

Stable Diffusion 과 ControlNet 을 활용한 성분 배합비 기반 립 메이크업 시뮬레이션

정다슬⁰ 박진호*
숭실대학교 정보과학대학원 인공지능학과,
숭실대학교 글로벌미디어학부
{daseulll, c2alpha}@soongsil.ac.kr

Formula-Driven Lip Makeup Simulation Using Stable Diffusion and ControlNet

Daseul Jeong⁰ Jinho Park*
Graduate School of Information Science, Soongsil University
School of Media, Soongsil University

요 약

화장품 립 제품 개발 현장에서 배합비 변경 시마다 시제품 재제조와 육안 확인을 반복해야 하는 비효율을 화장품 립 제품의 성분 배합비(유기 색소, 무기 안료, 왁스, 오일, 진주 광택제, 필름 형성제)를 정량적 입력값으로 활용해, 발색 색상과 질감 특성을 시각적으로 시뮬레이션하는 인공지능 기반 립 메이크업 생성 시스템을 제안한다. 기존의 머신러닝 기반 연구는 수치적 물성 예측에 그쳐 시각적 확인이 어려웠고, GAN 및 확산 모델 기반의 가상 메이크업 연구는 실제 화장품의 정량적 배합 정보를 반영하지 못한다는 한계가 있었다. 이러한 문제를 해결하기 위해 성분 배합비를 정규화된 벡터로 변환하고, 다층 퍼셉트론(MLP)을 통해 색상, 광택, 불투명도 등의 시각적 속성을 예측하는 구조를 확립하였다. 나아가 예측된 색상 데이터를 공간적 조건 지도로 변환하여 ControlNet의 입력으로 활용함으로써 배합비에 부합하는 정밀한 색상을 구현하였다. 또한, 원료 특성 기반의 유효 광택 지수를 정의하고, 이에 따라 생성 모델의 컨디셔닝 스케일과 디노이징 강도를 동적으로 제어함으로써 입술의 질감 표현력을 극대화하였다. 정량적·정성적 실험 및 화장품 업계 전문가들을 대상으로 한 사용성 평가를 통해, 본 시스템이 실제 R&D 현장에서 시제품 제작 루프를 단축하고 초기 배합 설계의 예측력을 높이는 데 실질적으로 기여할 수 있음을 입증하였다.

Abstract

In the development process of cosmetic lip products, repeated prototype manufacturing and visual inspection are often required whenever the formulation ratio changes, resulting in significant inefficiency. To address this issue, this paper proposes an artificial intelligence-based lip makeup generation system that visually simulates lip color and texture characteristics using quantitative cosmetic formulation information, including organic pigments, inorganic pigments, waxes, oils, pearlescent agents, and film formers. Existing machine learning-based approaches have mainly focused on numerical property prediction, making visual verification difficult, while GAN- and diffusion-based virtual makeup studies have limitations in reflecting quantitative cosmetic formulation information. To overcome these limitations, formulation ratios were converted into normalized vectors, and a multilayer perceptron (MLP)-based regression structure was designed to transform formulation information into visual attributes such as color, glossiness, and opacity. Furthermore, the predicted color information was converted into a spatial condition map and utilized as an input condition for ControlNet, enabling generation results that reflect formulation-based color characteristics. In addition, an effective gloss index based on ingredient characteristics was defined, and the conditioning scale and denoising strength of the generation model were dynamically adjusted according to the gloss characteristics to improve lip texture representation. Through quantitative and qualitative experiments, as well as a usability evaluation involving cosmetic industry practitioners, the proposed system demonstrated the potential to reduce repetitive prototype production processes and support early-stage formulation design in cosmetic R&D workflows.

키워드: 립 메이크업 시뮬레이션, Stable Diffusion, ControlNet, 배합비 예측, 질감 제어, 이미지 인페인팅

Keywords: Lip Makeup Simulation, Stable Diffusion, ControlNet, Formula Prediction, Texture Control, Image Inpainting

1. 서론

화장품 분야에서 ‘발색’이란 색소가 피부 표면과 만나면서 실제로 드러나는 색상의 변화를 말한다. 똑같은 립

*corresponding author: Jinho Park / School of Media, Soongsil University (c2alpha@ssu.ac.kr)

제품을 사용해도, 피부 언더톤과 피부 상태에 따라 발색 결과가 다르게 나타날 수 있다[1]. 이런 다양성 때문에 화장품 발색을 정확히 예측하는 일은 쉽지 않은 과제로 남아 있다

화장품 연구개발 현장에서는 일반적으로 성분 배합비를 여러 차례 바꿔가며 시제품을 만들고, 그때마다 발색 결과를 직접 확인하는 과정을 반복한다. 이 작업은 많은 시간과 노력이 들어가며, 초기에 어떤 배합을 선택하든 결과를 단번에 예측하기 어렵다는 어려움이 뒤따른다. 최근 들어 화장품 업계 또한 디지털 전환 바람을 타고, 인공지능 기반 시뮬레이션 기술에 대한 관심이 점점 높아지는 중이다.

