

논문 2025-62-4-6

얼굴형을 고려한 자카드 유사도 기반 헤어스타일 추천 시스템

(Jacquard Similarity-based Hairstyle Recommendation System based on Face Shapes)

이 상 민*, 정 재 형*, 이 계 식**

(Sangmin Lee, Jaehyung Jung, and Gyesik Lee[©])

요 약

다양한 산업에서 개인화된 추천 서비스에 대한 수요가 지속적으로 증가함에 따라, 사용자 선호도와 신체적 특징을 통합하는 정교한 추천 알고리즘의 중요성이 대두되고 있다. 본 연구는 자카드 유사도(Jaccard similarity)를 기반으로 사용자의 얼굴 특징 및 스타일 선호도를 가중치로 반영하는 새로운 헤어스타일 추천 시스템을 제안한다. 특히, 얼굴형(긴 얼굴형, 각진 턱 등)과 이목구비 비율 등 세부적인 얼굴 특징을 분석하여, 사용자 개개인의 특성과 조화를 이루는 헤어스타일을 추천한다. 제안된 알고리즘은 자카드 유사도에 가중치를 적용하여 기존 방식에서 놓쳤던 얼굴 특징과 스타일 요소 간의 상호작용을 효과적으로 반영한다. 실험 결과, 기존의 단순 자카드 유사도 방식보다 더 높은 정확도와 사용자 만족도를 제공하는 정교한 추천 결과를 도출하였다. 본 연구는 뷰티 및 패션 분야에서 개인화된 서비스 수준을 높이는 데 기여할 수 있는 잠재력을 제시한다.

Abstract

As the demand for personalized recommendation services in various industries continues to grow, the importance of sophisticated recommendation algorithms that incorporate user preferences and physical features has become increasingly important. In this study, we propose a novel hairstyle recommendation system based on Jacquard similarity to weight users' facial features and style preferences. In particular, we analyze detailed facial features such as face shape (long face, angular chin, etc.) and forehead-eye ratio to recommend hairstyles that are in harmony with the user's individual characteristics. The proposed algorithm effectively reflects the interaction between facial features and style elements that are missed in the existing methods by weighting the Jacquard similarity. Experimental results show that the proposed algorithm provides sophisticated recommendations with higher accuracy and user satisfaction than the traditional simple Jacquard similarity method. This research has the potential to contribute to increasing the level of personalized services in the beauty and fashion fields.

Keywords : Jacquard similarity, CNN, Hairstyle recommendation system, Data analysis

I. 서 론

추천 시스템은 사용자가 과부하 된 정보 속에서 적절한 선택을 할 수 있도록 돕는 의사결정 시스템으로 전자 상거래, 미디어 추천, 건강 관리 등 다양한 분야에서

중요한 역할을 하고 있다^[1]. 기존의 추천 시스템은 주로 사용자의 선호도, 과거의 기록들을 기반으로 추천을 수행해 왔다. 최근 딥러닝과 머신러닝의 발전으로 얼굴 인식 및 분석 기술이 크게 향상되어 얼굴 특징을 활용한 더욱 정교하고 개인화된 추천이 가능해졌다.

본 연구에서는 얼굴 특징을 추가적인 요소로 고려하여 사용자에게 보다 개인화된 경험을 제공하고자 한다. 특히, 얼굴형과 이목구비 분석을 활용한 헤어스타일 추천 알고리즘인 자카드 유사도 (Jaccard Similarity)에 가중치를 적용하는 방식을 제안하고자 한다.

Received : January 16, 2025 Revised : January 24, 2025
Accepted : February 3, 2025

자카드 유사도는 두 집합 간의 유사성을 측정하는 방법으로, 교집합을 기준으로 두 집합의 차이를 정량화하는 방식이다. 본 연구에서는 이 방법을 확장하여, 얼굴형과 이목구비에 가중치를 부여한 새로운 자카드 유사도 알고리즘을 도입한다.

