie cech dla typu *light summer* (82%), podczas gdy dla *true winter* jedynie 1%. Może to wskazywać na trudność modelu w uchwyceniu specyfiki chłodnych, ciemnych typów w niektórych warunkach oświetleniowych lub przy ograniczeniach danych uczących. Model testowany na Deep Armocromia osiągał również wyższe wskaźniki dopasowania dla typów o wyraźnym kontraście chromatycznym. Przykładowo, dla typu *dark winter* osiągnięto wskaźnik dopasowania cech na poziomie 82%, podczas gdy dla *soft autumn* zaledwie 15%.

Tabela 3. Wyniki metryk poszczególnych cech dla 12 sezonów kolorystycznych obu zbiorów danych

Sezon	Spice Market				Deep Armocromia			
	Dokład- ność satu- ration	Dokład- ność hue	Dokład- ność value	Wskaźnik średniego dopasowa- nia do cechy	Dokład- ność saturation	Dokład- ność hue	Dokład- ność value	Wskaźnik średniego dopasowania do cechy
Bright spring	0,11	0,21	0,16	0,16	0,00	0,31	0,02	0,11
Bright winter	0,29	0,64	0,36	0,43	0,00	0,82	0,02	0,28
Dark autumn	0,67	0,25	0,67	0,53	0,95	0,34	0,84	0,71
Dark winter	0,67	0,89	0,56	0,70	0,93	0,69	0,85	0,82
Light spring	0,33	0,11	0,33	0,26	0,86	0,55	0,73	0,71
Light summer	0,44	0,44	0,44	0,44	0,96	0,67	0,82	0,82
Soft autumn	0,13	0,25	0,13	0,17	0,02	0,41	0,02	0,15
Soft summer	0,00	0,60	0,10	0,23	0,04	0,67	0,04	0,25
True autumn	1,00	1,00	1,00	1,00	0,31	0,35	0,31	0,33
True spring	0,40	0,50	0,40	0,43	0,11	0,24	0,11	0,15
True summer	0,31	0,23	0,23	0,26	0,08	0,00	0,05	0,05
True winter	0,00	0,11	0,06	0,06	0,02	0,00	0,02	0,01
Średnia	0,36	0,44	0,37	0,39	0,36	0,42	0,32	0,37

Źródło: opracowanie własne.

Podsumowując analizę porównawczą wyników modeli na dwóch bazach danych, można stwierdzić, że model końcowy cechuje się umiarkowaną skutecznością w klasyfikacji pełnych sezonów kolorystycznych, przy czym najwyższą trafność uzyskuje w typach o jednoznacznych parametrach (np. *dark winter*, *true autumn*).

5. Wpływ personalizacji na rynek mody

Zastosowanie AI w analizie kolorystycznej przekłada się na wymierne korzyści zarówno dla konsumentów, jak i producentów. Z jednej strony, precyzyjne dopasowanie palet barwnych eliminuje błędy wynikające z subiektywnych ocen stylistów i doradców, co zwiększa satysfakcję użytkowników oraz ich lojalność względem marki (Agbanu i in., 2024, s. 102). Z drugiej strony, konsumenci podejmują lepiej przemyślane decyzje zakupowe; np. inwestują w produkty, które nie tylko spełniają oczekiwania estetyczne, ale również wzmacniają ich indywidualny styl i tożsamość wizualną.

Badania pokazują, że personalizacja ma istotny wpływ na zachowania zakupowe w sektorze mody. Jeon i Park (2025) wykazali, że użytkownicy platform takich jak Instagram znacznie chętniej angażują się w reklamy mody, które są spersonalizowane i odpowiadają ich kolorystycznym preferencjom. Co więcej, wzrasta nie tylko zaangażowanie, ale również intencja zakupu oraz zaufanie do marki (Jeon i Park, 2025, s. 142). Zjawisko to znajduje swoje potwierdzenie również w analizach prowadzonych przez Trivedi i Trivedi (2018), którzy wskazują, że personalizacja w aplikacjach mody ma bezpośredni wpływ na poziom satysfakcji użytkownika

oraz jego decyzję o zakupie, szczególnie jeśli aplikacja dostarcza informacji w sposób przejrzysty, szybki i dostosowany do indywidualnych potrzeb (Trivedi i Trivedi, 2018, s. 4-6).

Personalizacja nabiera obecnie szczególnego znaczenia, zwłaszcza w kontekście dostrzegania wielu zagrożeń tzw. *fast fashion*. Zgodnie z badaniami (Villa, 2022) możliwość dostosowania produktu do cech użytkownika zwiększa nie tylko jego intencję zakupu, ale także skłonność do inwestowania w odzież wysokiej jakości i trwałości. Personalizacja wzmacnia korelację między wartościami proekologicznymi a zachowaniami konsumpcyjnymi, co bezpośrednio przekłada się na zainteresowanie modą zrównoważoną (Villa, 2022, s. 36). Dzięki temu narzędzia oparte na PCA mogą pełnić istotną funkcję w przesuwaniu uwagi konsumentów z ilości na jakość, sprzyjając podejściu *slow fashion*.