지금까지의 관련 연구 흐름은 크게 두 갈래로 나눌 수 있다. 첫째, 머신러닝을 이용해 물성을 예측하려는 시도들을 보면[2,6], 배합비로부터 CIE Lab* 색상값이나 광택 같은 물리적 속성을 추정하는 방식이 많이 제안되었다. 이러한 연구는 배합비와 시각적 특성 사이의 관계를 수치로 분석하는 데에는 의미가 있지만, 실제 발색을 이미지로 보여주는 데에는 한계가 따르기도 한다.

둘째, GAN을 활용한 가상 메이크업 연구[3,9,11]는 얼굴 이미지에 메이크업 스타일을 입히는 쪽으로 발전했다. BeautyGAN[4], PSGAN[9] 같은 대표적 사례가 있는데, 자연스러운 립 메이크업 이미지를 합성하는 데 성공했지만, 대부분 참조 이미지를 바탕으로 스타일만 옮겨올 뿐, 화장품의 세부 배합 정보 같은 정량적 요인은 직접 반영하지 않는다.

요즘엔 Stable Diffusion과 ControlNet처럼 조건부 이미지 생성에 특화된 최신 생성모델 연구도 눈에 띄게 활발해졌다[4,5]. 이런 방법은 텍스트나 공간 조건을 입력해 고화질 이미지를 손쉽게 만들어낼 수 있다는 장점이 있지만, 여전히 화장품 배합비와 질감 특성까지 동시에 아우르는 연구는 드물다.

그래서 본 연구에서는 화장품 립 제품의 성분 배합비를 입력값으로 삼아, 발색과 질감 특성을 동시에 시각화해주는 인공지능 기반 립 메이크업 생성 시스템을 새롭게 제안한다. 제안 시스템은 주어진 배합 정보를 바탕으로 색상과 질감을 먼저 예측해낸 뒤, Stable Diffusion과 ControlNet 기반의 생성 모델에 이 결과를 반영해 립 메이크업 이미지를 완성하는 구조로 설계되어 있다.

(1) 화장품 배합비를 6 차원 벡터로 정규화하고, MLP(다층 퍼셉트론) 기반 회귀 모델을 통해 CIE Lab* 색상값, 광택, 불투명도 등 주요 시각 속성을 예측하는 ‘배합비-시각 속성 변환’ 구조를 구현했다.

(2) 예측한 색상 정보를 Color Condition Map(CCM)으로 변환하여 ControlNet의 공간 조건 입력에 활용, 배합비 기반 색상 특성이 실제 이미지 생성 과정에서 잘 반영되도록 하였다.

(3) 왁스와 오일의 비율에서 산출한 유효 광택 지수를 바탕으로, ControlNet의 컨디셔닝 스케일(λ)과 DDIM strength(s)를 동적으로 조절하여, 이미지 질감 표현을 정교하게 다루는 방식을 제안했다.

(4) 실제 화장품 업계 전문가들이 참여한 사용성 평가를 통해, 본 시스템이 현장 R&D 환경에서 실질적으로 활용될 가능성도 함께 점검했다.

이후 2 장에서는 관련된 기존 연구들을 정리하고, 3 장에서는 시스템 구조를 자세히 소개한다. 4 장에서는 실험 결과를 살펴보고, 5 장에서 사용성 평가 사례를, 마지막 6 장에서는 연구의 결론과 향후 과제에 대해 논의한다.

2. 관련 연구

2.1 배합비 기반 물성 예측 연구

화장품 원료와 물리적 특성의 관계를 정량화하는 연구는 축색학과 화장품 화학 분야에서 오랫동안 수행되어 왔다. Lin 등(2006)[2]은 립스틱 색소 농도와 CIE L*a*b* 발색값 간의 선형 회귀 모델을 제안하였으며, Lochhead(2008)[3]는 왁스 함량이 제품의 경도와 매트 질감을 결정하고 오일 성분이 광택과 밀착도를 제어한다는 원리를 체계적으로 기술하였다. Mitra 등(2021)[6]은 유기 색소와 무기 안료의 배합 비율이 CIE a*(적-녹) 및 b*(황-청) 좌표를 결정하며, 진주 광택제(마이크)가 이리데스트 반사 효과를 부여함을 실험적으로 입증하였다.

최근에는 SVR, 랜덤 포레스트, MLP와 같은 머신러닝 기법을 활용하여 복수 성분 간의 비선형 교호작용을 모델링하고 색도·광택도·불투명도를 동시에 예측하는 연구들이 등장하였다[3,6]. 그러나 이들 연구는 공통적으로 수치 출력에 그치며, 예측 결과를 실제 발색 이미지로 가시화하는 단계로는 나아가지 못하였다.

