

## 딥러닝을 통한 하이엔드 패션 브랜드 감성 학습

장세윤 · 김하연\*† · 이유리\*\* · 설진석\*\*\* · 김성재\*\*\* · 이상구\*\*\*

서울대학교 생활과학연구소, \*군산대학교 의류학과,  
\*\*서울대학교 의류학과/서울대학교 생활과학연구소, \*\*\*서울대학교 컴퓨터공학부

### Deep Learning for Classification of High-End Fashion Brand Sensibility

Seyoon Jang · Ha Youn Kim\*† · Yuri Lee\*\* · Jinseok Seol\*\*\* ·  
Seongjae Kim\*\*\* · Sang-goo Lee\*\*\*

Dept. of Research Institute of Human Ecology, Seoul National University

\*Dept. of Clothing & Textiles, Kunsan National University

\*\*Dept. of Textiles, Merchandising, and Fashion Design, Seoul National University/  
Research Institute of Human Ecology, Seoul National University

\*\*\*Dept. of Computer Science and Engineering, Seoul National University

Received November 25, 2021; Revised December 15, 2021; Accepted January 25, 2022

#### Abstract

The fashion industry is creating innovative business models using artificial intelligence. To efficiently utilize artificial intelligence (AI), fashion data must be classified. Until now, such data have been classified focusing only on the objective properties of fashion products. Their subjective attributes, such as fashion brand sensibilities, are holistic and heuristic intuitions created by a combination of design elements. This study aims to improve the performance of collaborative filtering in the fashion industry by extracting fashion brand sensibility using computer vision technology. The image data set of fashion brand sensibility consists of high-end fashion brand photos that share sensibilities and communicate well in fashion. About 26,000 fashion photos of 11 high-end fashion brand sensibility labels have been collected from the 16FW to 21SS runway and 50 years of US *Vogue* magazines beginning from 1971. We use EfficientNet-B1 to establish the main architecture and fine-tune the network with ImageNet-ILSVRC. After training fashion brand sensibilities through deep learning, the proposed model achieved an F-1 score of 74% on accuracy tests. Furthermore, as a result of comparing AI machine and human experts, the proposed model is expected to be expanded to mass fashion brands.

**Key words:** Fashion brand sensibility, High-end fashion, Image classification, Supervised learning, Deep learning; 패션 브랜드 감성, 하이엔드 브랜드, 이미지 분류, 지도 학습, 딥러닝

†Corresponding author

E-mail: [hykim@kunsan.ac.kr](mailto:hykim@kunsan.ac.kr)

본 논문은 박사학위 논문의 일부임.

This work was supported by the Korea Creative Contents Agency funded by the Korean Government (R2020040102, Technology development of intelligent fashion demand prediction and market analysis to improve fashion design for small business owners).

#### I. 서 론

패션 산업은 트렌드가 지배적인 역할을 하는 산업으로서, 다른 어떤 산업보다 상품수명의 주기가 짧은 제품을 다루고 있기에 수요 예측을 정확히 하는 것을 매우 중요하게 생각해 왔다. 특히 상품기획자나 디자이너가 트렌드를 이끌던 시대에는 그들의 휴리스틱한

판단과 직관(intuition)이 의사결정에 중요하게 작용해 왔다(DuBreuil & Lu, 2020; Lin & Yang, 2019; Takagi et al., 2017). 그러나 이러한 예측 방법은 디자이너의 예술적 견해나 상품기획자의 과거 판매 데이터에 기반한 회귀적 판단이기 때문에 비즈니스상에서 위험요소로 존재한다(DuBreuil & Lu, 2020; Israeli & Avery, 2018). 최근 데이터 분석 기술이 만족한 수준에 도달하게 되면서, 패션 기업에서도 누적된 방대한 양의 빅데이터에서 큰 흐름을 읽어내고, 데이터에 기반하여 실시간으로 판매에 대응하기 위해 인공지능 기반 의사결정 지원 서비스를 도입하고 있다. 구체적으로 어떤 디자인의 상품을 얼마나 생산할 것인가, 언제 어떤 상품을 얼마만큼 가격인하 할 것인가와 같은 기업의 이윤과 직결된 문제를 빅데이터 분석 결과로 도출된 증거를 기반(evidence-based)으로 해결하고 있다.