최근 수년간 많은 분야에서 딥러닝이 가져온 눈부신 성과 덕분에, 이제 거의 모든 연구 분야에서 딥러닝은 피할 수 없는 시대의 흐름이 되었다^[2]. 얼굴 분석 모델을 통해 사용자의 이목구비를 분석하고, 개발한 딥러닝 모델을 활용하여 턱 모양과 같은 세부적인 얼굴 특징(예: 긴 얼굴형, 각진 턱 등)을 정확히 분류한다. 이러한 얼굴 특징에 기반하여 어떤 헤어스타일의 특징이 잘 어울리는지 추천한다.

특히 얼굴형과 이목구비를 반영하는 과정에서, 특정 추천 헤어스타일 특징의 중복 정도를 가중치로 적용하는 방법을 도입한다. 예를 들어 '긴 얼굴형'에 적합한 헤어스타일 특징("가르마 머리", "내린 머리", "옆 볼륨")과 '긴 코'에 적합한 헤어스타일 특징("내린 머리", "옆 볼륨", "컬", "중간 기장") 두 집합에 중복되는 특징인("내린 머리", "옆 볼륨")에 가중치를 설정하여 추천의 정확도를 더욱 높인다.

본 연구에서 제안하는 알고리즘은 뷰티, 패션, 맞춤형 제품 추천 시스템 등 다양한 분야에 응용될 수 있다. 이러한 확장 가능성은 추천 시스템의 개인화 수준을 더욱 높이고, 사용자의 개별적 특성을 반영한 더욱 정교한 추천을 제공할 것이다.

II. 본 론

1. 연구 배경 및 관련 연구

자카드 유사도(Jaccard similarity)는 두 집합 간의 유사성을 측정하는 지표로, 교집합과 합집합의 비율을 통해 계산된다. 본 연구에서는 사용자의 얼굴 특징과 선호도를 기반으로, 유사성을 평가하는 데 자카드 유사도를 활용한다. 기존 연구에서도 자카드 유사도의 개선을 통해 추천 시스템의 성능을 향상하기 위한 다양한 시도가 이루어져 왔다.

$$Rating_Jaccard(a, b) = \frac{N_r(a, b)}{|I_a \cap I_b|}$$

기존 연구에서는 Rating_Jaccard 방식을 제안하여, 사용자 a와 b가 평가한 항목의 교집합에서 공통 평점을 가진 항목의 개수를 계산하고, 이를 두 사용자가 평가

한 전체 항목의 합집합으로 나누어 유사성을 측정하였다^[1]. 그러나 이러한 방식은 평가 항목의 중요도나 특정 항목의 반복 빈도를 고려하지 않으며, 모든 항목을 동일한 가중치로 처리하는 한계를 가진다. 이에 따라 특정 항목의 중요성이 유사성 평가에 적절히 반영되지 않는 문제가 발생할 수 있다.

추천 시스템의 성능을 개선하기 위해, 데이터 불균형 문제를 해결하는 다양한 방법론이 제안되었다. 특히, Huang et al.은 클래스 분포의 불균형을 해결하기 위해 분포 균형 가중치를 정의하고 이를 기반으로 손실 함수를 설계하였다^[3].

분포 균형 가중치는 다음과 같이 정의된다:

$$r_{DB} = \frac{1/n_i}{\sum_{j=1}^C 1/n_j}$$

위 식에서 (n_i)는 클래스 i 의 빈도를, (C)는 전체 클래스의 수를 가리킨다.

이 식은 클래스의 빈도를 기반으로 가중치를 재조정하며, 빈도가 낮은 클래스에 더 높은 중요도를 부여하도록 설계되었다. 이를 바탕으로 제안된 최종 손실 함수는 다음과 같다:

$$L_{DB} = \begin{cases} -r_{DB}(1-p_i)^\gamma \log(p_i) & \text{if } y_i = 1 \\ -r_{DB}p_i^\gamma \log(1-p_i) & \text{if } y_i = 0 \end{cases}$$

여기서, (p_i)는 클래스 i 의 예측 확률, (γ)는 초점 조정 계수(focal parameter).