2.2 GAN 기반 가상 메이크업

2018년 Li 등이 발표한 BeautyGAN[4]은 생성적 적대 신경망(GAN)을 이용해 참조 이미지의 메이크업 스타일을 다른 얼굴 사진에 자연스럽게 입히는 방식을 제안했다. 이 논문에서는 전역 도메인 손실 함수와 부위별 히스토그램 손실 함수를 결합함으로써, 보다 그럴듯한 메이크업 전이 결과를 얻어냈다. 하지만 메이크업이 적용된 참조 이미지가

필수적으로 필요하다는 한계가 있었고, 화장품의 성분 배합비와 같은 구체적인 정량 입력을 직접 반영하기에는 한정적인 모습을 보였다.

이후 Jiang 등(2020)의 PSGAN[9]은 공간 인식 어텐션 메커니즘을 도입하여 자세·표정 변화에 강건한 메이크업 전이를 구현하였으며, Deng 등(2021)의 LADN[10]은 국소 적대적 분리 네트워크로 더욱 세밀한 부위별 메이크업 제어를 달성하였다. 그러나 이들 방법 역시 참조 이미지의 존성이라는 구조적 한계를 벗어나지 못하였다.

확산 모델 측면에서 Rombach 등(2022)[7]은 잠재 공간에서 확산 과정을 수행하는 잠재 확산 모델(LDM)을 제안하여 높은 품질의 이미지 생성을 가능하게 하였다. 이를 기반으로 한 Stable Diffusion 의 Inpainting 기능[7]은 마스크로 지정된 영역만 선택적으로 재생성할 수 있어 립 영역 발색 합성에 적합하다. 그러나 텍스트 프롬프트만으로는 배합비의 정량적 정보를 정밀하게 반영하기 어렵다.

2.3 Stable Diffusion 및 ControlNet

Zhang 등(2023)[5]이 제안한 ControlNet 은 사전 학습된 확산 모델[7]의 가중치를 완전히 고정한 채로, 동일한 인코더 구조의 복사본 네트워크와 영(0)으로 초기화된 제로 컨볼루션(zero convolution) 레이어를 통해 엣지 맵[5], 깊이 맵[5], 색상 맵 등의 공간적·정량적 조건을 이미지 생성 과정에 직접 주입한다. 이 구조는 소규모 데이터셋으로도 안정적인 조건부 제어 학습이 가능하다는 장점을 가진다[5].

국내에서는 송미영·김용선(2021)[11]이 모바일 AR 환경에서 얼굴형에 최적화된 가상 메이크업을 제공하는 시스템을 제안하였으며, 안예은 등(2024)[12]은 안면 색상 데이터 분석 기반의 퍼스널 컬러 진단 및 가상 메이크업 애플리케이션을 개발하였다. 그러나 이들 연구는 배합비 기반 발색 예측 기능을 포함하지 않는다. Table 1 은 관련 연구들의 기술적 차별성을 종합 비교한 결과이다.

Table 1. 관련 연구 기술 비교

3. 제안하는 시스템

3.1 전체 파이프라인 구조

연구에서 제안한 시스템은 얼굴 이미지, 또는 입술만 잘라낸 이미지를 입력받아, 화장품 성분 배합비가 담긴 텍스트를 함께 활용한다. 그러면 주어진 배합비에 맞는 색감과 질감이 자연스럽게 어우러진 립 메이크업 이미지를 만들어내도록 구성했다. 사용자는 입술 부분을 직접 골라

지정할 수도 있고, 자동 검출 기능을 통해 간편하게 영역을

Method	Generation Method	Color Control	Texture Control	Formula Input	Reference Image Required	Dynamic Parameter Control
[4] BeautyGAN	GAN	Supported	Partial Support	✗	Required	✗
[9] PSGAN	Attention GAN	Supported	Partial Support	✗	Required	✗
[7] Stable Diffusion Inpainting	Diffusion	Supported	Limited	✗	Not Required	✗
[5] SD + ControlNet	Diffusion + ControlNet	Supported	Partial Support	✗	Not Required	✗
Proposed	Diffusion + ControlNet + MLP	Supported	Multi-texture Support	✓	Not Required	✓

설정할 수도 있다. 이후 시스템은 입력 정보에 따라 립 부위에 맞춘 발색 시뮬레이션을 실행한다.