글로벌 시장조사기관인 MarketsandMarkets™(2019)에 따르면 글로벌 패션 시장에서 인공지능 기술의 규모는 2019년 \$228million(약 2,550억 원) 정도로 추산되지만, 2024년에는 \$1,226million(1조 4천억 원)으로 급성장해 연평균 성장률이 40.8%에 달할 것으로 예상된다. 글로벌 패션 뉴스 WWD(Women's Wear Daily)에 따르면, 패션 기업이 인공지능 기술을 도입함으로써 고객에게 개인화된 경험을 제공하고, 효율적인 재고 관리가 가능해지면서 불필요한 재고를 20~50%까지 감축시킬 수 있을 것으로 기대된다. 이 뿐만 아니라, 빅데이터와 인공지능 기반으로 트렌드를 예측할 경우, 예측에 따른 오류는 최소 50% 이상 감소될 것으로 전망하였는데, 이는 패션 디자이너가 평소에 트렌드 예측을 위해 수행하는 작업을 30%까지 대체해 주는 것이다. 다시 말해 인공지능은 디자이너의 본질적인 작업 방식을 바꿀 수는 없지만, 디자이너가 보다 높은 가치의 디자인에 집중할 수 있도록 지원해 줄 수 있는 도구가 될 것으로 기대된다(Standish & Ganapathy, 2018).

인공지능과 빅데이터 기술의 발전은 소비자에게 온라인의 무수히 많은 대안 중에서 개인의 취향에 가장 잘 맞는 상품을 추천해 줌으로써 소비자의 구매의사 결정 과정을 획기적으로 감소시켜주었다. 그러나 패션 상품은 브랜드 정체성, 브랜드 권위, 사회적 상징, TPO 등과 같이 눈에 보이지 않는 속성이 소비자의 선택에 크게 영향을 미치기 때문에, 사용자 구매이력이나 회원 정보 등 명시적인 정보를 바탕으로 하는 일반적인 추천 알고리즘으로 패션의 다차원적 속성을 읽어내기

에 어려움이 있다. 따라서 패션의 본질에 좀 더 가까이 다가가기 위해서는 패션 이미지가 전달하는 감성적인 속성까지 읽어내는 시각지능의 정교화가 수반되어야 한다.

패션 사진을 포함한 이미지는 데이터로 정형화시키기 어려워 분석과 예측의 정보로 투입되는 사례가 드물었다. 하지만 이미지 데이터는 색상, 도형 등의 속성 정보를 포함하고 있을 뿐만 아니라 텍스트보다 훨씬 풍부한 정보를 내포하고 있다고 알려져 있다(Hong et al., 2016). 따라서 이를 분석에 활용하기 위해서는 이미지를 데이터로 정제(preprocessing)하고 분류(classification)하는 메타데이터화 작업이 반드시 선행되어야 하며, 이 정도에 따라 분석 및 예측 모델의 정교화 수준이 달라질 수 있다.

지금까지 패션 이미지는 주로 복종, 아이템, 길이감, 컬러, 소재감, 실루엣, 디테일 등의 다면적인 속성에 해당하는 정보를 속성 값(value)으로 변환해서 메타데이터화되었다. 여기서 쓰인 속성은 이론상으로 속성 값이 객관적으로 정립되어 있거나, 실무적으로 상품명 등을 통해 속성 값에 대한 접근이 용이하기 때문에 쉽게 사용될 수 있었다. 실제 IT 중심의 패션 인공지능 연구는 패션의 객관적 속성을 메타데이터로 변환시킨 뒤 분류 및 예측 모델에 투입하는 방식이 주를 이룬다(Eshwar et al., 2016; Liang et al., 2015; Liu et al., 2012; Seo & Shin, 2018). 그러나 패션 제품은 객관적인 속성이 서로 유사하거나 같다고 하더라도 브랜드에 따라 서로 다른 디자인의 옷이 될 수 있다. 패션 제품은 브랜드 정체성, 브랜드 콘셉트, 브랜드 스토리, 심볼, 브랜드 헤리티지 등과 같은 추상적 개념이 디자인과 결합되어 표출되기 때문에, 소비자들은 유사한 디자인 속성을 지닌 제품이라도 브랜드마다 서로 다른 감성을 느끼고, 그 결과 서로 다른 제품으로 지각하기 때문이다(Aaker, 1997; Keller & Swaminathan, 2020; Kim et al., 2021; Ko et al., 2012).

