creative commons

COMMONS DEED

저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:

저작자표시. 귀하는 원저작자를 표시하여야 합니다.

비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.

변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 이용허락규약(Legal Code)을 이해하기 쉽게 요약한 것입니다.

Disclaimer

dCollection

공학석사학위논문

트렌딩 패션 브랜드 의류 이미지 분석 기반 색상 팔레트 생성: 딥 러닝 접근 방식

Color palette generation using fashion e-commerce images: the deep learning approach

2023 년 8 월

서울대학교 대학원
산업공학과

최 용 우

트렌딩 패션 브랜드 의류 이미지 분석 기반 색상 팔레트 생성: 딥 러닝 접근 방식

Color palette generation using fashion e-commerce platform images: the deep learning approach

지도교수 조 성 준

이 논문을 공학석사 학위논문으로 제출함

2023 년 06 월

서울대학교 대학원

산업공학과

최 용 우

최용우의 공학석사 학위논문을 인준함

2023 년 06 월

위 원 장 _____윤 명 환_____(인)

부위원장 _____조 성 준_____(인)

위 원 _____이 성 주_____(인)

초록

패션 산업에서 색상 정의는 매년 변화하며 자주 쓰이는 색상 또한 계속해서 변화하는 동적 특성을 가지고 있다. 그러나 온라인 쇼핑 산업은 일관된 기준으로 색상을 분류하며, 이 과정에서 특정 색상 필터에 의류가 부족하거나 과도하게 존재하는 문제가 발생하고 있다. 이러한 불균형은 패션 인공지능 시스템의 성능에도 부정적인 영향을 미치고 있다. 특히 온아웃이라는 인공지능 패션 스타트업을 창업하게 되면서 유저 중심으로 평가되어야 하는 인공지능은 동일한 간격의 RGB 색상 공간을 기준으로 이미지를 학습하지만 사람의 색상 인식은 RGB 공간 내의 미세한 값 변화에 크게 영향을 받는다는 문제를 발견했다. 또한 사람의 색상 인식은 시간에 따라 지속적으로 변화하기 때문에 지속적인 색상 재정의가 필요하다. 이에 본 연구는 패션 전문가들이 분류한 실제 판매되는 의류의 색상 데이터를 분석하여 트렌드를 반영한 색상 팔레트를 제시하며, 데이터 분포에 기반하여 유저 중심의 세분화된 색상 팔레트를 생성하는 방안을 제안한다. 이를 통해 현존하는 문제를 해결하고 패션 인공지능의 성능을 향상시키는 방법을 탐색하고자 한다.

주요어: 패션 인공지능, 이미지 분석, 색상 분석, 딥러닝, 산업공학

학번: 2020-27798

목차

초록 i

목차 ii

표 목차 iv

그림 목차 v

제 1 장 서론 8

1.1 문제 정의 ····· 8

1.2 연구 동기 및 공헌 ····· 14

1.3 연구 목표 및 기대효과 ····· 15

1.4 연구 방법 개요 ····· 16

제 2 장 선행연구 20

2.1 Convolutional Neural Networks ····· 20

2.2 Regional-Convolutional Neural Networks ····· 22

2.3 Faster Regional-Convolutional Neural Networks ····· 25

2.4 Mask Regional-Convolutional Neural Networks ····· 28

2.5 K-means Clustering ····· 31

2.6 Color Trend Anlysis Using Machine Learning with Fashion Collection Images ····· 33

2.7 Color identification method for fashion runway images: An experimental study ····· 36

2.7 Digital image analysis method to extract fashion color semantics from artworks ····· 37

제 3 장 해법 38

3.1 모델 구조 ····· 38

3.2 데이터 수집 구조 ····· 39

3.3 데이터 정제 ····· 40

3.4 색상 데이터 분류 ····· 41

3.5 색상 데이터 세분화 ····· 42

제 4 장 실험 결과 43

4.1 실험 요약 ····· 43

4.2 실험 데이터 학습 데이터 셋 선정 ····· 44

4.3 실험 데이터 셋 예시 ····· 46

4.4 실험 방법 ····· 47

4.5 실험 결과 ····· 47

제 5 장 결론 51

5.1 결론 ····· 51

5.2 향후 연구 ····· 52

참고문헌 54

Abstract **57**

감사의 글 **58**

표 목차

표 1.1 색상 분류 기준 ····· 18
표 4.1 실험군 ····· 43
표 4.2 실험 결과 ····· 47

그림 목차

그림 1.1 2023 겨울 색상 분포 ····· 8

그림 1.2 2023 봄 색상 분포 ····· 8

그림 1.3 보라색 안에 존재하는 다양한 색 ····· 9

그림 1.4 매 시즌 브랜드별 재정의되는 보라색 ····· 9

그림 1.5 필터가 대표하지 않는 의류 색상 ····· 10

그림 1.6 색상 분류 이후 단순 RGB 기반 Item Retrieval시 영역의 불분명함 ····· 11

그림 2.1 분석 데이터 예시 ····· 33

그림 2.2 의류 분할 방법 ····· 34

그림 2.3 사용 모델 이미지 ····· 34

그림 2.4 사용 파이썬 컬러 팔레트 ····· 34

그림 3.1 데이터 수집/정제 방법 ····· 39

그림 3.2 의류 분할 결과 예시 ····· 40

그림 3.3 색상 분류 모델 학습 방법 ····· 41

그림 4.1 Black 색상 RGB 데이터 기반 K-Means Clustering 결과 ····· 45

그림 4.2 Black 색상 HSV 데이터 기반 K-Means Clustering 결과 ····· 45

그림 4.3 Blue 색상 RGB 데이터 기반 K-Means Clustering 결과 ····· 45

그림 4.4 Blue 색상 HSV 데이터 기반 K-Means Clustering 결과 ····· 45

그림 4.5 실험 진행 데이터셋 예시 ····· 46

제 1 장 서론

1.1 문제 정의

디자이너들과 패션 브랜드들은 소비자들의 시선을 자신들의 제품으로 집중시키기 위해 끊임없이 색상을 연구하고 실험하며 활용한다. 이는 브랜드 고유의 색상 팔레트에서 명도와 채도의 변화를 주는 것부터 새로운 컬렉션에서 특이한 색상 조합을 탐색하고 도입하는 것에 이르기까지 다양한 방식으로 이루어진다. 이렇게 색상의 지속적인 변화와 실험은 패션 산업의 핵심적인 요소를 구성하며, 최종적으로는 고객들의 구매 결정을 크게 좌우한다(Choi 외, 2012). 패션 산업은 끊임없이 진화하고 변화하는 특성을 가지고 있으며, 특히 색상 트렌드는 변화하는 정도가 두드러진다. 이는 매년, 심지어 계절마다 패션 산업의 색상 트렌드는 계속해서 변화한다. 그림 1.1과 그림 1.2에서 22년 겨울에는 남색 의류가 많이 출시되며 23년 봄에는 흰색 의류가 많이 판매되고 있는 계절의 특성을 확인할 수 있다.

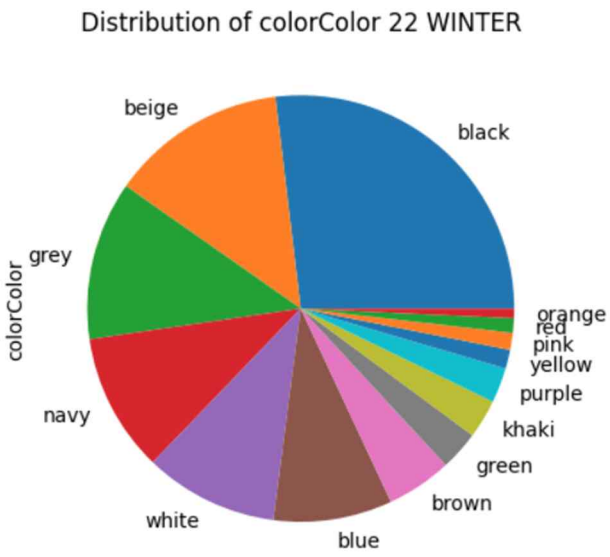

그림 1.1: 2022 겨울 색상 분포

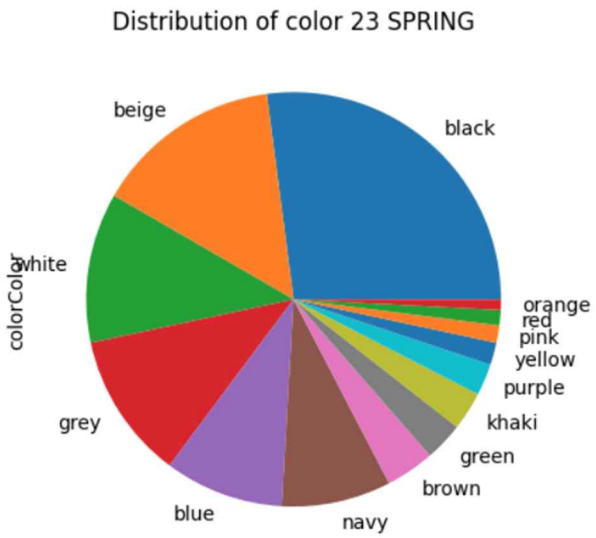

그림 2.2: 2023 봄 색상 분포

의류 특성상 범용적인 채도 기준의 색상 분류 안에서 그림1.3과 같이 명암 비율에 따라 고객이 인지하는 색상은 크게 변한다. 브랜드 또한 그림1.4와 같이 매년 동일한 색상을 사용하지 않고 새로움을 더하기 위해 계속해서 명암에 변화를 준다.