전체 시스템은 총 네 단계로 이루어진 파이프라인을 거친다. 먼저 Module 1에서는 입술 영역을 세분화(세그멘테이션)하고, 이어서 Module 2에서 배합비 정보를 시각적 속성으로 변환한다. 다음으로 Module 3은 ControlNet 기반 이미지 생성 과정을 담당하고, 마지막으로 후처리 단계에서는 Poisson Blending 기법을 적용해 이미지를 자연스럽게 다듬는다. 각 단계는 입력된 배합비와 이미지 정보를 순차적으로 처리하며, 이 모든 과정을 거쳐 질감과 색상이 입술 위에 자연스럽게 반영된 최종 결과물을 완성한다.





Figure 1. Overall Pipeline of the Proposed System.

3.2 Module 1: 입술 세그멘테이션

입술 영역을 추출하기 위해, Gradio 기반 인터페이스에 스케치 도구를 활용해 사용자가 직접 윗입술과 아랫입술의 경계를 그릴 수 있도록 만들었다. 여기에 더해, 자동으로 입술 부분을 마스킹해주는 기능도 제공하고자 MediaPipe Face

Mesh 를 적용했다. MediaPipe Face Mesh 는 얼굴 전체에 총 468 개의 3D 랜드마크 좌표를 뽑아주는데, 이 중 입술에 해당하는 인덱스만 뽑아서 입술 외곽선을 얻었다.

추출된 입술 랜드마크 좌표를 기반으로 Convex Hull 연산을 수행하여 이진 마스크 M_{bin} 을 생성하였다. Convex Hull 연산은 랜드마크 간의 불연속 영역을 보완하고 안정적인 입술 마스크 형태를 생성하기 위해 적용하였다. 이후 Gaussian Blur 를 적용하여 소프트 마스크 M_{soft} 를 생성하였으며, 이를 통해 입술 경계 부근에서 발생할 수 있는 부자연스러운 경계 현상을 완화하고 보다 자연스러운 합성 결과를 얻고자 하였다.



.Figure 2. Lip Segmentation and Soft Mask Generation Process.

3.3 Module 2: 배합비-시각 속성 변환

사용자가 입력한 성분 배합비 텍스트는 정규 표현식 기반 파서를 통해 성분명과 농도 정보를 추출하며, 이를 6 차원 벡터

$$f = [f_{\{org\}}, f_{\{inorg\}}, f_{\{wax\}}, f_{\{oil\}}, f_{\{pearl\}}, f_{\{film\}}] \in \mathbb{R}^6$$

형태로 정규화하였다. 각 벡터 요소는 유기 색소, 무기 안료, 왁스, 오일, 진주 광택제, 필름 형성제의 상대적 비율을 의미한다.

정규화된 배합비 벡터는 MLP 기반 회귀 모델의 입력으로 사용되며, 모델은 입력된 배합비와 시각 속성 간의 관계를 학습하여, CIE Lab* 색상값, 광택 지수(Gloss Index), 불투명도(Opacity)로 구성된 5 차원 시각 속성 벡터를 변환하도록 구성하였다. (Table 2 참조).

Table 2. MLP-based Formula-to-Visual Attribute Conversion Model

Layer	Nodes	Activation / Remark
Input	6	Formula Vector Input
Hidden 1	64	Batch Normalization + ReLU + Dropout
Hidden 2	32	Batch Normalization + ReLU + Dropout
Hidden 3	16	Batch Normalization + ReLU + Dropout
Output	5	Lab* 색상값, 광택 지수, 불투명도

손실 함수는 예측된 시각 속성과 목표 시각 속성 간의 차이를 줄이기 위한 방식으로 구성하였다.

색상 관련 속성(L*, a*, b*)은 Lab* 색공간 기반 오차를 중심으로 학습하였으며,

평가 단계에서는 ΔE2000 색차 개념을 참고하여 생성 결과의 색상 차이를 정성적으로 분석하였다.

또한 광택 및 불투명도와 같은 질감 관련 속성에 대해서도 오차 기반 손실 항을 함께 적용하여, 생성 과정에서 질감 특성이 일부 반영될 수 있도록 구성하였다.




Figure 3. Architecture of the MLP-based Formula-to-Visual Attribute Conversion Model.

3.4 Module 3: ControlNet + SD Inpainting

예측된 CIE Lab* 색상값은 OpenCV 기반 색공간 변환을 통해 RGB 형태로 변환하였다.

이후 입술 마스크 영역에 예측된 색상을 반영한 가이드 이미지를 생성하였으며,

이를 색상 조건 맵(Color Condition Map, CCM)으로 정의하였다. 생성된 CCM 은 ControlNet 기반 조건부 생성 모델의 공간 조건 입력으로 활용하였으며, Stable Diffusion v1.5 기반 Inpainting 모델을 이용하여 입술 영역에 대한 립 메이크업 이미지 생성 과정을 수행하였다.

이를 통해 입력된 배합비 기반 색상 특성이 생성 과정에 조건 정보로 활용될 수 있도록 구성하였다.