본 연구에서는 이러한 분포 균형 가중치 방식을 기반으로, 자카드 유사도를 확장하여 중복된 스타일 요소의 빈도를 가중치에 반영하는 방식을 설계하였다. 이를 통해 특정 스타일 요소가 반복적으로 나타날수록 해당 요소의 중요도가 유사성 평가에 적절히 반영될 수 있도록 하였다. 제안된 방식은 기존 자카드 유사도의 한계를 보완하여, 사용자 얼굴 특징과 선호도를 더욱 정교하게 반영한 추천 결과를 제공한다. 또한, 데이터 불균형 문제를 완화하고 추천 정확도를 높여 사용자 만족도를 향상하는 데 기여하였다. 이 방식은 특정 특징의 반복성을 고려하여 유사성을 평가함으로써, 추천 시스템의 정밀도와 개인화 수준을 동시에 강화할 수 있다.

2. 데이터 수집 및 분석

2.1 데이터 수집

본 연구에서는 얼굴 분석을 위한 데이터로 Kaggle에

서 수집한 8,000장의 얼굴 이미지와 한국 가수, 배우, 개그맨 등 연예인의 얼굴 이미지 2,000장을 사용하였다. 이 데이터는 턱 모양과 얼굴 특징을 분석하는 데 사용되었다.

2.2 이미지 데이터 분석

본 연구에서는 얼굴 전처리, 특징 추출, 분류, 및 추천 알고리즘의 통합된 구조를 제안한다. 그림 1과 같이 먼저, OpenCV를 이용하여 얼굴 이미지를 정렬하고 조정함으로써 전처리 단계를 수행하였다. 이후 MediaPipe를 사용하여 얼굴 비율을 측정하고, 이를 바탕으로 주요 특징을 추출하였다. 턱 모양 분류를 위해 효율성과 정확도가 높은 EfficientNet B4 기반의 CNN 모델을 활용하였으며, 최종적으로 턱 모양 및 이목구비 특징을 개선된 자카드 알고리즘을 통해 분석하여 적합한 추천 결과를 도출하였다.

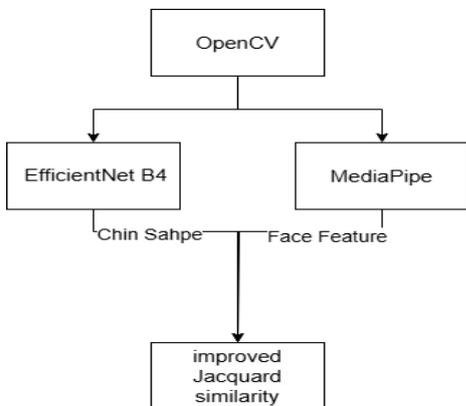


그림 1. 헤어스타일 추천시스템 구조
Fig. 1. Structure of the hairstyle recommendation.

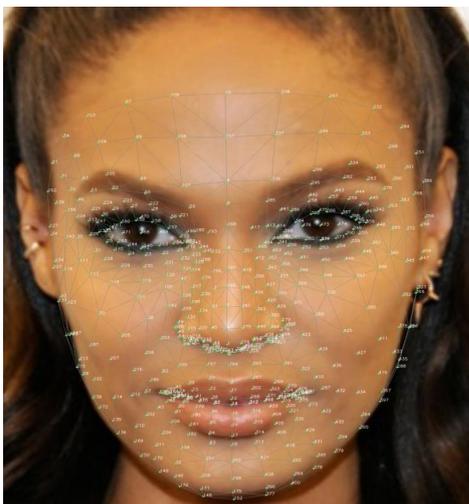


그림 2. Mediapipe 사용 예시
Fig. 2. Mediapipe example.

(1) 이목구비 분석

그림 2에서 보이듯이 각 지점에 표시된 숫자를 이용하여 비율을 측정하였고 '얼이 긴' 얼굴이나 '턱이 짧은' 얼굴 등 14가지의 특징을 추출하였다.