그림 3.3: 보라색 안에 존재하는 다양한 색

그림 4.4: 매 시즌 브랜드별 재정의되는 보라색

그러나, 온라인 패션 쇼핑 플랫폼에서의 색상 분류는 대체로 국가에서 정의한 색상 분류 기준에 기반하여 정적인 특성을 보인다. 이러한 고정된 색상 분류 기준은 트렌드의 변화에 따라 일부 색상 필터가 과다한 의류를 포함하는 반면, 다른 색상 필터는 의류 항목이 부족하게 되는 등, 특정 색상 필터에서 의류 항목의 분포가 불균형 하게 되는 문제를 초래한다. 이렇게 발생한 데이터 불균형은 소비자가 원하는 제품을 찾는 데 어려움을 야기하며 온라인 쇼핑의 사용성을 저하시킨다.

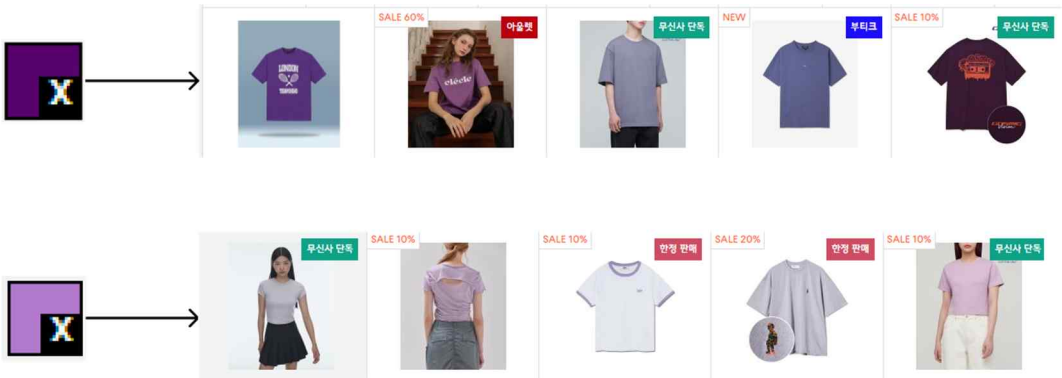

그림 5.5: 필터가 대표하지 않는 의류 색상

이에 더해, 이러한 문제는 RGB 색상 공간을 기준으로 이미지를 학습하는 패션 인공지능의 효율성에도 부정적인 영향을 주게 된다. RGB 값의 미세한 차이가 사용자의 색상 인식에 큰 변화를 가져오므로, 이를 정확히 반영하는 것은 사용자 중심의 패션 인공지능 성능을 높이는데 결정적인 요소가 된다.

그림 6.6: 색상 분류 이후 단순 RGB 기반 Item Retrieval시 영역의 불분명함

지속적으로 변화하는 색상 트렌드를 분석하고 패션 기업들은 온라인에 판매되는 의류에 색상 분류 기준을 정의한다. 2023년 판매되고 있는 100개 기업의 7만개 의류 색상 분류는 패션 전문가들에 의해 정의되어 있다. 이러한 데이터는 충분히 활용되지 못하고 있으며 지속적으로 공개되기 때문에 색상 트렌드를 반영한 색상에 데이터를 수집 가능하다.

SNS의 성장에 따라 색상과 연관된 키워드 마케팅의 중요성이 증대되어 왔으며, 소비자들 또한 색상 트렌드와 관련된 키워드에 점점 더 민감하게 반응한다(Shin 외, 2018). Divita(2019)의 'Fashion Forecasting'에 따르면 패션산업의 주요 선수들은 주로 색상 트렌드 분석 보고서를 구독하거나 전문가에게 조언을 얻는다. 이들은 사회, 경제, 인테리어 디자인 등 다양한 분야에서 소비자의 관심사를 감지한다. 특히 파리, 뉴욕, 밀라노, 런던과 같은 패션 중심지에서의 패션쇼를 주요한 분석 요소로 활용한다. 이런 접근법과 머신러닝을 이용해 컬러 트렌드를 예측하는 연구는 수년간 진행되어 왔다(DuBreuil 외, 2020). 하지만 Pantone과 색상 전문 회사가 매년 발표하는 색상 트렌드는 패션 트렌드를 이끄는 명품 디자이너 패션 쇼에서 자주 사용되지 않는다(Han A 외, 2022).

삼정KPMG가 2022년 발표한 리포트에 따르면 국내 명품 시장은 국내 패션 시장의 20%를 차지한다. 명품 디자이너 브랜드들이 선보이는 패션 쇼 옷 색상들은 대중들이 구매하는 트렌드는 아니다. 삼성패션연구소는 '메가 트렌드의 부재'를 2023년 패션산업 키워드로 발표했다. 패션산업은 변화하고 있다. 색상 트렌드 또한 예측의 영역이 아닌 브랜드 고유의 특성, 소비자의 선호도에 해당한다. 하지만

소비자 중심의 색상 트렌드 연구는 진행되고 있지 않다. 의류 산업에서 소수가 이끄는 색상 트렌드를 예측하는 가치보다 대중이 구매하는 색상 트렌드를 유저 중심으로 분석하고 세분화할 필요가 있다.

1.2 연구 동기 및 공헌

온라인 패션 산업이 커지면서 패션 인공지능의 중요성이 증가하고 있다. 이를 연구하고 상용화하는 과정에서 의류의 색상 특성이 매우 민감한 이슈가 주요한 장애물로 작용한다는 것을 발견하였다. 사용자의 온라인 쇼핑 경험, 특히 기본적인 색상 필터 기능을 제공하는 것부터 문제가 해결되지 못하고 있다. 더하여 패션 인공지능 개발 과정에서 지속적으로 색상 인식의 한계에 부딪히는 문제점을 경험하였다. 이는 이미지 관련 딥러닝 모델이 RGB 데이터를 기반으로 학습을 진행하지만 RGB 색상의 미세한 차이에 대한 사람의 색상 인식 차이를 컴퓨터가 판단할 수 없다는 본질적인 한계 때문이었다. 따라서 본 연구는 색상을 단순히 학습시키는 것이 아니라, 사람의 색상 인지를 패션 인공지능에 통합하는 새로운 접근 방식을 제안하고자 한다.

본 논문은 다음과 같은 세 가지 주요 공헌을 제공한다. 첫째, 유저 중심의 색상 분석의 필요성에 대한 인식을 제시한다. 둘째, 온라인 의류 쇼핑에서 색상 필터의 비효율성을 개선하기 위해 대기업 브랜드가 판매중인 수만개의 의류 색상을 분석하여 트렌드를 반영한 자동 컬러 팔레트 생성 방안을 제안한다. 셋째,

제안한 해법의 효과를 입증하기 위해 다양한 인스턴스에 대한 실험을 통해 그 실용성을 검증한다. 이러한 공헌을 통해 본 논문은 패션 인공지능의 색상 인지 능력을 향상시키는 방향으로 연구의 새로운 패러다임을 제시한다.

1.3 연구 목표 및 기대효과

본 연구의 목표는 온라인 패션 쇼핑 플랫폼에서의 색상 분류와 색상 인지의 문제를 해결하고, 사용자 중심의 패션 인공지능의 성능과 사용자 경험을 향상시키는 것이다. 브랜드가 의류 판매를 위해 정의하는 색상 분류를 수집하여 트렌드를 반영하고, 분석 기법을 통해 자동으로 컬러 팔레트가 생성되는 방법을 제안하고, 이를 통해 소비자들이 실제로 찾고자 하는 제품을 정확하게 필터링할 수 있도록 돕는다. 제안하는 방법은 기존의 고정된 색상 분류 기준을 넘어서 패션 산업의 동적인 변화에 대응하고 소비자들이 선호하는 색상 트렌드를 정확히 반영하는 새로운 접근 방식이다. 이를 통해 온라인 패션 쇼핑 플랫폼에서의 색상 필터링이 더욱 효과적이고 효율적이게 되어 소비자들은 자신의 취향과 관심사에 맞는 제품을 빠르고 정확하게 찾을 수 있게 되며 지속적으로 필요한 데이터 라벨링을 온라인에 판매되고 있는 의류 정보로 대체한다.

이 연구의 기대 효과는 다음과 같다. 첫째, 사용자 중심의 색상 트렌드 분석을 통해 온라인 패션 쇼핑 플랫폼이 소비자들의 요구와 선호도를 더욱 정확하게 파악할 수 있다. 둘째, 자동 컬러 팔레트 생성 방법을 통해 패션 인공지능의 색상

인지 능력을 향상시켜, 소비자들이 원하는 색상과 비슷한 제품을 추천하고 보다 맞춤화된 쇼핑 경험을 제공할 수 있다. 셋째, 이 연구를 통해 개선된 색상 분류 기준과 색상 인지 기술은 패션 산업의 혁신과 경쟁력을 향상시킬 수 있게 기여할 수 있다. 따라서 본 연구는 패션 산업과 온라인 쇼핑 플랫폼에 큰 영향을 미치며, 소비자들의 쇼핑 경험을 개선하고 산업의 발전을 촉진하는 데 기여할 것으로 기대된다.

1.4 연구 방법 개요

본 연구에서는 온라인 패션 산업에서의 색상 분류와 색상 인지 문제를 해결하기 위한 연구 방법을 제안한다. 연구 방법의 개요는 아래와 같다.