또한 배합비 기반 시각 속성 정보를 바탕으로 질감 관련 프롬프트 조건을 함께 적용하였다.

예를 들어 matte, satin, glossy 와 같은 질감 유형에 따라 서로 다른 프롬프트 조건을 적용하였으며,

예측된 색상 정보를 기반으로 nude pink, coral 계열 등의 색상 표현 키워드를 함께 활용하여 생성 이미지의 시각적 특성을 조절하였다.




Figure 4. ControlNet-based Stable Diffusion Inpainting Architecture.

3.5 동적 질감 제어 메커니즘

기존의 조건 기반 이미지 생성 연구에서는 생성 파라미터를 고정값으로 사용하는 경우가 많았다. 그러나 본 연구에서는 립 제품의 질감 특성을 보다 유연하게 반영하기 위해, MLP 기반 예측 광택 지수 G 와 오일 비율 정보를 결합한 유효 광택 지수 G_{eff} 를 정의하였다.

$$G_{eff} = G \times 0.7 + \left(\frac{f_{oil}}{f_{wax} + f_{oil} + \epsilon} \right) \times 0.3$$

여기서 f_{oil} 과 f_{wax} 는 각각 오일 및 왁스 성분의 상대적 비율을 의미하며, ϵ 은 0 으로 나누는 상황을 방지하기 위한 작은 상수이다. 가중치 값은 예비 실험 결과를 기반으로 경험적으로 설정하였다.

계산된 G_{eff} 값은 생성 단계에서 질감 유형을 구분하기 위한 기준값으로 활용하였다. 본 연구에서는 G_{eff} 범위에 따라 Matte, Satin, Glossy 계열로 질감을 구분하였으며, 각 질감 유형에 따라 ControlNet conditioning scale(λ), 생성 강도, inference step 수, CFG scale 값을 다르게 설정하였다. 이를 통해 질감 유형에 따른 시각적 차이를 생성 이미지에 반영하고자 하였다.

Table 3. 질감 유형별 동적 생성 파라미터 설정

Finish	G_{eff}	λ (CN)	s (DDIM)	Steps	CFG	Visual Characteristic
Matte	<0.25	0.30	0.60	40	7.0	부드럽고 확산된 질감
Satin	0.25– 0.60	0.65	0.72	45	7.5	은은한 광택 표현
Glossy	≥ 0.6 0	0.95	0.82	50	8.0	광택감이 강조된 질감

3.6 웹 인터페이스 및 시스템 구조 (Figure 5)

시스템 구현을 위해 Gradio 기반 웹 인터페이스를 구성하였으며, Google Colab 의 NVIDIA Tesla T4 GPU 환경에서 생성 실험을 수행하였다.

Figure 5 에는 실제 시스템 실행 화면과 생성 결과 예시를 함께 제시하였다.

화면의 왼쪽 패널을 보면, 사용자는 입술 이미지를 업로드한 뒤에 마스크링 도구를 사용해 입술 영역을 직접 지정할 수 있다. 또, 그 아래에 위치한 입력창에 성분명과 배합비 정보를 텍스트로 입력하게끔 설계했다. 이렇게 필요한 입력을 마친 후 ‘스마트 배합 렌더링’ 버튼을 누르면, 오른쪽 패널에서 바로 생성된 이미지와 함께 배합에 대한 해석

결과까지 확인할 수 있다.




Figure 5. Web Interface of the Proposed System

배합비 텍스트는 정규표현식 기반 파서를 통해 성분명(한글 및 영문)과 농도 정보를 추출하도록 구성하였다. 또한 시스템은 글리터, 마이카, 카올린과 같은 질감 관련 보조 성분 정보를 함께 분석하여 생성 과정에 반영하였다.

배합 해석 패널에서는 추정 피니시 유형, 추정 색상명, RGB 및 HEX 색상 코드, 성분 인식 결과, 매트/글로시 점수 등을 함께 제공하여 사용자가 생성 결과의 특성을 직관적으로 확인할 수 있도록 하였다.

4. 실험 및 결과 분석

4.1 실험 환경 및 데이터셋

모든 실험은 Google Colab Pro+ T4 GPU 환경에서 수행하였다. Stable Diffusion 기반 생성 파이프라인은 HuggingFace Diffusers 환경에서 구현하였으며, 배합비-시각 속성 변환 모델은 PyTorch 기반으로 구성하였다.

실험 데이터는 립 제품의 대표적인 색상 및 질감 유형을 반영한 약 50 개의 배합 사례를 기반으로 구성하였다.

각 사례는 성분명 및 배합비 정보와 이에 대응하는 립 발색 이미지를 포함하며,

Matte, Satin, Glossy 계열의 질감 유형을 포함하도록 구성하였다.