특징 분류 기준은 그림 3과 같이 8,000 명의 얼굴 비율을 분석한 결과를 바탕으로 Zwahlen et al.의 연구를 참고하여 황금 비율을 정의하는 데 참고하였다^[4].

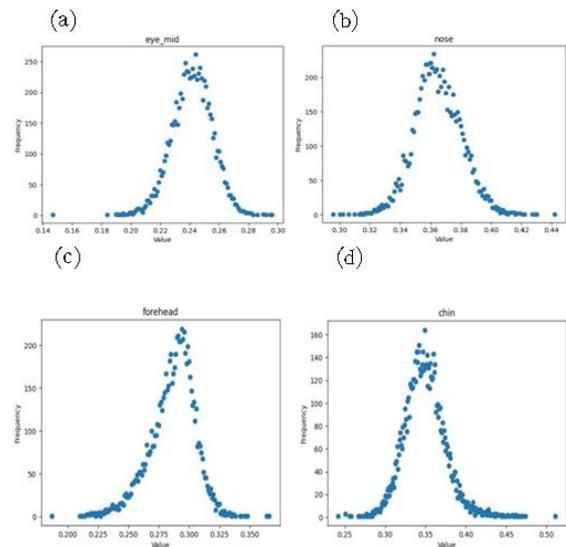


그림 3. (a) 미간 비율; (b) 코 비율; (c) 이마 비율; (d) 턱 비율

Fig. 3. Ratios: (a) Between the eyebrows; (b) Nose; (c) Forehead; (d) Chin.

특징별 이목구비의 기준은 표 1에서와 같이 사분위를 이용하여 Q1 보다 작다면 짧은 비율을 Q3의 값보다 작다면 긴 비율로 정하였다.

표 1. 이마, 코, 턱, 얼굴 세로, 광대의 사분위표
Table 1. Quartiles of forehead, nose, chin, vertical ratio, and cheekbone.

Feature	Q1 (Short/Low)	Q3 (Long/High)	Mean
Forehead	≤ 0.276	≥ 0.299	0.2863
Nose	≤ 0.355	≥ 0.375	0.3648
Chin	≤ 0.333	≥ 0.363	0.3489
Vertical ratio	≤ 0.476	≥ 0.542	0.5098
Cheekbone	≤ 0.161	≥ 0.175	0.1681

(2) 턱 모양 분석 모델

해당 모델에서는 턱 모양(각진 형, 둥근형, 세모형) 분류를 위하여 CNN 기반의 EfficientNet B4,

EfficientNet B5, ResNet50, VGG16 등 네 가지 모델을 비교·분석하였다.

더욱 높은 정확도를 갖기 위해서 잡음 추가 기법을 사용하였다. 잡음 추가(Noise addition)는 원본 데이터에 임의의 잡음을 추가하여 식별정보 노출을 방지한다. 이때 데이터 활용 목적에 따른 잡음의 크기, 연관 칼럼에 대해 동일한 잡음을 추가하는 중방향 일관성, 잡음 크기에 대한 예측 방지 등이 주요한 이슈이다^[5].

각 모델의 분류 정확도를 그림 4에 제시하였으며, 실험 결과 EfficientNet B4가 약 92~94%의 정확도를 보여 가장 우수한 성능을 나타냈다. 반면 EfficientNet B5는 약 88%, ResNet50은 약 90%, VGG16은 약 80%의 정확도를 보여 상대적으로 낮은 성능을 보였다. 이에 따라 본 연구에서는 가장 높은 정확도를 보인 EfficientNet B4를 최종 모델로 채택하여 턱 모양 분류 모델을 개발하고, 이를 예측에 활용하고자 한다.