6. Zakończenie

Stworzenie systemu klasyfikacyjnego udowodniło, jak złożony i interdyscyplinarny jest proces cyfrowej analizy kolorystycznej. Potwierdziło się, że integracja wiedzy z zakresu sposobu widzenia barw, algorytmiki oraz teorii koloru pozwala na zbudowanie narzędzia, które, pomimo ograniczeń, już teraz może stanowić istotne wsparcie dla doradców modowych i użytkowników końcowych. W przyszłości podobne systemy mogą funkcjonować jako wirtualni doradcy kolorystyczni, działający na stronach internetowych, w aplikacjach mobilnych lub za pośrednictwem interfejsów głosowych.

Kluczowym wyzwaniem, które wciąż pozostaje nierozwiązane, jest pełne zrozumienie kontekstu wizualnego użytkownika. Dopóki systemy nie będą potrafiły uwzględniać interakcji pomiędzy cechami takimi jak temperatura kolorystyczna skóry, kontrast twarzy czy intensywność naturalnych barw, dopóty pełna automatyzacja analiz kolorystycznych nie będzie możliwa bez udziału eksperta.

Mimo to opracowany model pokazał, że automatyczna klasyfikacja może stanowić skuteczne narzędzie pomocnicze. Dzięki dalszym modyfikacjom architektury i poszerzeniu zbiorów danych prawdopodobnie możliwe będzie osiągnięcie jeszcze lepszych wyników w przedstawianym procesie. W przyszłości rozwiązania tego typu mogą w istotny sposób wpłynąć na transformację branży modowej, nie tylko poprzez poprawę trafności stylizacyjnej, ale również dzięki wspieraniu idei zrównoważonej mody i ograniczaniu nadprodukcji.

Literatura

- Agbanu, I. I., Mohammed, A. B. i Inikpi, O. R. (2024). Effect of AI Driven Personalization on Purchasing Decisions and Customer Satisfaction in the Fashion Industry in Nigeria. *Global Journal of Research in Business Management*, 4(5).
- Cassidy, T. D. (2007). Personal Colour Analysis, Consumer Colour Preferences and Colour Forecasting for the Fashion and Textile Industries. *Colour: Design & Creativity*, 1(1), 6.

- Gutiérrez, J. (2021). Hermann von Helmholtz, Ewald Hering and Color Vision: A Controversy Over Styles of Reasoning? *Manuscrito – Revista Internacional de Filosofia*, 44(1).
- Farahat, H. (2021). Seasonal Color Type as a Guideline for Selecting Best Color Outfit. *International Design Journal*, 11(1).
- Jeon, S. i Park, M. (2025). Impact of Instagram Personalized Fashion Advertising on Consumer Perception and Behavior. *The Research Journal of the Costume Culture*, 33(2), 129-154.
- Jetsu, T., Essiarab, Y., Heikkinen, V., Jääskeläinen, T. i Parkkinen, J. (2008). *Color Classification Using Color Vision Models*. CGIV 2008 and MCS'08 Final Program and Proceedings. University of Joensuu.
- Kimmons, R. (2020). Color Theory in Experience Design. W: *Learner and User Experience Research*. EdTechBooks.
- Madan, A. (2021). Face Recognition Using Haar Cascade Classifier. *International Journal for Modern Trends in Science and Technology*, 7(1), 85-87.
- Park, J., Ji, S., Kim, H. i Hwang, E. (2018). *An Automatic Virtual Makeup Scheme Based on Personal Color Analysis*. Proceedings of IMCOM'18, Langkawi, Malezja.
- Rahil, M. i Singh, R. P. (2022). Comparison of Color Classification Using Computer Vision and Deep Neural Network. *International Journal of Innovative Research in Computer Science & Technology (IJIRCST)*, 10(4).
- Seo, R. S. (2017). *A Study of Image-making by Personal Color Analysis: A Focus on Autumn Type Make-Up and Hair*. 2017 4th International Conference on Computer Applications and Information Processing Technology (CAIPT).
- Spice Market Colour. (b.d). *Find your colour magic. That's intelligent styling*. Pobrano 27.06.2025 z <https://www.spicemarketcolour.com.au/>
- Stacchio, L., Paolanti, M., Spigarelli, F. i Frontoni, E. (2024) Deep Armocromia: A Novel Dataset for Face Seasonal Color Analysis and Classification. *Computer Vision – ECCV 2024 Workshops. ECCV 2024. Lecture Notes in Computer Science*, 15623.
- Trivedi, J. P. i Trivedi, H. (2018). Investigating the Factors that Make a Fashion App Successful: The Moderating Role of Personalization. *Journal of Internet Commerce*.
- Villa, C. (2022). Product Personalization: A Lever to Increase the Intention to Purchase Sustainable Fashion. Empirical Research on the Effect of Product Personalisation on the Relationship between Pro-environmental Values and the Intention to Purchase Sustainable Fashion (Praca magisterska, Copenhagen Business School).

Automation of Personal Colour Analysis Consultations Using AI

Abstract: The aim of this study is to evaluate the possibilities of automating color analysis of beauty types using artificial intelligence, based on classical color concepts, the four seasons theory, and its extension to 12 subtypes. The subject of the study is the Personal Colour Analysis (PCA) process and its potential implementation through machine learning algorithms and image processing techniques. The study employs an original method of beauty type classification based on a three-module AI system that analyzes the features of Hue, Saturation, and Value. The key findings indicate that the developed model achieves satisfactory classification accuracy and shows consistency with the classical assumptions of color theory. The conclusions highlight the potential for implementing such solutions in the fashion and styling industry, both in the context of personalizing user experiences and supporting the idea of sustainable consumption.

Keywords: personal colour analysis process, artificial intelligence, Armocromia, seasonal classification, machine learning