또한 생성 결과 평가를 위해 사용자가 지정한 입술 마스크 이미지와 다양한 립 색상 사례를 활용하여 생성 결과 비교 실험을 수행하였다

4.2 평가 지표

본 연구에서는 생성 결과의 색상 및 질감 표현 특성을

확인하기 위해 생성 이미지 기반 정성 평가와 전문가 사용성 평가를 수행하였다.

우선 생성 결과 평가에서는 입력된 배합비 특성이 생성 이미지에 적절히 반영되는지를 중심으로 확인하였다. 이를 위해 CIE Lab* 색공간 기반 색상 비교와 ΔE_{2000} (CIEDE2000) 색차 개념을 참고하여 생성 결과와 목표 색상 간의 시각적 차이를 비교하였다. 또한 Matte, Satin, Glossy 유형에 따른 질감 표현 차이를 중심으로 생성 결과를 정성적으로 분석하였다.

추가적으로 실제 시스템의 실무 활용 가능성을 확인하기 위해 화장품 업계 종사자 20 명을 대상으로 사용성 기반 설문 평가를 수행하였다. 참가자들은 실제 시스템을 사용하여 다양한 배합 사례를 입력하고 생성 결과를 확인한 뒤, 색상 표현 만족도, 질감 표현 만족도, 실무 활용 가능성 등에 대해 5 점 리커트 척도로 응답하였다.

본 연구는 대규모 수치 기반 성능 비교보다는, 생성형 AI 기반 립 메이크업 시뮬레이션 시스템의 구현 가능성과 실무 적용 가능성을 확인하는 데 초점을 두었다. 따라서 생성 결과의 시각적 특성과 사용자 기반 활용성 평가를 중심으로 분석을 수행하였다.

4.3 정성적 평가 — 실제 시스템 수행 결과 (Figure 4)

Figure 4 는 세 가지 실제 배합 케이스의 시뮬레이션 수행 결과이다. 좌측은 원본 입술 이미지+마스킹 영역, 우측은 생성 결과이다.




Figure 4 (a) . Coral/Orange Matte 계열 생성 결과

(a)는 적색산화철, 황색산화철, 적색 201 호 및 카올린 조합

기반의 사례이다. 생성 결과에서는 오렌지·코랄 계열 색상이 형성되었으며, 광택 표현이 상대적으로 낮게 나타났으며, 입술 주름 구조가 비교적 유지되는 무광 계열 질감이 표현되었다. 특히 카올린 성분이 포함된 사례에서 Matte 계열과 유사한 시각적 특성이 나타나는 경향을 확인할 수 있었다

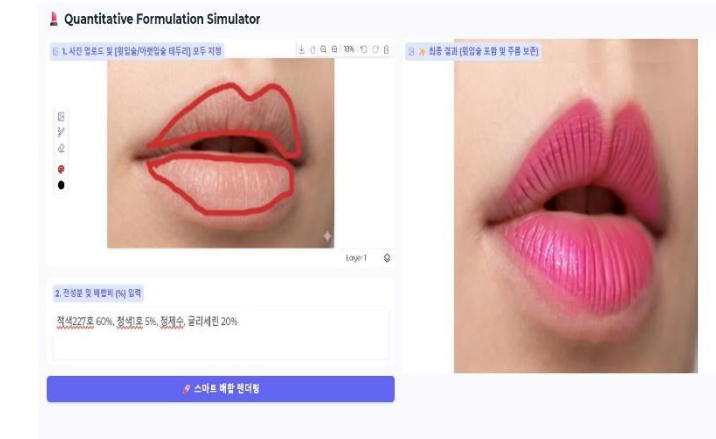


Figure 4 (b) . Glossy Pink 계열 생성 결과

(b)는 적색 227 호, 청색 1 호, 정제수, 글리세린 조합을 입력한 사례이다. 생성 결과에서는 밝은 핑크 계열 색상이 표현되었으며, 입술 중앙부를 중심으로 상대적으로 높은 광택감이 나타났다. 또한 입술 주름 구조가 일부 유지되면서도 상대적으로 높은 광택 특성이 함께 표현되는 경향을 확인할 수 있었다.




Figure 4 (c) . Satin/Nude Rose 계열 생성 결과와 자동 배합 분석

(c)는 적색 104 호, 황색산화철, 티타늄디옥사이드, 호호바오일, 마이카 등의 조합을 입력한 사례이다. 생성 결과에서는 밝은 누드로즈 계열 색상이 생성되었으며, Matte

계열 대비 은은한 광택감이 함께 표현되었다. 또한 Figure 4(c)에서는 생성 결과와 함께 자동 배합 분석이 출력되는 실제 시스템 화면을 함께 확인할 수 있다.