첫째, 실시간 국내 top 100 내셔널 브랜드가 판매하고 있는 의류 이미지와 브랜드가 정의한 색상 텍스트 정보를 수집한다. 이는 동적으로 변화하는 색상 분류 기준을 지속적인 라벨링 인력 없이 현재 판매되고 있는 의류를 자동으로 수집하는 시스템을 설계하여 실제 상황에 대한 적합성을 보장하는 정보로 대체하여 연구에서 제안하는 새로운 ‘트렌드’를 정의한다.

둘째, 수집한 데이터에서 이미지 데이터와 색상 텍스트 데이터를 추출하고 전처리하여 색상 대분류 딥러닝 모델 학습에 적절하게 변환한다. 이미지 데이터의 경우 의류 분할, 노이즈 제거 등의 전처리 과정을 거친 후 색상 RGB 데이터를 추출한다. 색상 텍스트 데이터의 경우 14개의 사전 정의한 대분류를 전처리를

진행한다.

셋째, 전처리된 데이터를 활용하여 색상 대분류를 자동 컬러 팔레트 생성 딥러닝 모델을 학습한다. 학습된 딥러닝 모델은 색상 특성을 반영하는 임베딩으로 사용 가능하며 시즌 중 새로운 이미지가 추가될 경우에 색상 분류에 사용될 수 있다. 이를 통해 트렌드를 반영한 자동화 대분류 컬러 팔레트를 생성한다.

넷째, 생성된 대분류 컬러 팔레트를 기반으로 비지도 학습 클러스터링 기법을 활용하여 세분화된 컬러 팔레트를 제시한다. RGB의 미세한 차이를 느끼는 사람의 색상 인지와의 차이를 극복하기 위해 단계별로 적절한 클러스터링 모델을 사용하여 대표되는 색상을 추출한다.

표 1.1 : 색상 분류 기준

대분류	중분류	대분류	중분류
White	어두움	Brown	어두움
	중간		중간
	밝음		밝음
Black	어두움	Green	어두움
	중간		중간
	밝음		밝음
Beige	어두움	Khaki	어두움
	중간		중간
	밝음		밝음
Blue	어두움	Grey	어두움
	중간		중간
	밝음		밝음
Orange	어두움	Yellow	어두움
	중간		중간
	밝음		밝음
Pink	어두움	Purple	어두움
	중간		중간
	밝음		밝음
Navy	어두움	Red	어두움
	중간		중간
	밝음		밝음

다섯째, 제안된 방법의 성능과 효과를 평가하기 위해 다양한 의류 인스턴스에 대한 실험을 수행한다. 실제 사용자를 대상으로 한 사용성 테스트를 진행하고, 자동 컬러 팔레트를 활용한 색상 필터링의 효과를 분석한다. 이를 통해 제안된 방법의 실용성과 유효성을 검증하며, 필요한 경우 개선할 수 있는 부분에 대해 추가적인 검토를 수행한다.

위와 같은 연구 방법을 통해 우리는 패션 인공지능의 색상 인지 능력을 향상시키고, 사용자 중심의 패션 트렌드를 반영하는 효과적인 색상 분류 및 색상 인지 기술을 개발하고자 한다. 결과적으로 패션 산업과 온라인 쇼핑의 사용자 경험을 향상시키고, 색상 관련 마케팅 및 트렌드 분석에 새로운 방법을 제공할 수 있을 것이라 예상한다.

제 2 장 선행연구

2.1 Convolutional Neural Networks

CNN은 주어진 데이터 세트에서 특징의 공간 계층 구조를 자동으로 적응적으로 학습할 수 있는 능력으로 인해 특히 컴퓨터 비전 작업과 같은 다양한 분야에서 광범위하게 적용되고 있다(LeCun외, 1998). 주어진 데이터 세트에서 기능의 공간 계층 구조를 자동으로 적응적으로 학습하도록 설계되어 기존의 많은 기계 학습 모델에서 두드러진 병목 현상이었던 수동 기능 추출의 방식을 혁신했다.

CNN은 입력 레이어와 출력 레이어뿐만 아니라 convolution, ReLU(Retified Linear Unit), pooling, Fully connected 및 regularization 레이어를 포함한 여러 숨겨진 레이어로 구성된다(Krizhevsky외, 2012). Convolution 레이어는 입력 레이어에 convolution 연산을 적용하고 그 결과를 다음 레이어에 전달하는 핵심이다. Convolution 레이어의 매개 변수는 학습 가능한 필터(또는 커널) 세트로 구성되며, 이 필터는 작은 수용 영역을 가지지만 개수가 입력 레이어의 깊이로 확장된다.

이미지 인식의 맥락에서 이러한 필터는 이미지 전체에 걸쳐 이동되어 모든 공간 위치에서 필터의 활성화를 나타내는 feature map을 생성한다. 직관적인 예시를 들다면, 네트워크는 첫 번째 레이어에서 어떤 방향의 가장자리나 어떤 색상의 얼룩 같은 시각적 특징을 보거나, 궁극적으로 객체의 전체 부분 또는 더 깊은 레이어의 전체 객체를 볼 때 활성화되는 필터를 학습한다.

CNN 아키텍처의 또 다른 필수 요소인 pooling layer는 표현의 공간 크기를 줄여 계산 복잡성을 줄이고 과적합을 제어하는 데 도움이 된다. ReLU 계층은 요소별 활성화 기능을 적용하여 네트워크에 비선형성을 도입한다(Nair 외, 2010). 이 비선형성을 통해 모델은 더 복잡한 작업을 학습하고 수행할 수 있다.

수년간 CNN은 이미지 분류(Krizhevsky 외, 2012), 객체 감지(Ren외, 2015), 의미론적 세분화(Long외, 2015), 심지어 자연어 처리(Kalchbrenner, 2014)와 같은 비전을 넘어선 영역에서도 성공적으로 활용되었다. 따라서 CNN은 공간적인 구조와 패턴을 인식하고 학습하는 능력 덕분에 패션 이미지 분석과 같은 복잡한 이미지 분류 문제에 적합하다(Liu외, 2016).

2.2 Regional - Convolutional Neural Networks

CNN은 이미지 분류 작업에 상당한 기여를 했지만, 이미지에서 개체를 인식하고 구체적으로 localization 하려면 다른 접근 방식이 필요하다. 이 과제는 Girshick(2014)이 convolution 신경망(R-CNN)이 있는 localization 개발을 통해 해결했다.

R-CNN은 지역 제안 방법을 CNN과 통합하여 모델이 이미지 내에서 객체를 감지하고 위치를 찾을 수 있도록 한다. R-CNN 방법은 선택적 검색(Uijlings 외, 2013)이라는 방법을 사용하여 이미지 내의 잠재적 객체에 대해 제안된 bounding box 세트를 생성하는 것으로 시작한다. 제안된 각 영역은 CNN에 입력될 수 있도록 고정된 크기로 합성된다. 그런 다음 CNN은 각 영역에서 특징 벡터를 추출하여 클래스별 선형 SVM(support vector machine) 세트로 공급하여 최종 객체 분류를 수행한다.

Region-based Convolutional Neural Networks (R-CNN)는 객체 탐지를 위한 CNN 기반 방법 중 하나로, 객체의 위치와 클래스를 동시에 탐지하는 것이 특징이다. R-CNN의 기본적인 방법론은 아래와 같이 3단계로 요약할 수 있다.

1) Region Proposals (영역 제안): 이미지에서 객체가 존재할 것으로 예상되는 부분을 추출한다. 이 단계에서는 Selective Search 방법을 사용하여 이미지에서 후보 영역을 뽑아낸다. 이 후보 영역들은 서로 크기와 모양이 다르다.
2) Feature Extraction (특징 추출): 각각의 후보 영역에 CNN을 적용하여 고정된 크기의 특징 벡터를 추출한다. CNN의 마지막 fully connected layer에서 추출된 특징

벡터는 후보 영역의 공간 정보를 잘 보존하며, 이는 다음 단계의 객체 탐지에 큰 도움이 된다. 3) Classification and Bounding Box Regression (분류 및 경계 상자 회귀): 추출된 특징 벡터를 바탕으로 각 후보 영역이 특정 클래스에 속하는지 판단한다. 이 단계에서는 Support Vector Machine (SVM)을 사용하여 각각의 클래스에 대해 분류를 수행한다. 그리고 후보 영역의 정확한 위치를 회귀 분석을 통해 조정한다.

수식적으로 R-CNN은 다음과 같이 설명할 수 있다. 특징 벡터는 이미지 I에 대해 특징 추출 함수 Φ를 적용하여 얻는다. $\Phi: I \rightarrow \mathbb{R}^d$, 여기서 Φ는 이미지를 d차원의 특징 벡터로 매핑하는 CNN이고, I는 이미지의 후보 영역이다. SVM은 각 클래스에 대한 이진 분류를 수행하기 위해 사용되며, 그 결과는 이미지 I가 클래스 j에 속하는지 나타내는 이진 레이블 $y \in \{+1, -1\}$를 생성한다. 이진 레이블 y는 아래의 방정식을 통해 계산된다.

$$y = w^T\Phi(I) + b,$$

여기서 w는 학습된 가중치, b는 편향이다.

이와 같은 방법론을 통해 R-CNN은 이미지 내의 객체 위치와 클래스를 동시에 탐지할 수 있다.