또한 대부분의 패션 인공지능 학습이 패션 산업 현장의 요구에서 시작된 것이 아니라, 기술 분야에서 먼저 주도하였기 때문에 패션의 본질을 이해하고 패션도메인 관점으로 접근하는 연구는 부족한 실정이다. 따라서 패션 산업의 도약을 위해서 패션 도메인에 대한 지식을 인공지능 기술에 전이시키는 연구가 필요한 시점이다.

본 연구에서는 패션 브랜드의 유·무형의 디자인 요

소가 결합하며 유발시키는 고유하고 독특하면서 일관성 있는 감각적인 연상과 느낌을 패션 브랜드의 감성이라 정의하고, 색상, 디테일, 아이템 유형과 같은 객관적 속성에 대한 이미지 인식 및 분류뿐만 아니라 측정이 용이하지 않았던 감성에 대한 판명까지도 인공지능이 수행할 수 있도록 브랜드 감성 분류기를 구축하고, 분류기의 판별 능력을 다각도로 검증하고자 하였다. 이를 위해, 첫째, 대표적인 하이엔드 패션 브랜드를 서로 유사한 감성의 집단으로 구분하고, 딥러닝 기술을 활용하여 패션 브랜드 감성 집단을 지도 학습시켰다. 둘째, 브랜드 감성 분류기의 성능을 다각도로 교차 검증해 봄으로써 감성 분류의 실효성을 증명해 보고자 하였다. 구체적으로 브랜드 감성이 잘 녹아든 이미지를 브랜드 감성 분류기에 투입해 봄으로써 분류기의 질적인 성능을 검증하였다. 이 뿐만 아니라 지속적으로 새로운 디자인이 등장하는 패션 산업의 특성을 반영하여, 학습에 투입되지 않은 패션 이미지에 대해서도 브랜드 감성의 분류가 가능한지 검증해 보았다. 마지막으로 하이엔드 패션 브랜드 감성으로 학습한 브랜드 감성 분류기가 매스 패션에도 확대 적용이 가능한지 살펴보았다.

본 연구는 하이엔드 패션 브랜드 감성의 분류와 인공지능 기반의 지도 학습 연구방법 제시를 통해 향후 관련 연구의 마중물 역할을 하는 데 의의가 있다. 또한 실무적 차원에서는 상품추천 과정에서 소비자 선호를 추론하는 데 패션 브랜드 감성이라는 데이터 속성을 추가함으로써 추천 알고리즘이 더욱 정교화될 수 있을 것으로 기대된다.

## II. 관련 연구동향

### 1. 패션 산업에서 인공지능의 활용

인공지능은 인간 고유의 학습, 추론, 지각, 그 밖의 능력을 인공적으로 구현한 컴퓨터 프로그램이나 컴퓨터 시스템이다(Lake et al., 2017). 인공지능을 구현하는 방법으로는 머신러닝(machine learning; 기계 학습)과 그 하위 기술인 딥러닝(deep learning)이 있는데, 2010년대부터 머신러닝과 딥러닝으로 분화하여 연구되기 시작했다. 머신러닝은 수동적으로 제공된 속성 정보들에서 알고리즘을 이용해 데이터를 분석하고, 학습하며, 이를 기반으로 판단이나 예측을 수행한다. 반면 딥

러닝은 인공신경망(artificial neural network; ANN)에서 발전한 형태의 인공지능으로 많은 노드(node), 은닉층 및 학습 알고리즘이 포함된 복잡한 구조를 사용하여, 분류에 중요한 속성을 자동으로 골라서 학습한다는 특징이 있다(Lee & Shin, 2020).

패션에서 인공지능에 대한 연구는 1950년대부터 시도되어 왔으나, 2000년대에 들어서야 패션 제품에 대한 트렌드나 물량 예측, 패션 디자인 지원의 도구로 인식되어 왔다. 패션 도메인에서 대중적인 인공지능 연구방법론으로는 퍼지 이론(fuzzy logic), 유전 알고리즘(genetic algorithms), 의사결정 나무(decision trees), 베이저안 네트워크(Bayesian networks), 딥러닝 알고리즘(ANN, CNN, ARIMA 등)이 있다.