5. 화장품 산업 종사자 사용성 평가

5.1 설문 설계 및 대상

실제 활용 가능성을 확인하기 위해 화장품 업계 종사자 20 명을 대상으로 체험 기반 사용성 평가를 실시하였다. 참가자는 연구·개발(R&D) 분야 종사자 10 명과 영업·마케팅 분야 종사자 10 명으로 구성하였다.

평가 참가자들은 실제 시스템을 직접 사용하여 대표적인 배합 사례를 기반으로 생성 결과를 확인하였다. 이후 색상 표현 만족도, 질감 표현 자연성, 실무 활용 가능성, 개발 효율성 등에 대해 5 점 리커트 척도(1=매우 그렇지 않다, 5=매우 그렇다) 기반 설문에 응답하였다.

또한 Figure 4 의 Matte, Satin, Glossy 계열 생성 결과를 포함하여 실제 시스템의 입력·생성 과정을 직접 체험할 수 있도록 구성하였다.

5.2 설문 결과

Table 6 은 전문가 사용성 평가 결과를 나타낸다. 전체적으로 모든 항목에서 평균 4 점 이상의 긍정적인 평가가 나타났으며, 특히 ‘실무 활용 가능성’ 항목이 평균 4.35 점으로 가장 높은 평가를 받았다.

Table 6. 화장품 산업 종사자 사용성 평가 (소규모 사용자 평가, 5 점 리커트 척도)

평가 항목	평균	표준 편차	긍정 응답률 (%)	주요의견
색상 표현 만족도	4.20	0.72	75%	실제 색상 검토에 도움
질감 표현 만족도	4.15	0.81	70%	질감 차이가 비교적 명확
실무 활용 가능성	4.35	0.65	90%	초기 검토 단계 활용 가능
개발 효율성 기여	4.10	0.78	80%	배합 검토 시간 단축 가능
전체 만족도	4.25	0.68	85%	실제업무 적용

평가 항목	평균	표준 편차	긍정 응답률 (%)	주요의견
				가능성 확인

6. 결론 및 향후 연구

본 논문에서는 화장품 립 제품의 성분 배합비를 기반으로 발색 색상과 질감 특성을 시각적으로 시뮬레이션하는 생성형 AI 기반 시스템을 제안하였다.

응답자들은 입력된 배합비 정보를 이미지 형태로 빠르게 확인할 수 있다는 점에서 높은 활용 가능성을 제시하였다. 특히 Matte 및 Glossy 계열 생성 결과에서 질감 차이가 비교적 구분된다는 의견이 나타났다.

반면 일부 응답자들은 입술 경계 및 미세 주름 표현의 세밀도가 부족하다는 의견을 제시하였으며, 향후 데이터 확장 및 생성 품질 개선의 필요성이 언급되었다.

5.3 사용성 평가 결과 및 분석

연구·개발 분야 참가자들은 텍스트 기반 배합 정보만으로는 시각적 발색 및 질감 특성을 직관적으로 확인하기 어려웠으나, 생성 이미지를 통해 결과를 즉시 시각적으로 확인할 수 있다는 점에서 높은 활용 가능성을 제시하였다.

반면 영업·마케팅 분야 참가자들은 색상 및 질감 결과를 시각적으로 빠르게 공유할 수 있다는 점에서 제품 기획 및 커뮤니케이션 측면의 활용 가능성을 긍정적으로 평가하였다.

특히 Figure 4의 세 가지 질감 케이스를 비교한 결과, 참가자들은 Matte, Satin, Glossy 계열 간의 질감 차이가 비교적 명확하게 표현된다고 평가하였다. Matte 계열에서는 광택 표현이 상대적으로 낮은 무광 계열 특성이, Glossy 계열에서는 광택감이 강조된 시각적 표현이 상대적으로 잘 나타난다는 의견이 나타났다.

또한 실제 시제품 제작 검토 과정에서는 실제 샘플 제작 이전 단계에서 발색 결과를 충분히 예측하기 어려웠으나, 제안 시스템은 배합 입력 직후 생성 결과를 확인할 수 있다는 점에서 초기 기획 및 검토 단계의 효율성을 높일 가능성이 있는 것으로 평가되었다.

다만 일부 사례에서는 입술 주름 표현과 경계 부근의 세밀도가 부족하다는 의견도 제시되었으며, 향후 립 전용 LoRA 기반 추가 학습 및 실제 화장품 발색 데이터 확장이 필요할 것으로 판단된다.

제안 시스템은 배합비 정보를 입력받아 MLP 기반 시각 속성 변환 과정을 수행하고, Stable Diffusion Inpainting 및 ControlNet 기반 생성 과정을 통해 립 메이크업 이미지를 생성하도록 구성하였다. 또한 배합 특성에 따라 생성 파라미터를 조절함으로써 Matte, Satin, Glossy 계열 질감 차이를 시각적으로 표현하고자 하였다.