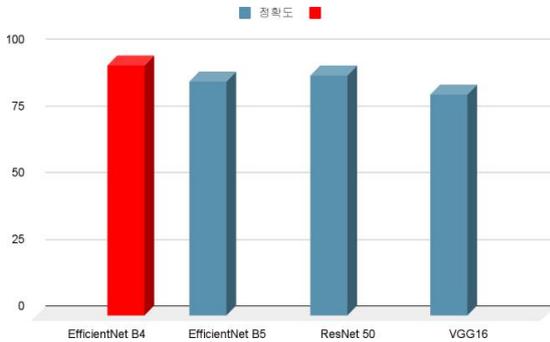


그림 4. EfficientNet B4, EfficientNet B5, ResNet 50, VGG16의 정확도

Fig. 4. Accuracy of EfficientNet B4, EfficientNet B5, ResNet 50, VGG16.

3. 얼굴 특징에 맞는 헤어스타일 기준

얼굴 특징에 따른 헤어스타일 추천은 추출된 특징을 활용하여 장점을 부각하고 단점을 보완하는 방식으로 이루어진다. 홍성희(2008)의 연구에 따르면 턱 모양(둥근형, 각진형, 세모형)과 얼굴 길이, 이마 및 광대 크기에 따라 얼굴형을 분류하고, 이에 맞춰 헤어스타일을 제시하는 것이 효과적이라고 보고되었다^[6]. 본 연구에서는 이러한 분류법을 바탕으로 얼굴형을 턱의 모형과 이목구비로 구분하고 유형별로 적합한 헤어스타일 특징을 선정하였다.

예를 들어 긴 얼굴형의 경우 이마가 넓어 보이거나 얼굴 길이가 부각될 수 있으므로 앞머리를 내려서 이마 노출을 줄이고 옆머리에 볼륨을 주어 세로로 긴 비율을 시각적으로 보완하는 것이 효과적이다. 또한 각진 형

얼굴은 상대적으로 턱선이 강조되기 쉬우므로 남자의 경우 남성성을 강조할 수 있지만 여성의 경우 긴 머리에 웨이브를 주어 각진 이미지를 완화할 수 있다. 이처럼 얼굴의 턱과 이목구비의 비율을 고려한 헤어스타일 추천을 통해 개인의 이미지 개선에 도움을 줄 수 있다.

4. 자카드 유사도 적용

본 연구에서는 자카드 유사도를 얼굴 특징별 추천 헤어스타일 데이터와 비교하여, 가장 적합한 헤어스타일을 추천하는 알고리즘에 적용한다.

표 2. 얼굴형에 따른 추천 헤어스타일 특징 테이블
Table 2. Features based on the shape of faces.

얼굴 특징	얼굴형별 추천헤어스타일 특징
긴 얼굴형	"가르마 머리", "내린머리", "옆 볼륨", "중간 기장", "컬", "뒷머리"
긴 코	"내린 머리", "옆 볼륨", "컬", "짧은 기장", "중간 기장"
긴 턱	"중간 기장", "긴 기장", "옆 볼륨", "컬"
세모형	"앞머리 볼륨", "옆 볼륨", "중간 기장", "긴 기장", "컬", "뒷머리"

표 3. 헤어스타일의 특징 테이블
Table 3. Features of hairstyles.

헤어스타일	헤어스타일의 특징
덴디펌X	"중간 기장", "내린 머리", "앞머리 볼륨", "다운펌"
리첸트	"짧은 기장", "올린 머리", "다운펌"
쉐도우펌	"중간 기장", "내린 머리", "앞머리 볼륨", "옆 볼륨", "컬"

자카드 유사도의 공식은 다음과 같다.

$$J(A, B) = \frac{|A \cap B|}{|A \cup B|}$$

- A: 얼굴 특징 (표 2)
- B: 헤어스타일 특징 (표 3)

자카드 유사도를 이용하여 공통되는 헤어스타일 특징을 찾아 유사도를 측정한다.