Yun et al.(2009)은 의류 제품의 품질향상과 봉제공정 자동화 관점에서 겉감의 물성에 따라 최적의 접착심지를 선정하는 전문가의 문제해결 과정을 퍼지 이론으로 변환하는 연구를 수행하였다. 퍼지 이론에서 애매하고 불확실한 개념은 0~1 사이의 연속적인 값의 멤버십 함수로 표현될 수 있다. 연구자들은 접착포의 전단, 굽힘, 신도 등 물성을 ‘낮음(0) - 적절(1) - 높음(0)’의 구체적인 퍼지 값으로 변환시켰고, 접착심지가 부착된 접착포의 물성을 예측함으로써 최적의 심지를 도출하는 과정을 증명하였다.

유전 알고리즘은 유전자가 이전 세대 정보를 저장하여 다음 세대에 전달하되, 교배(crossover), 변이(mutation) 등의 진화 과정을 거치며 보다 우월한 염색체를 전달한다는 생물의 유전 현상을 접목한 것이다. 선행연구(Kim & Cho, 2000; Tokumaru et al., 2003)에서는 실루엣, 디테일, 트리밍 등 디자인 속성을 조합하여 다음 세대의 디자인을 생성해 내는 프로그램을 개발했다.

의사결정 나무는 전체 자료를 몇 개의 소집단으로 분류하거나, 예측하는 대표적인 빅데이터 분석 방법이다. 선행연구에서는 판매 패턴 유형을 목표 변수로 하여, 보유했던 데이터를 가장 잘 분리할 수 있는 상품의 속성 값을 찾아 최종 목표에 이르기까지 데이터를 분기시켜 나갔다. 이러한 로직에 따르면 특정 상품의 속성을 의사결정 나무에 대입시켜 나감으로써 판매 패턴 유형을 예측할 수 있다. Lee et al.(2014)은 가을에 판매된 남성 브랜드 제품의 품목, 디자인, 가격, 소재, 색상, 패턴, 핏의 7개 상품속성을 투입해 4가지 유형의 판매 패턴을 도출하였고, Chae and Kim(2020)은 스포츠 브랜드의 티셔츠 판매 패턴과 연관된 구체적인 상품

속성의 조합을 밝힘으로써 패션 상품의 수요 예측에 적용하여 보았다.

Mello et al.(2008)은 시즌의 콘셉트를 나타내는 일련의 키워드 및 이미지를 기반으로 새로운 시즌을 위한 자동 컬러 예측 프로그램을 개발하였다. 연구자들은 패션 스타일리스트의 창의적인 디자인 프로세스를 모방하여 지식 기반 컬러 예측 시스템을 모델링하였다. 이 과정에서 선행 트렌드가 이어지는 트렌드에 영향을 미치게 된다는 개념은 확률적인 추론 방법인 베이지안 네트워크 알고리즘으로 증명하였다.

## 2. 패션 이미지 분류

패션 사진을 포함한 이미지는 시각 정보이기 때문에 색상, 도형 등의 속성 정보를 포함하고 있을 뿐만 아니라 텍스트보다 풍부한 정보를 내포한다(Hong et al., 2016). 이러한 패션 이미지를 빅데이터와 인공지능에서 고차원적으로 활용하기 위해서는 이미지에 대한 속성을 데이터화하는 메타데이터 작업이 선행되어야 한다. 특정 이미지가 어떤 속성에 해당하는지 찾는 이미지 분류 기술은 2015년을 기점으로 사람의 인식 오류율인 5%를 넘어서서 2017년에는 2%에 이르렀으며(Cooper, 2019), 인간이 감지하기 어렵거나 불가능한 것들까지도 객관적이고 정확한 방식으로 감지하며 산업 분야에서 생산성의 혁신을 가져오고 있다. 패션 산업에서 이미지 분류 기술은 색상, 스타일, 길이, 패턴과 같은 구체적인 속성을 추출할 수 있도록 성능이 향상됨에 따라 사용자 자신도 인식하지 못하는 잠재적인 취향을 파악하는 도구로 사용될 수 있다(An et al., 2019).