높은 탐지 품질에도 불구하고 R-CNN에는 몇 가지 제한이 있다. 가장 중요한 것은 제안된 각 영역에 대해 독립적으로 CNN 기능 벡터를 추출해야 하기 때문에 계산시 비효율적이다. Fast R-CNN(Girshick, 2015)은 제안된 영역간에 계산을 공유하여 프로세스를 훨씬 더 효율적으로 만들 수 있는 ROI pooling 이라는 기술을 도입하여 이러한 단점을 극복하기 위해 제안되었다.

그리고 Faster R-CNN 아키텍처(Ren 외, 2015)가 제안되었는데, 이는 탐지 네트워크와 전체 이미지 convolution 기능을 공유하는 지역 제안 네트워크(RPN)를 도입하여 탐지 속도를 더욱 높였다.

2.3 Faster Regional - Convolutional Neural Networks

Ren 외(2015)은 속도와 효율성 측면에서 R-CNN 및 Fast R-CNN의 한계를 인식하여 Faster R-CNN으로 알려진 새로운 프레임워크를 제안했다. 이 아키텍처는 결과의 품질을 저하시키지 않으면서 객체 감지 속도를 크게 향상시켰다.

Faster R-CNN은 기본적으로 두 개의 모듈로 구성된다. 지역 제안 네트워크(RPN)로 알려진 첫 번째는 잠재적인 객체 bounding box를 제안한다. 두 번째 모듈은 이러한 제안된 영역을 사용하여 객체를 식별하고 분류하는 detector이다. Faster R-CNN의 한 가지 핵심 혁신은 RPN과 Faster R-CNN 검출기가 동일한 convolution 레이어를 공유한다는 것이다. 이를 통해 모델은 속도를 향상시킬 뿐만 아니라 지역 제안 중에 학습한 기능을 객체 감지에 활용할 수 있다.

RPN은 공유 convolution feature map 출력 위에 작은 네트워크를 슬라이딩하여 작동한다. 각 슬라이딩 윈도우 위치에서 여러 개의 잠재적 영역 bounding box와 이와 관련된 점수를 생성한다. 그런 다음 bounding box는 객체 분류를 위해 Fast R-CNN detector에 공급된다. 전체 모델은 다중 작업 손실 함수를 사용하여 엔드 투 엔드로 훈련되어 시스템의 전반적인 일관성을 보장한다.

Faster R-CNN은 R-CNN 및 Fast R-CNN의 단점을 개선하기 위해 제안된 방법론으로, 객체 탐지의 정확성을 유지하면서 처리 속도를 빠르게 하는 것에 집중한다. Faster R-CNN은 두 부분으로 구성되는데, 첫번째로 Region Proposal Network (RPN, 영역 제안 네트워크)로서 객체가 있을 만한 영역의 후보를

제안하고, 두번째로는 제안된 영역에서 객체를 검출하는 네트워크이다. 네트워크는 아래와 같이 구성된다.

1) Feature Extraction (특징 추출): R-CNN 계열의 다른 방법론들과 마찬가지로, 이미지에서 특징을 추출하기 위해 CNN을 사용한다. 이때 사용되는 CNN은 VGG, ResNet 등이 될 수 있다. 2) Region Proposal Network (영역 제안 네트워크): RPN은 고정된 크기의 윈도우를 슬라이딩 윈도우 방식으로 이미지 위에 이동시키며, 각 위치에서 여러 개의 영역 제안을 생성한다. 이 과정에서 k개의 앵커 박스(Anchor Box)가 사용되며, 각 앵커 박스에 대해 객체가 존재할 확률과 객체 경계 상자의 좌표를 출력한다. 3) RoI Pooling: 제안된 각 영역에 대해 RoI 풀링을 수행하여 고정된 크기의 특징 맵을 생성한다. 4) Classification and Bounding Box Regression (분류 및 경계 상자 회귀): 생성된 특징 맵을 기반으로 객체의 클래스를 분류하고 경계 상자의 위치를 조정한다.

Faster R-CNN의 핵심 요소인 RPN은 다음 수식을 통해 표현된다. RPN의 출력은 각 앵커 박스에 대한 객체 존재 확률 p와 상대적인 객체 경계 상자 좌표 t가 된다.

$$p_i = P(cls = object \mid A_i),\ t_i = (x_i, y_i, w_i, h_i)$$

여기서 A_i는 i번째 앵커 박스이며, (x_i, y_i)는 앵커 박스의 중심 좌표, w_i와 h_i는 앵커 박스의 너비와 높이를 나타냄

이렇게 Faster R-CNN은 기존의 R-CNN, Fast R-CNN 방법론에 비해 계산량을 줄여 처리 속도가 빠르고 더욱 정확한 객체 탐지 성능을 보이는 장점을

가지고 있다.

Faster R-CNN은 객체 감지 작업에서 높은 정확도와 효율성을 보여주었다. 그러나 이전 제품에 비해 개선되었음에도 불구하고 Faster R-CNN은 다양한 크기의 물체를 처리하기 어렵고 2단계 감지 프로세스로 인한 계산 복잡성 증가와 같은 한계가 존재한다. 따라서 이러한 문제 해결을 위해 객체 감지를 위한 피처 피라미드 네트워크(FPN)와 인스턴스 분할을 위한 mask R-CNN(He 외, 2017)과 같은 많은 후속 아키텍처의 기반으로 사용되었다.

2.4 Mask Regional - Convolutional Neural Networks

He외(2017)은 Faster R-CNN의 원칙을 기반으로 인스턴스 분할 작업을 위해 설계된 프레임워크인 Mask R-CNN을 개발했다. Mask R-CNN은 이미지에서 객체를 분류하고 위치시킬 뿐만 아니라 각 객체 인스턴스를 정확하게 분할하는 것을 목표한다.

Mask R-CNN은 bouding box 인식을 위해 병렬로 각 관심 영역(RoI)에서 분할 마스크를 예측하기 위한 branch를 도입한다. 이 갈라진 네트워크 구조를 통해 Mask R-CNN은 인스턴스 수준 분할 마스크와 객체 클래스를 동시에 효율적으로 예측할 수 있다.

Mask R-CNN의 중요한 혁신 중 하나는 RoIAlign의 개념으로, RoIpool 작업으로 인한 공간 정렬 오류를 해결하기 위해 설계된 간단하지만 효과적인 레이어다. RoIAlign은 RoIPool의 정밀하지 않은 정수화 스텝을 제거하여, 추출된 feature을 입력에 올바르게 정렬한다. 이것은 의류 이미지와 같은 픽셀 수준의 정밀도가 필요한 분할 작업에서 특히 중요하다.

이전 연구와 마찬가지로 Mask R-CNN은 엔드 투 엔드로 훈련되었으며 COCO 객체 감지 및 인스턴스 분할 문제와 같은 벤치마크에서 우수한 성능을 보였다. Mask R-CNN의 성공에도 불구하고 여전히 몇 가지 제한 사항이 존재한다. 예를 들어, 분할 전 개체의 정확한 탐지에 크게 의존하므로 탐지 오류가 파이프라인을 통해 전파될 수 있다. 또한 상당한 계산량을 요구하기 때문에

실시간 적용이나 제한된 계산 리소스가 있는 장치에 배포하기가 어렵다. 의류는 시즌별로 생산되며 판매기간이 길기 때문에 즉시 반영하지 않더라도 의류 분할을 위한 하루정도의 기간은 존재해도 되기 때문에 Mask R-CNN을 선택했다.

Mask R-CNN은 객체 탐지와 더불어 픽셀 수준의 인스턴스 분할까지 수행하는 방법으로, Faster R-CNN의 확장이다. 기본적인 아이디어는 Faster R-CNN의 구조를 그대로 사용하되, 마지막에 마스크 예측을 위한 병렬 분기를 추가하는 것이며 아래와 같이 구성된다.

1) Feature Extraction: 이전의 R-CNN 계열과 같이 이미지에서 특징을 추출하는 것이 첫 단계다. 이때 사용되는 CNN은 ResNet과 같은 딥러닝 모델이 될 수 있다. 2) Region Proposal Network (영역 제안 네트워크): 특징 맵을 입력으로 받아 객체가 존재할 가능성이 높은 영역을 제안한다. 3) RoIAlign: RoIAlign은 Faster R-CNN에서의 RoIPool 대신 사용되는 기술로, 정확한 위치 정렬을 통해 디지털화로 인한 위치 왜곡을 최소화한다. 4) Classification and Bounding Box Regression (분류 및 경계 상자 회귀): 객체의 종류를 분류하고 경계 상자의 위치를 조정한다. 5) Mask Prediction: 분류 및 경계 상자 회귀와 병렬로 수행되며, 인스턴스의 픽셀 수준의 세분화를 담당한다. 마스크 예측은 RoIAlign로부터 얻은 feature map을 입력으로 받아 각 픽셀이 객체에 속하는지 아닌지를 예측한다.

Mask R-CNN의 핵심인 마스크 예측은 다음과 같이 표현된다. 주어진 RoI에 대해 k 클래스에 대한 m x m 마스크를 출력하는 함수를 M_k라고 하면, 각 클래스에 대한 이진 마스크를 출력하는 방식으로 수행된다.

$$M_k: R \rightarrow \{0,1\}^m$$

여기서 R은 입력 이미지의 RoI이고, k는 특정 클래스, m은 마스크의 크기를 나타냄

이 함수는 FCN(Fully Convolutional Network) 방식을 따르며, 각 픽셀이 주어진 클래스에 속하는지를 결정한다. 이처럼 Mask R-CNN은 높은 수준의 정밀도와 속도로 인스턴스 분할을 수행할 수 있는 방법론을 제공하며, 객체 탐지와 분할에 있어서 획기적인 성과를 보여준다.