III. 실험

1. 가중치 부여 방식

본 연구에서 제안하는 추천시스템은 얼굴 특징에 따른 헤어스타일 추천 과정에서 중복되는 스타일 요소에

가중치를 부여하여 정확도를 향상한다. 가중치 부여는 사용자의 선호도와 얼굴 특징에 적합한 헤어스타일 간의 유사성을 강화하는 역할을 한다. 이를 위해 다양한 가중치 계산 방식을 설계하였으며, 가장 적합한 방식을 선택하여 추천 알고리즘에 적용하였다.

가중치 함수는 사용자가 가진 특정 얼굴 특징과 헤어스타일 데이터를 비교하여, 공통으로 나타나는 스타일 요소의 빈도를 기반으로 가중치를 부여한다. 이 과정에서 중복된 스타일 요소의 개수가 많을수록 가중치가 비선형적으로 증가하도록 설계되었으며, 이를 통해 특정 스타일 요소가 유사성 평가에서 적절한 영향을 미칠 수 있도록 구성하였다.

$$f(x) = \begin{cases} n \cdot FC[x] & \text{if } x \in FC \\ 1 & \text{if } x \notin FC \end{cases}$$

기본적인 가중치를 적용하는 방식은 아래식과 같다.

- x: 스타일 요소
- FC[x]: 스타일 요소 x의 빈도값.
- n: 중복되는 추천 헤어스타일 요소의 영향력을 조절하는 파라미터.

얼굴 특징에 따른 추천 헤어스타일 간의 유사성을 평가하기 위해, 자카드 유사도 $J(A,B)$ 를 가중치 함수와 결합하여 다음과 같이 정의한다.

$$J(A, B) = \frac{\sum_{x \in A \cap B} f(x)}{\sum_{x \in A \cup B} f(x)}$$

- A: 얼굴 특징에 따른 추천 헤어스타일 집합.
- B: 특정 헤어스타일의 특징 집합.
- f(x): 위에서 정의한 가중치 함수.

2. 가중치 변형 방법

얼굴 특징과 헤어스타일 간의 관계를 정밀하게 반영하기 위해 다양한 가중치 변형 방식을 제안하고 실험하였다. 각 변형 방식은 중복된 특징의 가중치를 계산하는 방식에 차이를 두어, 추천의 정확도 및 최적의 가중치를 도출하는 데 목표를 두고 있다.

본 연구에서는 가중치 계산 방식을 설계함에 있어, Huang at al. 논문에서 제안된 분포 균형 가중치 방법을 참고하였다. 이 접근법은 데이터 불균형 문제를 해결하고, 특정 요소의 중요도를 효과적으로 반영할 수 있는 가중치 계산 방식을 제공한다.

(1) 탄젠트 함수적용

탄젠트 함수는 중복된 특징의 가중치를 비선형적으로 조정하여, 중복의 중요성을 고려하면서도 가중치의 과도한 증폭을 방지하는 방식이다. 이는 특정 특징이 아무리 중요하더라도, 그 영향이 지나치게 커지는 것을 제한하고 안정적으로 조정하기 위해 사용된다. 다음과 같은 수식을 사용한다.

$$\tanh(n * FC)$$

이 방식은 데이터의 변동성을 반영하면서도, 과도한 가중치 부여로 인해 발생할 수 있는 추천 시스템의 왜곡을 줄이는 데 적합하다. tanh 함수의 이러한 안정적 특성은 중복된 특징의 영향을 효과적으로 반영하는 동시에 추천 정확도를 개선하는 데 기여한다.