실험 결과, 제안 시스템은 입력된 배합 성분에 따라 서로 다른 색상 및 질감 특성이 생성 결과에 반영되는 경향을 확인할 수 있었다. 특히 Figure 4의 실제 생성 결과에서는 Matte, Satin, Glossy 계열별 질감 차이가 시각적으로 구분되는 특성이 나타났다. Figure 4(c)의 자동 배합 해석 패널을 통해 입력 성분 기반 피니시 및 색상 정보 분석 기능도 함께 제시하였다.

또한 화장품 업계 종사자를 대상으로 수행한 사용성 평가 결과, 참가자들은 배합비 정보를 시각적으로 빠르게 확인할 수 있다는 점에서 활용 가능성을 제시하였다.

이를 통해 제안 시스템이 초기 제품 기획 및 배합 검토 단계에서 보조 도구로 활용될 수 있음을 확인할 수 있었다. 향후에는 립 전용 LoRA 기반 추가 학습을 통한 질감 표현 개선, 실제 화장품 제조 데이터 기반 배합비-발색 데이터셋 구축, 모바일 환경 경량화 등이 추가적인 과제로 남아 있다.

감사의 글

본 연구는 과학기술정보통신부 및 정보통신기획평가원의 메타버스 융합대학원의 연구 결과로 수행되었음 (IITP-2026-RS-2024-00430997)

본 연구는 과학기술정보통신부 및 정보통신기획평가원의 지원을 받아 2026년도 AI 중심대학(2026-0-00057)의 결과로 수행되었음

References

- [1] C. S. Peng and H. J. Kim, "Skin undertone influence on cosmetic color perception: A spectrophotometric analysis," J. Cosmetic Science, vol. 71, no. 4, pp. 215–228, 2020.
- [2] Y. Lin, H. Chen, and W. Huang, "Colorimetric modeling of lip cosmetics using spectrophotometric analysis," Color Research &

Application, vol. 31, no. 3, pp. 210–218, 2006.

- [3] R. Y. Lochhead, "The role of polymers in cosmetics: Recent trends," ACS Symposium Series, vol. 961, pp. 3–59, 2008.
- [4] T. Li, R. Qian, C. Dong, S. Liu, Q. Yan, W. Zhu, and L. Lin, "BeautyGAN: Instance-level facial makeup transfer with deep generative adversarial network," in Proc. ACM MM, pp. 645–653, 2018.
- [5] L. Zhang, A. Rao, and M. Agrawala, "Adding conditional control to text-to-image diffusion models," in Proc. ICCV, pp. 3836–3847, 2023.
- [6] S. C. Mitra, U. R. Doshi, and B. Shah, "Advances in cosmetic pigment technology," J. Cosmetic Science, vol. 72, no. 3, pp. 201–219, 2021.
- [7] R. Rombach, A. Blattmann, D. Lorenz, P. Esser, and B. Ommer, "High-resolution image synthesis with latent diffusion models," in Proc. CVPR, pp. 10684–10695, 2022.
- [8] C. Lugaresi et al., "MediaPipe: A framework for building perception pipelines," arXiv:1906.08172, 2019.
- [9] S. Jiang, T. Liu, C. Fan, H. Wu, Q. Zhong, D. Li, R. Zhong, and X. Liu, "PSGAN: Pose and expression robust spatial-aware GAN for customizable makeup transfer," in Proc. CVPR, pp. 3123–3132, 2020.
- [10] Y. Gu, Z. Li, S. Zhai, J. Bao, and H. Zhang, "LADN: Local adversarial disentangling network for facial makeup and de-makeup," in Proc. ICCV, pp. 10481–10490, 2019.
- [11] 송미영, 김용선, "모바일 증강현실 기반의 얼굴형을 적용한 가상 메이크업 도구 개발," 한국컴퓨터정보학회논문지, vol. 29, no. 1, 2021.
- [12] 안예은, 이규빈, 정수현, 김희수, 유제혁, "안면 색상 데이터 분석 기반의 퍼스널 컬러 진단 및 가상 메이크업 애플리케이션 개발," 한국영상학회논문집, vol. 22, no. 2, pp. 41–57, 2024.

〈 저 자 소 개 〉

정 다 슬

- 2024년~2026년 숭실대학교 정보과학대학원 석사
- 관심분야: 생성형 인공지능, 컴퓨터 비전, AI 응용 서비스
- <https://orcid.org/0009-0008-4808-6217>



박 진 호

- 1999년 KAIST 수학과 학사
- 2001년 KAIST 응용수학과 석사
- 2007년 KAIST 전산학과 박사
- 현재 숭실대 글로벌미디어학부 교수
- 관심분야: 강화학습, 금융 IT
- <https://orcid.org/0000-0002-8694-2976>