2.5 K-means Cluestering

K-means 클러스터링은 비지도 학습의 한 방법으로, 데이터를 K개의 클러스터로 분류하기 위해 많이 사용되는 알고리즘이다. 이 알고리즘은 이미지 분할, 고객 분할 및 이상 탐지 등 다양한 영역에서 적용되었다(Jain, 2010).

분류되는 과정은 각 데이터 포인트를 가장 가까운 중심점에 할당하고, 각 클러스터의 중심점을 해당 클러스터에 속한 데이터 포인트의 평균으로 업데이트하는 과정을 반복하며 진행된다. 알고리즘은 아래 4단계로 요약할 수 있다:

1) 초기화: 먼저, K개의 클러스터 중심(centroid)을 임의로 설정한다. 이 중심들은 데이터 공간 내에서 무작위 위치에 있을 수 있다. 2) 할당: 각 데이터 포인트를 가장 가까운 클러스터 중심에 할당한다. 이 때 거리는 보통 Euclidean distance를 사용하여 계산하며, 다음 수식으로 표현된다.

$$d(i, j) = \mathrm{sqrt}(\Sigma(x_\{i\}-x_\{j\})^2)$$

i와 j는 각 데이터 포인트와 클러스터 중심을, x는 해당 위치에서의 변수 값을 나타냄

3)업데이트: 각 클러스터의 중심을 해당 클러스터에 속한 데이터 포인트들의 평균으로 업데이트한다. 이는 다음 수식을 통해 계산된다.

$$\mu_k = 1/n_k \ \Sigma \ x_n$$

여기서 n_k는 k번째 클러스터에 속한 데이터 포인트의 개수를, Σx_n은 k번째

클러스터에 속한 모든 데이터 포인트의 합을 나타냄.

4)수렴: 중심점이 더 이상 크게 변하지 않거나 사전 정의된 최대 반복 횟수에 도달할 때까지 할당 단계와 업데이트 단계를 반복한다.

K-means는 단순함에도 불구하고 최소값으로 수렴할 수 있으며 최종 결과는 중심의 초기 선택에 따라 결과가 달라질 수 있기 때문에 다양한 초기값으로 알고리즘을 실행하여 클러스터 내 분산을 최소화해야 하며 주어진 데이터가 달라질때마다 과정을 반복해야한다.

또한 군집의 형태가 구형이고 크기가 균일하다고 가정한다는 것이며, 이는 모든 데이터셋에 대해 적용되지 않을 수 있다. 또한 클러스터의 수를 지정하는 일은 도메인에 대한 지식을 많이 요구하는 일이다.

본 논문 연구에 적용하기에 장점은 정해진 클러스터 수만큼 세분화된 색상 분류가 가능하다는 점이며 단점은 색상 분포에 따라 분류되기 어려운 noise 색상들을 모두 포함하는 클러스터가 생성되기에 centroid 색상 값이 대표하지 못하는 클러스터가 생성될 수 있다는 것이다.

2.6 DBSCAN Clustering

DBSCAN은 다양한 모양과 크기의 클러스터를 검색할 수 있는 고유한 기능으로 인기를 얻은 밀도 기반 클러스터링 알고리즘이다(Ester외, 1996). K-평균과 같은 partitioning 방법과 달리 DBSCAN은 사용자가 클러스터 수를 사전에 지정할 필요가 없으며 클러스터에 속하지 않는 노이즈 지점을 식별할 수 있습니다.

데이터 세트에서 방문하지 않은 각 점에 대해 알고리즘은 γ-근접의 모든 점을 검색한다. 이 근방에 MinPt 이상이 있으면 새 클러스터가 시작되고 점이 핵심 점으로 표시된다. 그렇지 않으면 점에 노이즈 레이블이 지정된다(이 레이블은 나중에 경계 점으로 변경될 수 있음). 현재 클러스터의 γ-근접에서 발견된 각 새 코어 포인트에 대해 알고리즘은 γ-근접의 모든 포인트를 검색한다. 점이 방문되지 않은 경우 해당 점이 현재 클러스터에 추가되고 방문된 것으로 표시된다. ε-근접에 MinPt 이상이 있으면 코어 점으로도 레이블이 지정된다. 현재 클러스터에 새 코어 포인트를 추가할 수 없을 때까지 프로세스가 계속된다. 그런 다음 알고리즘은 데이터 세트에서 다음 방문하지 않은 지점으로 진행되고 1단계와 2단계를 반복한다.

DBSCAN에는 몇 가지 장점이 존재한다. 임의의 모양의 군집을 찾을 수 있으며, 사용자가 군집 수를 지정할 필요가 없다. 그러나 몇 가지 제한 사항이 존재한다. 다양한 밀도를 갖고 있는 클러스터 분류에는 어려움을 보이며 γ 및 MinPts 선택에 민감하다. 또한 고차원 데이터는 "차원성의 저주"로 인해 문제가 크게 적용되어 속도가 느리다.

DBSCAN(Density-Based Spatial Clustering of Applications with Noise)은 밀도 기반의 클러스터링 알고리즘으로, 데이터 포인트들이 밀집된 공간을 클러스터로 인식하는 방법을 제시한다. DBSCAN의 기본 아이디어는 데이터 포인트의 '밀도'를 근거로 클러스터를 형성하고 이를 바탕으로 클러스터의 형태를 자동으로 탐지한다. 이 때 '밀도'란 특정 반경 ε 내에 있는 이웃 데이터 포인트의 수를 의미한다. DBSCAN의 알고리즘은 다음과 같다.

1) 점 분류: 데이터 세트의 각 방문하지 않은 점에 대해 최소 MinPt가 ε 거리 내에 있는 경우 해당 점을 코어 점으로 분류한다. 그렇지 않으면 점에 노이즈 레이블을 지정한다. 2) 이웃 확장: 새로 분류된 각 코어 점에 대해 ε-근접을 검색한다. 이 근처에 방문하지 않은 지점이 있으면 방문한 것으로 표시하고 현재 클러스터에 추가한다. 새로 방문한 점에 최소 MinPts가 ε-인접점에 있는 경우 이 점을 코어 점으로 분류한다. 3) 클러스터 완료: 현재 클러스터에 더 이상 핵심 점을 추가할 수 없을 때까지 Neighborhood Expansion 단계를 반복한다. 4) 데이터셋을 통한 반복: 데이터셋에서 방문하지 않은 다음 지점으로 이동하여 지점 분류 및 인접 확장 단계를 반복한다.

본 논문에서는 K-means clustering을 활용한 색상 대 분류 이후에 데이터 분포가 불규칙한 세분화된 색상 분류를 위해 활용된다. RGB 색상공간은 원 분포를 가지지 않는다는 EDA를 기반으로 중분류 이후 세분화에 DBSCAN을 시도했다.

2.7 Color Trend Analysis using Machine Learning with Fashion Collection Images

위 논문은 Pantone의 글로벌 색상 표준과 패션 컬렉션에 사용되는 색상 간의 관계를 탐구한다. 기계 학습 기술을 사용하여 웹 스크랩된 패션 쇼 이미지 데이터를 분석하고 측정 가능한 결과를 얻으며 정석적인 평가를 진행한다.

그림2.1 : 분석 데이터 예시

연구원들은 먼저 기계 학습을 통해 신체와 의복 요소를 분리한다. 이 후 배경과 모델이 입고 있는 의류에 대한 색상 noise를 제거하기 위해 딥 러닝 기반 semantic segmentation model을 사용하여 각 이미지의 의류 영역을 식별한다. 이러한 기술로 옷의 색을 배경과 피부의 색으로부터 분리할 수 있게 해준다. 다음으로, 유사한 색을 묶기 위해 k-평균 알고리즘을 사용하여 색상을 smoothing 하여 색상 칩을 생성한다.

마지막으로 팬톤이 발표한 트렌딩 색상 팔레트(16색)와 분석 색상 칩 간의 유사성을 분석한다. 이들은 모든 분석 컬러 칩과 비교하여 각 팬톤 색상에 대한 유사성 점수를 계산하였고 유사도 점수는 팬톤 색상에서 일정 거리 이내에 있는

분석 색상 칩의 개수를 기준으로 정했다.

그림 2.2 : 의류 분할 방법

이 연구는 팬톤 트렌드와 패션 컬렉션에 사용되는 색상 사이에 상당한 차이가 있다는 것을 보여준다. 구체적으로, 그들은 분석된 의류의 30%만이 그 시즌에 팬톤이 예측한 16가지 색상 중 한 개와 일치한다는 것을 발견했다. 이것은 디자이너들이 컬러 트렌드에 있어서 반드시 팬톤의 추천을 따르지는 않는다는 것을 시사한다.

연구원들은 기계 학습이 패션 산업 내에서 생산을 지도할 수 있는 잠재력을 가지고 있다고 제안한다. 디자이너는 패션 컬렉션의 이미지 데이터를 분석하여 현재 인기 있는 색상에 대한 통찰력을 얻고 그에 따라 디자인을 조정할 수 있다. 이를 통해 시장 조사 과정에서 시간을 절약할 수 있고 디자이너들이 추세를 유지하는 데 도움이 될 수 있다고 주장한다.