(2) 지수 함수적용

아래 수식에서, $e^{0.1 \times n}$ 은 중복 횟수에 따른 기하급수적 증가를 의미하며, 이는 특징이 자주 등장할수록 가중치가 빠르게 증가하는 효과를 가져온다.

$$e^n \times FC$$

(3) 시그모이드 함수 적용

시그모이드 함수는 중복되는 특징의 가중치를 비선형적으로 조정하면서도, 0과 1 사이의 값으로 정규화하는 특성을 가진다. 이는 특정 특징이 과도하게 많이 중복되더라도 가중치가 일정 수준 이상으로 증가하지 않도록 제한하는 효과가 있다. 다음과 같은 수식을 사용한다

$$1/(1 + e^{-n \times FC})$$

여기서 n은 시그모이드 곡선의 기울기를 조절하는 매개변수이고, 시그모이드 함수의 S자 형태 특성으로 인해, 중복 빈도가 낮은 구간에서는 완만한 가중치 증가를, 중간 구간에서는 급격한 증가를, 높은 구간에서는 다시 완만한 증가를 한다. 이러한 특성은 중복 빈도에 따른 가중치 부여를 자연스럽게 조절할 수 있게 한다.

(4) 루트-로그 조합 방식

루트와 로그 함수를 조합한 이 방식은 중복 빈도의 증가에 따른 가중치 상승을 점진적으로 감소시키면서도, 초기 중복에 대해서는 충분한 가중치를 부여하는 특징이 있다. 수식은 다음과 같다

$$\sqrt{1 + \log(1 + FC)}$$

이 방식은 극단적인 가중치 부여를 방지하면서도 중요 특징을 효과적으로 반영할 수 있다.

3. 응용 및 확장 가능성

본 연구에서 제안한 가중치 기반 자카드 유사도 개선 방식은 헤어스타일 추천 시스템을 넘어 다양한 분야에 적용될 수 있다. 특히 다중 특성을 가진 아이템을 추천하는 시스템에서 효과적으로 활용될 수 있으며, 구체적인 적용 분야는 다음과 같다.

첫째, 패션 스타일링 추천 시스템에 적용할 수 있다. 사용자의 체형, 피부톤, 선호 스타일 등 다양한 특성이 중복되는 경우, 본 연구의 가중치 부여 방식을 통해 더욱 정교한 의류 추천이 가능하다. 예를 들어, 특정 체형에 적합한 의류 스타일이 다른 특성과 중복될 경우, 해당 스타일에 더 높은 가중치를 부여하여 추천의 정확도를 높일 수 있다.

둘째, 화장품 추천 시스템에 확장 적용이 가능하다. 피부 타입, 피부 고민, 선호하는 제형 등 여러 특성이 교차하는 경우, 중복되는 특성에 가중치를 부여함으로써 사용자에게 최적화된 제품을 추천할 수 있다. 특히 민감성 피부나 특정 성분 선호도와 같은 중요 특성이 중복될 때, 이를 가중치에 반영하여 더욱 신뢰성 있는 추천이 가능하다.

4. 실험 및 비교 분석

본 연구에서는 얼굴 특징과 헤어스타일 간의 연관성을 반영한 추천 알고리즘을 개발하고, 다양한 가중치 변형 방식을 적용하여 성능을 평가하였다. 턱 모양을 기준으로 세모형, 각진형, 둥근형 각각 33% 총 100명의 연예인의 헤어스타일 데이터를 사용하여 각 가중치 변형 방식의 성능을 평가하였으며, 각 가중치마다 상위권에 해당 연예인이 실제로 선택한 헤어스타일이 포함되었는지를 기준으로 평가한 결과 가장 점수가 높게 나온 가중치 계산식은 다음과 같다.

$$\tanh(0.07 * FC)$$

위 식에서 0.07은 최적화된 파라미터를 가리킨다.

탄젠트 함수의 포화 특성을 통해 가중치의 과도한 증폭을 방지하였으며, FC의 값에 따라 가중치를 비선형적으로 증가시키는 효과를 제공하였다. 이를 통해 중복된 특징이 많을수록 중요도가 적절히 반영되면서도 안

정적으로 조정된 가중치를 적용할 수 있었다.

아래의 그래프는 기존 자카드 유사도 방식과 제안된 가중치 계산 방식을 비교한 결과를 나타낸다. 제안된 방식은 기존 방식 대비 약 43.86%의 성능이 향상했다.