패션 이미지를 분류하는 방법은 크게 정답을 주고 속성을 학습을 시키는 지도 학습(supervised learning)과 유사한 패턴을 스스로 찾아서 분류하는 비지도 학습(unsupervised learning)으로 구분된다. 먼저 지도 학습 방법을 이용한 이미지 분류는 특정 속성 값을 예측하기 위한 분류기를 구성하고 해당 속성이 레이블링된 데이터 셋을 훈련시켜, 새로운 패션 사진이 투입되었을 때 특정 속성 값으로 분류되게 신경망을 학습시키는 방법이다(Kiapour et al., 2014; Ma et al., 2017; Takagi et al., 2017). 선행연구에서는 정답 셋을 구축하기 위한 정보 출처로 온라인 쇼핑몰이나 소셜 미디어를 주로 활용해 왔다(Jia et al., 2019; Sadeh et al., 2019). 이

때 주로 아이템(예: 티셔츠, 폴오버, 셔츠 등)에 해당하는 이미지를 수집하여 학습(Seo & Shin, 2018)하였기 때문에, 학습 데이터 구축의 편의성은 높지만, 패션의 본질인 표현성, 심미성 등 주관적 속성은 간과되는 경향이 있었다.

패션의 감성적인 측면을 고려한 선행연구에서도 감성 분류의 한계점은 존재한다. 예를 들어 Takagi et al.(2017)의 연구에서는 패션 도메인 전문가들이 의복 스타일을 14개 감성(conservative, dressy, ethnic, fairy, feminine, gal, girlish, casual, lolita, mode, natural, retro, rock, street)으로 분류하였고, 감성의 지도 학습을 위해 감성을 대표하는 사진을 총 1만 3천여 장 구축하였다. 하지만 이 분류 기준에서 캐주얼(casual)은 다른 개념을 포괄하는 상위 개념으로 볼 수 있고, 젊은 여성의 착장을 연상시키는 가루(gal)나 로리타(lolita), 걸리시(girlish)의 경우, 시각적 차이를 명확히 분류하기가 쉽지 않다. 유행(mode)이라고 명명한 속성 값도 특정 착장을 연상하기에 어려움이 있다.

또한 패션 쇼핑몰이나 소셜 미디어의 특성 상 특정 시점에 노출된 정보를 수집하다보니 일부 감성 중심으로 속성이 구성되기도 한다. 예를 들어 Kwon et al.(2020)은 소셜 미디어에 주로 등장하는 패션 스타일 유형을 분류하였는데, 캐주얼과 스포티(sporty)와 관련한 단어가 중점적으로 도출되는 경향이 있었다. 반면, 현재 도래하지 않은 감성 값은 속성 구축 단계에서 제외될 수 있다.

반면에 정답 셋을 주고 학습시키지 않아도 스스로 유사성의 패턴을 찾아서 분류해내는 비지도 학습 방식을 사용하는 연구도 진행되고 있다. Lee et al.(2017)은 사용자가 마음에 드는 옷의 조합을 이미지 보드로 만들어 게시하는 플랫폼인 폴리보어(Polyvore)에서 약 30만 장의 착장 사진을 수집하였고, 딥러닝 알고리즘을 통해 패션 사진 각각을 1,024개 벡터로 변환시킨 후, 벡터를 2D 맵으로 시각화하였다. 그러나 현재 공개된 비지도 학습 알고리즘을 활용하여 컴퓨터가 유사성을 자율 판단하여 분류한 비지도 학습의 결과도 어느 정도 속성 정보가 반영되어 형태와 컬러가 서로 비슷한 것을 가까이에 위치시킨다는 점에서 한계는 존재한다.