그러나 이 연구에는 두 가지 기술적 한계가 있다. 앞서 언급한 바와 같이, 명암과 같은 사진 환경 요인으로 인해 실제 의복과 이미지 간의 잠재적인 색상

차이를 고려하지 않았으며, 의류 이미지의 구성 요소 세분화의 정확성을 높이기 위한 데이터 사전 처리가 부족한 것으로 보인다.

전반적으로 "패션 컬렉션 이미지와 함께 머신러닝을 이용한 컬러 트렌드 분석"은 패션 업계에서 머신러닝이 컬러 트렌드 분석에 어떻게 활용될 수 있는지에 대한 귀중한 통찰력을 제공한다. 이 연구 결과는 색상 트렌드를 넘어 다른 디자인 변수에 대한 추가 연구가 확대되어 생산을 더욱 효과적으로 안내할 수 있음을 시사한다.

위 논문의 디자이너 입장에서의 컬러 트렌드 분석에 가치를 제공하고자 하는 목정성과 다르게 본 논문은 소비자 중심의 가치 제공에 대한 연구를 진행했다는 차이점이 존재한다.

2.8 Color identification method for fashion runway images: An experimental study

위 논문은 불확실한 조건에서 패션 런웨이 이미지에 대한 최적의 색상 식별 방법을 개발하기 위한 실험적 연구다. 이 연구에서는 전문가의 시각적 평가, PANTONE Color Palettes Generator (PCPG), K-means 방법과 같은 기존 방법과 연구에서 개발된 새로운 방법을 포함한 다섯 가지 실험 방법을 비교한다. 이 연구의 저자는 중국의 Donghua University와 Nanjing Senkni Clothing Industry Co., Ltd.의 해당 분야 전문가입니다. 이 연구는 상하이 패션 디자인 및 가치 창출 협업 혁신 센터의 지원을 받아서 디자이너 중심의 색상 분석을 진행했다.

그림 2.3 : 사용 모델 이미지

2.9 Digital image analysis method to extract fashion color semantics from artworks

위 논문은 패션디자이너들이 작품으로부터 패션색상 의미론을 추출하기 위한 디지털 색상분석 방법을 제시한다. 이 방법은 이전에 패션 디자이너가 필요로 했던 인지적 노력 없이 Munsell, PCCS 및 SKCS에 있는 Monet의 그림 190개에 대한 색 구성표를 자동으로 평가할 수 있습니다. 이 논문은 또한 PCCS와 SKCS의 먼셀 척도, 색조, 톤을 추정하고 색상의 심리적 의미를 도출하는 방법을 설명합니다. 개발된 방법은 Monet의 그림과 패션 컬렉션에 대한 적용을 조사하는데 사용됩니다. 논문은 이 디지털 분석 방법이 향후 작업에서 패션 코드로 적절하게 레이블이 지정된 이미지 색상 데이터 세트를 생성할 것이며, 레이블이 지정된 데이터 세트 크기는 기계 학습 응용 프로그램이 패션 제품에 대한 소비자의 감정적 반응을 예측하기에 충분할 것이라고 결론했다. 위 논문은 분석 기법을 사용했지만 본 논문에서 제시하는 '실효성' 있는 컬러 사이언스와 거리가 먼 디자이너 중심의 색상 분석을 진행했다.

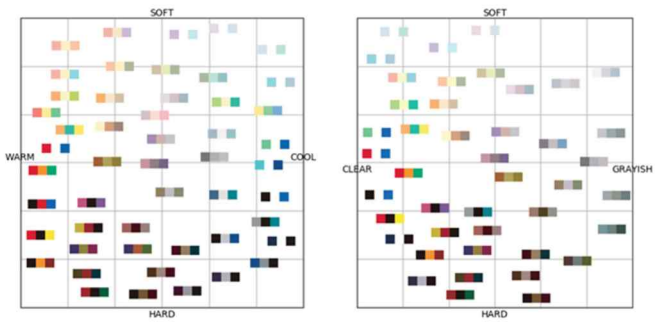

그림 2.4 : 사용 파이썬 컬러 팔레트

제 3 장 해법

3.1 모델 구조

본 연구에서 사용하는 Color Pallette 생성 모델의 구조는 다음 그림과 같이 데이터 수집 단계, 정제 단계, 색상 학습 단계, 색상 세분화 단계로 총 4단계로 이루어져 있다. 시즌마다 재정의되는 색상 분류를 브랜드가 정의한 색상으로 대분류를 나누고 Unsupervised Clustering 기법을 활용하여 대분류 색상안에서 세분화된 중분류 및 세부 색상분류를 자동으로 나누는 모델 구조를 제안하며 소비자 중심의 실험을 진행했다.

3.2 데이터 수집

본 논문에서 정의한 트렌드는 다수의 소비자들이 구매하는 의류로 대중들을 타겟으로 퀄리티 높은 옷을 합리적인 가격에 판매하는 내셔널 브랜드 100개가 대중 트렌드를 정의한다고 가정하고 데이터를 수집을 진행했다. 내셔널 브랜드를 통합한 플랫폼은 존재하지 않기 때문에 파이썬(BeautifulSoup, Selenium)을 활용하여 각 브랜드 자사몰에 강건한 데이터 수집기를 만들어 84269개의 판매중인 의류 페이지에서 상품별 대표 이미지 데이터와 브랜드가 정의한 색상 텍스트 데이터를 수집할 수 있는 시스템을 구축했다.

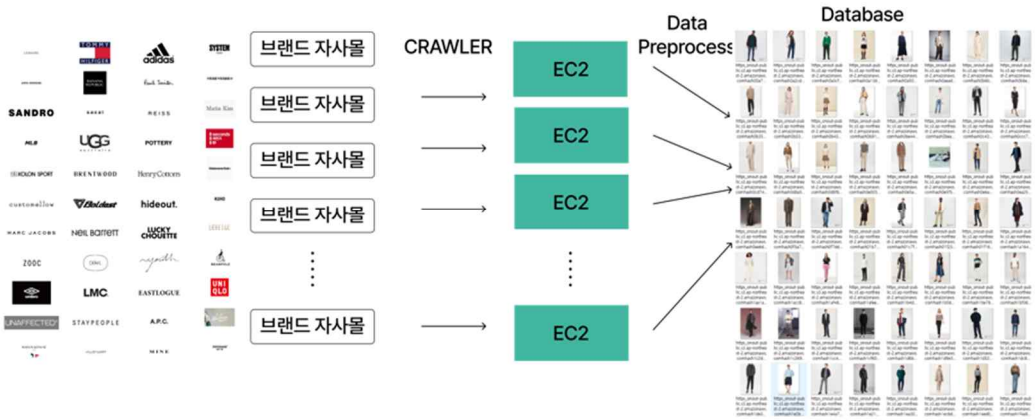

그림 3.1 : 데이터 수집/정제 방법

3.3 데이터 정제

내셔널 브랜드에서 판매하는 의류 이미지 데이터는 모델이 착용하고 있는 경우가 많아서 색상 분류 지도학습 CNN 모델을 학습시키기 어렵다. Image Segmentation으로 배경과 사람의 색상이 포함되지 않은 분할된 이미지가 필요했기에 Mask R-CNN을 활용하여 이미지 정제를 진행했다. DeepFashion2 Dataset의 masking 데이터를 학습 데이터로 활용했다. 내셔널 브랜드의 이미지에서 더 정확한 RGB 추출을 위해 픽셀단위 smoothing(blurring) 기법이 필요했고 Mean Shift Clustering을 활용하여 RGB smoothing을 진행하여 대표 RGB를 추출했다.

브랜드마다 색상 정의가 모두 상이하여 총 3519개의 경우의 수가 존재했으며 기본 14개 색상을 기준으로 영어(대, 소문자)/한글 총 42개의 색상 텍스트 조건을 만들어 라벨링을 진행하고 포함되지 않는 데이터는 눈으로 보면서 라벨링을 진행했다.

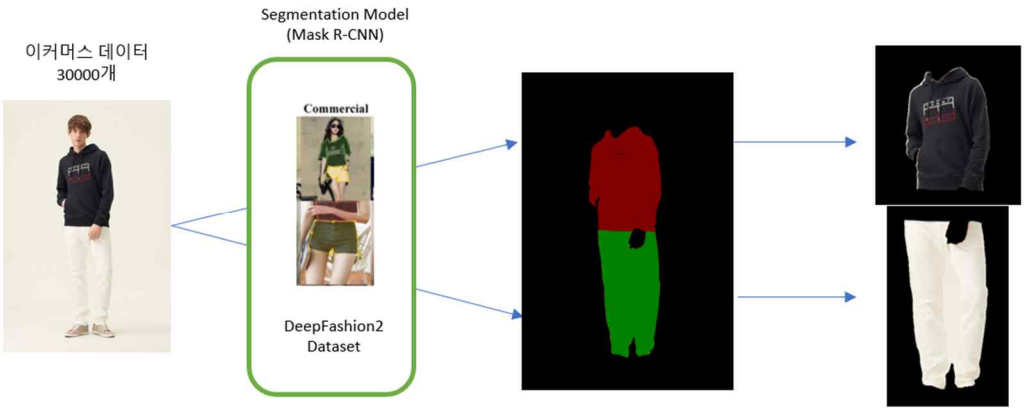

그림 3.2 : 의류 분할 결과 예시

3.4 색상 데이터 분류 - CNN

Segmentation 결과의 의류 이미지와 브랜드가 정의한 색상 데이터를 학습하여 14개의 색상 대분류 Classification 모델을 완성했다. 시즌 색상의 특성에 따라 과적합을 시켰다. 이미지를 기반으로 대분류 색상 분류가 RGB에 라벨링된 데이터를 수집했다.