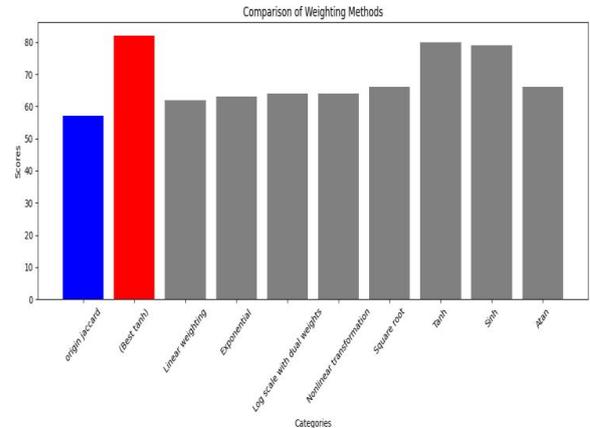


그림 5. 10개의 가중치 방식

Fig. 5. 10 ways of using weights.

IV. 결 론

본 연구에서는 중복 요소에 가중치를 부여한 개선된 자카드 유사도 방식이 기존의 자카드 유사도 기반 헤어스타일 추천 시스템보다 높은 정확도를 보임을 실증적으로 검증하였다.

향후 연구에서는 더 방대하고 다양한 헤어스타일 데이터셋을 구축하여 가중치 부여 방식의 변형을 시도할 계획이다. 특히, 현재 경험적으로 설정된 가중치 계산식의 파라미터(0.07)를 머신러닝 기법을 통해 최적화하고, 강화학습을 활용하여 동적으로 최적의 가중치를 학습하는 개선된 자카드 유사도 기반 추천 시스템을 개발하고자 한다. 이를 통해 보다 정교하고 개인화된 헤어스타일 추천 서비스를 제공할 수 있을 것으로 기대된다.

REFERENCES

- [1] S.-H. Park, "An Improved User-Based Collaborative Filtering Recommendation System Using Rating-Based Jaccard Similarity", Master's Thesis, Seoul National University of Science and Technology, pp. 1-8, Aug. 2023.
- [2] H. Yoo, S. Kim, and C.-B. Chae, "Deep Learning-Based Semantic Communications Research Trends", The Magazine

- of the IEIE, vol. 49, no. 11, pp. 853–861, Nov. 2022.
- [3] Y. Huang, B. Giledereli, A. Köksal, A. Özgür, and E. Ozkirimli, "Balancing Methods for Multi-label Text Classification with Long-Tailed Class Distribution", Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing, pp. 8153–8161, Nov. 2021.
- [4] R. A. Zwahlen, A. T. H. Tang, W. K. Leung, and S. K. Tan, "Is three-dimensional facial attractiveness related to the golden ratio, neoclassical canons, 'ideal' ratios and angles?", Maxillofacial Plastic and Reconstructive Surgery, vol. 44, no. 1, p. 28, 2022.
- [5] J. Doe and A. Smith, "De-identification Technology for Next-generation Artificial Intelligence", The Magazine of the IEIE, vol. 48, no. 10, pp. 824–834, Nov. 2022.
- [6] S.-H. Hong, "Factors Influencing Hairstyle Decisions According to Women's Face Shapes", Master's Thesis, Daegu Haany University Graduate School of Health, pp. 6–14, Feb. 2008.

— 저 자 소 개 —



이 상 민(비회원)
2015년 한경국립대학교
컴퓨터공학과
소프트융합전공 학사 졸업.

<주관심분야: 머신러닝, 딥러닝, 데이터분석, CNN>



정 재 형(비회원)
2015년 한경국립대학교
컴퓨터공학과
소프트융합전공 학사 졸업.

<주관심분야: 웹프로그래밍, UI/UX 디자인>



이 계 식(비회원)
2005년 University of
Muenster, Germany
수학 및 전산학과
박사 졸업.
2011년~현재 한경국립대학교
소프트웨어융합
전공 교수.

<주관심분야: 머신러닝, 딥러닝, 데이터분석, 프로그래밍언어론, 정형검증>