이렇게 분류된 의류 속성 정보는 착용자의 성별이나 상황, 의미를 추론하는 중요한 정보로 추천 서비스에 활용되기도 한다(Chen et al., 2012). Chicisimo라는

어플리케이션은 의류 속성과 TPO, 브랜드 간의 연관성을 수학적으로 분석하여 ‘취향의 그래프’로 나타낸 뒤 이 정보를 추천 서비스에 적용하였다(“Taste graphs”, 2019). Chicisimo는 초기 데이터를 수집 과정에서 소비자가 소셜 미디어에 자발적으로 게시한 텍스트뿐만 아니라, 다양한 의미가 내포된 착장 사진에서 소비자 선호와 관련된 속성을 추출하고 데이터로 변환시켰다(Aldamiz-echevarria, 2018). 이 사례 뿐 아니라 이미지 분류를 활용하여 확장 서비스로 개념을 증명하는 연구는 2000년대 초반부터 진행이 되었는데, Tokumaru et al.(2003)은 색의 조화와 감각을 기반으로 셔츠와 함께 입을 재킷이나 바지 등을 추천하는 가상 스타일링 프로그램을 제안하였다. 이후 Cheng and Liu (2008)의 연구에서는 의복의 객관적 속성인 컬러, 프린트, 형태, 소재를 ‘warm & cool, cheeriness, fitness, softness’의 퍼지 집합에 대응시켜 신경망에 투입하였다. 그 결과, 사용자가 원하는 이미지와 행사를 대입시키면 상황에 가장 잘 맞는 의복을 10개의 스타일(sexy, modern, sophisticated, elegant, luxuriant, romantic, girly, masculine, sporty, casual) 중에서 추천받을 수 있었다. 이와 유사한 개념으로 Chen et al.(2012)은 의복 속성을 분류하고, 속성 간의 상호 의존적인 동시 발생(co-occurrences) 정보를 바탕으로 스타일의 규칙을 모델링하였다. 최종적으로 고객의 옷장에서 스타일을 분석하고 제품을 추천하는 시스템을 설계하였다.

### 3. 하이엔드 패션 브랜드 감성

심리학에서 감성(sensibility)은 인간의 심리적인 반응으로 복합적이고 다양한 의미를 포함한다. 제품에 대한 소비자의 지각된 브랜드 감성은 제품의 단일 속성에 의해 결정되기보다 유·무형적 속성 요소들의 총체적인 결합에 의해 결정된다(Zhang et al., 2012). 패션 제품의 유형적 속성은 제품이나 서비스를 다른 경쟁사들과 식별하기 위해 사용하는 제품의 형태 또는 외관과 관련된 속성으로 시그니처한 컬러, 소재, 프린트와 패턴, 스타일, 디테일, 로고플레이 등으로 브랜드마다 상징성과 전형을 가진다(Fionda & Moore, 2009; McQuarrie & Phillips, 2008; Phillips et al., 2014). 무형적 속성은 브랜드가 가지는 상징적이며 외재적인 속성으로 크리에이티브 디렉터의 독창성, 감각, 브랜드 네임, 로고 연상, 브랜드 전통 등으로 이들 역시 브랜드

를 구성하는 주요 축이다(Keller, 2003). 이 뿐만 아니라 패션 브랜드의 뮤즈, 모델의 포즈 등 제품을 표현하는 간접적인 요소 모두 패션 브랜드의 감성에 영향을 미친다(Barron, 2021).

브랜드 감성과 유사하지만 차별화된 용어로 브랜드 이미지가 있다. 브랜드 감성이 상징성과 전형성이 높은 유·무형적 속성을 통해 제품에 전이된 인상이라면, 브랜드 이미지는 소비자 개개인이 과거 브랜드에 대한 인상적인 경험이나 메시지를 통해 형성된 강력하고 호의적인 브랜드 연상 작용의 일환이다(Keller, 2003). 여기에는 소비자들이 특정 브랜드를 접할 때 기억 속에서 떠오르는 브랜드에 대한 인지적, 감정적, 감각적 연상(Carpenter et al., 2005; Cho & Fiore, 2015; Clarke et al., 2012)이 포함된다(Ross & Harradine, 2011). 패션 제품의 경우에도 디자인, 리테일 환경, 프로모션 등 외부 자극은 소비자로 하여금 즐거움이나 행복과 같은 주관적 느낌을 통해 브랜드의 총체적인 이미지를 형성한다(Cho & Fiore, 2015). 브랜드 이미지는 소비자의 지각과 경험, 연상에 따라 해석이 다를 수 있지만, 브랜드 감성은 비교적 일관되게 전달된다.