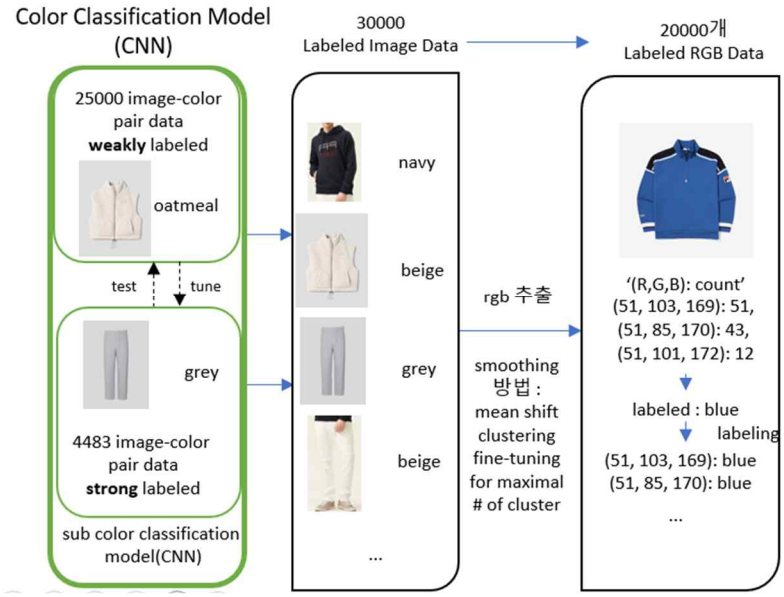

그림 3.3 : 색상 분류 모델 학습 방법

3.5 색상 데이터 세분화

대분류로 나뉜 색상 안에서 데이터 분포에 따라 RGB, HSV 색상 스페이스를 기준으로 K-means에 맞는 색상 공간을 선정하기 위해 실험을 진행하였다. 위 색상 대분류(CNN모델 결과 inference) 안에서 K-menas Clustering을 활용하여 색상을 3단계로 분류하고 3단계로 분류된 색상 안에 불규칙한 패턴을 DBSCAN Clustering을 활용하여 한단계 더 세분화한다. 이를 통해 시즌 판매 상품 정보에 따라 자동으로 세분화된 컬러 팔레트가 생성되는 기술을 제안한다.

제 4 장 실험 결과

4.1 실험 요약

실험 문제는 선택된 색상 필터내에 랜덤으로 선택된 10개의 상품이 필터 색상과 관계가 있는지 설문하여 제안하는 방법이 무신사가 현재 사용하고 있는 정적인 색상 필터보다 사용자의 사용성을 증대했는지 확인한다. 20명의 실험자를 대상으로 실험을 진행했으며 비교 실험 데이터셋을 무신사 색상필터를 사용했기 때문에 실험군을 무신사를 사용하는 20대 남성으로 선정했다. 실험은 Text To Speech에 자주 이용되는 Mean Opinion Score을 사용했으며 metric은 1~5로 설문을 진행했다. 운영중인 '온아웃' 앱 구조를 이용하여 간단한 UI를 제작해서 실험을 진행하였다. 비교 실험군은 무신사에서 실제 판매 중인 상품군 5번째 줄에 있는 UI를 활용하여 진행했다. 화면의 명암을 통일하기위해 아이폰 XR 밝기 100%로 통일했다.

표 4.1: 실험군

20살 남성 대학생	21살 남성 대학생	22살 남성 대학생	23살 남성 대학생
23살 남성 대학생	25살 남성 대학생	25살 남성 대학생	25살 남성 대학생
25살 남성 대학생	26살 남성 대학원	26살 남성 대학원	26살 남성 대학원
26살 남성 대학원	28살 남성 취준생	28살 남성 취준생	29살 남성 직장인
29살 남성 직장인	30살 남성 직장인	30살 남성 직장인	30살 남성 직장인

4.2 실험 데이터 학습 데이터 셋 선정

HSV와 RGB를 기반으로 색상 중분류를 진행한 이후에 자체적인 실험을 통해 각 색상별 K-means Clustering에 활용할 색상 스페이스 기준을 선정하였다. K-means clusetring의 한계인 클러스터를 항상 둥글다고 가정하는 한계를 실험을 통해 duplicates제거와 클러스터별 median을 기준으로 후처리를 진행했다. 이는 3차원 색상 스페이스에서 클러스터는 항상 둥글지 않다는 가설과 centroid를 사용할 경우 (0,0,0)검정과 (255,255,255)흰색과 같은 edge에 존재하는 색상이 포함되지 않는 문제를 실험을 통해 확인했기 때문이다. 본 논문에서 활용된 Smoothing 기술의 한계와 패턴 있는 의류의 특성에 따라 대분류 클러스터링 결과 검정색과 흰색의 중분류 Cluster Median이 크게 벗어나는 경우가 존재했으며 두개의 색상은 자동화하지 못하고 직접 오류를 제거했다. 따라서 총 40개의 색상 팔레트를 선정했으며 이외의 모든 색상은 데이터의 쏠림이 적은 색상 스페이스가 선정됐다. 그림 4.1과 4.2 예시에서 공통으로 cluster 2는 제외됐고 입력 데이터로 RGB가 선정됐다. 그림4.3과 4.4 예시에서는 데이터가 고르게 분포한 HSV 데이터가 선정됐다.

	meanRed	meanGreen	meanBlue	meanHue	meanSaturation	meanValue	number of data
cluster1	30.0	30.0	34.0	232.0	12.0	13.0	20899
cluster2	215.0	210.0	207.0	45.0	3.0	85.0	2169
cluster3	52.0	51.0	55.0	240.0	8.0	22.0	3679

그림 4.1 : Black 색상 RGB 데이터 기반 K-Means Clustering 결과

	colorRed	colorGreen	colorBlue	colorHue	colorSaturation	colorValue	number of data
cluster1	32.0	33.0	38.0	240.0	13.0	15.0	19605
cluster2	218.0	215.0	210.0	43.0	3.0	86.0	4781
cluster3	33.0	32.0	30.0	0.0	5.0	13.0	5952

그림 4.2: Black 색상 HSV 데이터 기반 K-Means Clustering 결과

	meanRed	meanGreen	meanBlue	meanHue	meanSaturation	meanValue	number of data
cluster1	189.0	199.0	213.0	211.0	11.0	84.0	3425
cluster2	35.0	43.0	57.0	221.0	33.0	22.0	3297
cluster3	100.0	129.0	161.0	212.0	34.0	63.0	2409

그림 4.3 : Blue 색상 RGB 데이터 기반 K-Means Clustering 결과

	meanRed	meanGreen	meanBlue	meanHue	meanSaturation	meanValue	number of data
cluster1	187.0	197.0	207.0	211.0	11.0	82.0	5396
cluster2	39.0	41.0	51.0	222.0	24.0	20.0	4841
cluster3	44.0	98.0	161.0	212.0	69.0	63.0	1170

그림 4.4 : Blue 색상 HSV 데이터 기반 K-Means Clustering 결과

4.3 실험 데이터 셋 예시

그림 4.5는 같이 자동으로 생성된 색상 팔레트 기반 필터별 의류 예시를 보여주며 그림 4.6은 무신사 색상 필터 기준 브랜드가 직접 입력한 판매중인 의류 예시를 보여준다.

그림 4.5 : 실험 진행 데이터셋 예시

4.4 실험 방법

피실험자 20명을 대상으로 50개의 랜덤한 필터색상과 포함되는 랜덤한 의류 예시를 보여주면서 적합성을 1~5 기준으로 설문 받았다. 똑같은 색상 필터는 2번이상 나오지 않도록 했다. 본 논문에서 제안한 40개의 색상 분류를 기준과 무신사에서 정의한 40개의 색상필터를 기준으로 실험했다. 색상 이름은 보여주지 않고 색상에 해당하는 RGB 팔레트를 보여주고 의류 색상 필터에 해당하는지에 대한 적합도(Mean Opinion Score)를 수집했다.

전체 필터에 대해 처음에 보여주고 시작했으며 각 컬러별 세분화가 진행되어 있다는 정보를 알려주고 strict 하게 피드백을 요청했다. 무신사 색상필터에 기타가 존재했는데 무지개색으로 표시를 받아서 결과를 제외했다. 쇼핑 환경과 똑 같은 환경을 제공하기 위해 가장 처음에 실제 필터 후보를 보여줬다.

4.5 실험 결과

실험 결과 본 논문의 색상 팔레트 생성 결과는 MOS 3.6으로 무신사2.55과 비교해서 큰 향상을 보여줬다. 하지만 noise를 제거하는 mean shift clustering 단계에서 의류 색상이 크게 잘못 라벨링된 결과가 존재했다는 문제를 발견했다. 또한 무신사 입점 브랜드들은 대표 이미지를 어둡게 가져가는 문제와 사람이 직접 등록했기 때문에 잘못 라벨링된 결과가 많이 존재했으며 색상 필터가 의류 색상을 대표하지 않는 문제 또한 존재했다.