이러한 패션 브랜드 감성은 특히 하이엔드 패션 브랜드에서 잘 드러난다고 알려져 있다. 대부분의 하이엔드 패션 브랜드나 디자이너들은 브랜드의 정체성이나 원형에 가까운 DNA를 제시한다(Svendsen, 2004/2006). 또한 이들은 자사 브랜드에 대한 소비자의 정서적 몰입을 증대시키기 위해 새로운 디자인에 끊임없이 의미와 상징을 부여하여 소비를 유도하고, 의미와 상징을 해석하는 과정에서 발생하는 브랜드 감성을 소비자와 공유한다. 따라서 계속해서 변화하는 트렌드 안에서도 하이엔드 패션 브랜드만의 일관된 브랜드 감성이 소비자에게 전달되고 있다(Fionda & Moore, 2009). 예를 들어 프랑스 파리의상조합의 멤버로 오프 꾸뛰르와 프레타포르테를 모두 개최하는 샤넬은 샤넬 라인이라고 불리는 인체 라인을 살린 실루엣과 함께 저지 가디건 수트, 골드버튼, 브레이드(braid) 장식, 대칭적 포켓 장식, 트위드 소재를 조형적 특징으로 가진다(Choi et al., 2018). 뿐만 아니라 창업자 코코샤넬에서부터 시작된 여성의 우아함과 미니멀리즘, 활동성, 기능성을 강조하는 브랜드 철학은 칼 라거펠트에 의해 자수나 밝은 톤이나 가장 단순한 흑백으로의 컬러 변형 등을 거치며 현대 여성 패션의 상징적인 브랜드가 되었다(Teo, 2018). 이러한 유·무형적 속성은 현재

에 이르기까지 샤넬만의 고유한 브랜드 감성으로 전달되고 있다.

특히 소비자는 자신을 표현하기 위해 패션 제품에 부여된 상징적 의미를 사용하며, 이에 따라 자신이 원하는 이미지를 만드는 데 도움이 되는 패션 브랜드를 구매할 가능성이 높기 때문에(Escalas & Bettman, 2005), 패션 브랜드와 리테일러에게 패션 브랜드의 감성을 이해하고 분류하는 것은 중요하다. Gaskill(as cited in Hines & Bruce, 2007)에 따르면, 패션 기업은 시즌 기획의 초기 단계에서 주요 패션 도시에서 열리는 패션 브랜드의 런웨이 정보를 수집하고 분석한다. 이 때 파급력 있는 디자이너들의 런웨이를 분석하는 업무를 반복하여 진행하며 이들의 감성을 학습하여, 패션 산업 종사자들과 커뮤니케이션하는 요소로 사용하기도 한다. 뿐만 아니라 패션 산업에서는 브랜드 위계의 중간에 위치해 있는 중저가의 패스트 패션 브랜드나 온라인 리테일러들이 하이엔드 브랜드의 디자인을 참고하여 자사 라벨로 빠르게 생산·판매하는 낙오프(knock-off)가 자주 언급된다(Copeland et al., 2019). 이러한 현상은 패션 위계를 관통하며 공유되는 패션 브랜드 감성이 존재함을 방증한다.

### III. 연구방법 및 절차

#### 1. 연구문제

최근 들어 패션 빅데이터를 활용하여 새로운 가치를 창출하는 비즈니스 모델이 생겨나고, 전통적인 패션 제품 생산 및 판매 패러다임도 변화를 맞이하고 있다. 패션 빅데이터를 정교하게 분석하기 위해서 선행되어야 할 것은 패션 이미지가 무엇을 의미하고 있는지를 알아내고, 컴퓨터가 인식할 수 있는 속성과 값으로 매칭시켜 데이터화하는 것이다. 패션 아이템이 가지는 색상, 소재, 아이템, 디테일, 실루엣 등의 객관적 속성은 머신러닝을 기반으로 하여 이미 높은 정확도로 속성 값이 자동 분류되고 있다. 그러나 패션은 단순 공산품이 아닌 사회적 상징을 가진 제품으로 패션 감성에 대한 정의는 연구마다 또는 문화권마다 상이하고, 학습에 사용된 자료의 출처와 수집 시기에 따라 특정 감성이 편향될 수 있다. 무엇보다 착장 사진을 특정 감성으로 분류하는 과정에서 분류자의 주관성이 배제될 수 없기 때문에, 일정한 기준을 가지고 감성을 자동

으로 분류할 수 있는 방법을 고안해야 한다. 특히 인공지능 기술이 상용화 수준으로 올라서고 있는 현재 시점에서 고차원적인 패션 이미지의 활용을 위해서는 패션 분야의 배경지식인 도메인 지식을 인공지능 기술에 전이시키고 이를 충분히 학습하는 것이 중요하다. 따라서 본 연구는 다음과 같은 연구문제를 설정하였다.