표 4.2: 실험 결과 (MOS)

NO	색상 분류	본 논문 결과	count	색상 분류	무신사 결과	Count
1	White_normal	3.6	29	블랙	4.7	23
2	White_dark	3.2	33	화이트	4.7	29
3	Dark_light	4.1	23	네이비	3.9	23
4	Dark_normal	4.5	24	그레이	3.4	27
5	Grey_light	4.4	26	아이보리	2.5	26
6	Grey_normal	3.8	24	블루	1.9	31
7	Grey_dark	3.9	20	라이트 그레이	3.0	22
8	Beige_light	3.8	29	스카이 블루	3.1	24
9	Beige_normal	3.7	22	베이지	1.9	28
10	Beige_dark	3.6	24	다크 그레이	1.6	25
11	Blue_light	4.2	30	그린	2.0	25
12	Blue_normal	4.2	22	기타	(제외)	30
13	Blue_dark	4.0	30	핑크	1.9	25
14	Orange_light	3.9	22	브라운	1.3	23
15	Orange_normal	3.7	28	옐로우	1.5	27
16	Orange_dark	3.8	27	민트	2.1	21
17	Pink_light	3.9	25	카키	1.9	25

18	Pink_normal	4.1	22	라이트 핑크	4.2	24
19	Pink_dark	3.7	24	레드	1.8	21
20	Navy_light	3.6	29	오렌지	2.1	25
21	Navy_normal	4.3	19	라벤더	3.6	27
22	Navy_dark	3.7	23	퍼플	1.8	21
23	Brown_light	2.4	25	샌드	3.3	27
24	Brown_normal	2.7	19	라이트 옐로우	3.4	20
25	Brown_dark	2.3	22	다크 그린	2.7	22
26	Green_light	4.0	30	라이트 그린	1.9	30
27	Green_normal	3.9	17	올리브 그린	2.2	27
28	Green_dark	3.8	27	페일 핑크	3.4	28
29	Khaki_light	2.3	30	버건디	3.3	23
30	Khaki_normal	2.7	24	데님	2.6	22
31	Khaki_dark	2.3	28	카멜	2.0	22
32	Yellow_light	3.6	32	딥레드	2.9	17
33	Yellow_normal	3.7	25	연청	2.8	30
34	Yellow_dark	3.3	25	카키 베이지	1.8	28
35	Purple_light	3.7	26	흑청	2.8	28
36	Purple_normal	3.6	20	실버	1.6	31

37	Purple_dark	3.5	34	중청	3.9	29
38	Red_light	2.6	19	진청	3.4	26
39	Red_normal	3.8	26	골드	2.1	20
40	Red_dark	4.0	16	로즈골드	3.2	18
평균	본 논문	3.6	1000	무신사	2.55	1000

제 5 장 결론

5.1 결론

이 연구는 온라인 쇼핑 플랫폼에서 발생하는 색상 필터 기능의 비효율 문제를 해결하는 새로운 방법론을 제시하였다. 이는 사용자들이 원하는 제품을 훨씬 더 효과적으로 찾을 수 있게 도와줄 것이다. 더욱이, 이 논문은 패션 AI 연구 및 개발에서 중요한 도전 과제로 떠오른, 사람의 색상 인지를 정확하게 반영하지 못한 기존의 모델 구조를 개선하는 방안을 탐구하였다. 특히, RGB 색상 공간에서 발생하는 미세한 색상 변화가 사람의 색상 인식에 큰 영향을 미치는 점을 감안하여, 우리의 방법론은 이러한 인간의 색상 인식 특성을 더욱 정확하게 모델링할 수 있도록 설계되었다. 이를 통해 우리는 패션 인공지능 기술이 더욱 발전하고, 그 결과로 온라인 쇼핑 경험이 향상될 수 있도록 기여하고자 한다.

5.2 향후 연구

이 연구는 중요한 첫걸음이지만, 아직도 색상 인식에 대한 과제는 존재한다. 향후 연구는 다음과 같은 방향으로 진행할 수 있다. 첫째, RGB, HSV 색상 공간에 대한 연구보다 더 넓은 범위의 색상 공간을 고려해 볼 수 있다. LAB 등의 다른 색상 공간을 탐색하며, 이러한 다양한 색상 공간이 패션 인공지능의 성능에 어떻게 영향을 미치는지 검토하는 것이 필요하다. 또한 카테고리 세분화 noise 제거 고도화, 의류 분할 고도화 등 더 정확한 색상 추출과 유저 중심의 색상 추출을 도전해 볼 수 있다. 둘째, A/B 테스트를 통해 사용자의 쇼핑 패턴, 클릭 행동, 검색 기록 등 사용자 행동 데이터를 색상 인식 모델에 통합하는 방안을 모색한다. 이렇게 함으로써 더욱 개인화된 쇼핑 경험을 제공하는 인공지능의 발전 가능성을 탐구해볼 수 있다. 셋째, 의류에 대한 연구를 넘어서 다른 패션 아이템들에 대한 연구를 확장한다. 신발, 가방, 액세서리 등 다양한 패션 아이템의 색상 특성에 대한 고려 및 이들이 어떻게 사용자의 쇼핑 경험에 영향을 미치는지에 대한 분석이 필요하다. 특히 뷰티산업에서도 색상에 대한 민감도가 매우 크기 때문에 립스틱 등 다양한 뷰티 산업의 데이터에도 적용해 볼 수 있겠다. 마지막으로, 인공지능의 추천 결과에 대한 사용자의 이해도와 신뢰성을 향상시키는 방안을 찾는다. 타 산업과 다르게 패션 산업은 대부분의 연구가 유저의 사용성을 고도화하는데 집중해 있다. 이는 인공지능의 해석 가능성과 투명성을 높이는 연구가 꼭 연결되어야 하기에 이 연구를 기반으로 한 향후 연구는 Speech To Text와 같이 유저 중심의 metric이 정의해서 연구의 가치가 선정

되는 방법에 대한 연구가 필요하다.

참고 문헌

[1] Choi, T. M., Hui, C. L., Ng, S. F., & Yu, Y. (2012). Color trend forecasting of fashionable products with very few historical data. IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews), 42(6), 1003–1010.

[2] Shin, J., Chae, H., & Ko, E. (2018). The power of e-WOM using the hashtag: Focusing on SNS advertising of SPA brands. International Journal of Advertising, 37(1), 71–85.

[3] DuBreuil, M., & Lu, S. (2020). Traditional vs. big-data fashion trend forecasting: an examination using WGSN and EDITED. International Journal of Fashion Design, Technology and Education, 13(1), 68-77.

[4] Han, A., Kim, J., & Ahn, J. (2022). Color Trend Analysis using Machine Learning with Fashion Collection Images. Clothing and Textiles Research Journal, 40(4), 308-324.

[5] LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, *86*(11), 2278-2324.

[6] Hinton, G. E., Srivastava, N., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. R. (2012). Improving neural networks by preventing co-adaptation of feature detectors. *arXiv preprint arXiv:1207.0580*.

[7] Nair, V., & Hinton, G. E. (2010). Rectified linear units improve restricted boltzmann machines. In *Proceedings of the 27th international conference on machine learning (ICML-10)* (pp. 807-814).

[8] Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster r-cnn: Towards real-

time object detection with region proposal networks. *Advances in neural information processing systems*, *28*.

[9] Long, J., Shelhamer, E., & Darrell, T. (2015). Fully convolutional networks for semantic segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 3431-3440).

[10] Zhang, Y., & Wallace, B. (2015). A sensitivity analysis of (and practitioners' guide to) convolutional neural networks for sentence classification. *arXiv preprint arXiv:1510.03820*.

[11] Liu, C., Cao, Y., Luo, Y., Chen, G., Vokkarane, V., & Ma, Y. (2016). Deepfood: Deep learning-based food image recognition for computer-aided dietary assessment. In *Inclusive Smart Cities and Digital Health: 14th International Conference on Smart Homes and Health Telematics, ICOST 2016, Wuhan, China, May 25-27, 2016. Proceedings 14* (pp. 37-48). Springer International Publishing.

[12] Girshick, R., Donahue, J., Darrell, T., & Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 580-587).

[13] Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster r-cnn: Towards real-time object detection with region proposal networks. *Advances in neural information processing systems*, *28*.

[14] He, K., Gkioxari, G., Dollár, P., & Girshick, R. (2017). Mask r-cnn. In *Proceedings of the IEEE international conference on computer vision* (pp. 2961-2969).

[15] Jain, A. K. (2010). Data clustering: 50 years beyond K-means. *Pattern recognition letters*, *31*(8), 651-666.

[16] Ester, M., Kriegel, H. P., Sander, J., & Xu, X. (1996, August). A density-based algorithm for discovering clusters in large spatial databases with noise. In *kdd* (Vol. 96, No. 34, pp. 226-231).

Abstract

Color palette generation using fashion e-commerce images: the deep learning

Yongwoo Choi
Department of Industrial Engineering
The Graduate School
Seoul National University

This study addresses the imbalance between the dynamic nature of color definitions in the fashion industry and the consistent color classification employed in the online shopping industry. By analyzing color data from actual sold garments, we propose a color palette that reflects current trends. Additionally, considering the significant impact of subtle value variations in the RGB color space on human color perception, we suggest a user-centric, fine-grained color palette generation approach based on data distribution. Through these efforts, we aim to resolve existing challenges and explore methods to enhance the performance of fashion artificial intelligence systems.

Keywords: Production planning, Optimization, Industrial engineering
Student Number: 2020-27798

감사의 글

서울대학교 산업공학과의 모든 식구들께 감사드립니다. 특히 Big Data/AI 연구실 구성원 식구들과 조성준 교수님께 많은 배움 얻고 갑니다. 사용자 중심의 가치를 만들어 낼 수 있는 인공지능 연구를 지속하겠습니다.