연구문제 1. 하이엔드 패션 브랜드로 유형화된 브랜드 감성을 지도 학습한다.

연구문제 2. 학습된 하이엔드 패션 브랜드의 감성 분류기의 실효성을 다각적으로 교차 검증한다.

#### 2. 연구절차

패션 브랜드의 감성은 패션 산업 내에서도 하이엔드 패션 브랜드에서 가장 두드러지게 발현되고 있으며, 상호간에 하이엔드 브랜드 감성으로 커뮤니케이션이 가능하다. 이에 브랜드 감성이 두드러지는 하이엔드 패션 브랜드를 선정하고, 시각 지능 기술을 이용하여 브랜드의 이미지에서 패션 브랜드 감성을 지도 학습하고자 하였다. 특히 패션 사진의 의미적 요소를 학습하기 위해 하이엔드 패션 브랜드의 런웨이 사진을 일차적으로 확보하였다. 또한 런웨이가 열리는 특정 시기에만 브랜드 감성이 편향되어 학습되지 않도록 광범위한 기간에 걸쳐 발행된 해당 브랜드의 화보, 광고 사진을 선별하여 지도 학습 데이터로 추가함으로써 학습 데이터의 조건을 다양화하였다. 이후 분류기의 성능을 다각도의 평가용 데이터 셋으로 검증해봄으로써 패션 브랜드 감성 분류의 실효성을 증명해보고자 하였다.

#### 3. 지도 학습을 위한 데이터 수집

패션 브랜드 감성을 학습시키기 위해 패션 브랜드 위계의 가장 상위에 위치하는 하이엔드 패션 브랜드의 사진을 디지털 미디어에서 수집하였다. 수집 대상은 Kim et al.(2021)의 선행연구에서와 같이 국내 패션 산업 전문가들이 하이엔드 패션 브랜드 중 브랜드 감성이 다른 브랜드와 충분히 구별되고 있다고 평가한 11가지 그룹(cluster)에 속한 20개 브랜드이다. 구체적으로 C1(Gucci, Thom Browne), C2(Louis Vuitton, Bur-

berry), C3(Christian Dior), C4(Chanel), C5(Hermès, Bottega Veneta), C6(Jil Sander, Celine, Chloé), C7(Isabel Marant), C8(Acne Studio, Maison Margiela), C9(Alexander McQueen), C10(Balenciaga, Saint Laurent, Balmain), C11(Off-White, Vetements)로 명명되었다. 예를 들어 C6 그룹의 Jil Sander, Celine, Chloé는 서로 유사한 브랜드 감성을 지닌 하이엔드 브랜드들로 C6의 레이블에 함께 속하게 된다.

지도 학습을 위해서는 레이블당 최소 1천 장 이상의 학습용 데이터가 요구된다(Jin & Liang, 2017; Schneider et al., 2020). 이러한 기준에 따라 최신의 브랜드 감성을 유지하면서 최소 학습 기준을 충족시킬 수 있도록 최근 5년치(2016 FW~2021 SS) 런웨이 패션 사진을 수집하였다. 이에 더하여 패션 잡지 『보그(Vogue)』에서 선정된 브랜드의 화보와 광고 사진을 추가로 수집하였다.

1) 런웨이 이미지

소셜 미디어나 쇼피몰 등 웹 상에 등장하는 패션 이미지는 옷의 접히거나 늘어나는 특성이나(Eshwar et al., 2016), 패션 이미지의 촬영 컨디션의 상이함(Wang & Ai, 2011)으로 인해 동일한 조건에서의 학습 데이터를 확보하기가 어렵다. 이에 대한 대안으로 Seo and Shin (2018)은 런웨이 데이터 셋을 제안하였다. 런웨이 사진은 브랜드별로 배경에 상이함이 있지만, 배경을 아웃포커스 하여 흐릿하고 서 있는 포즈로 사진을 찍기 때문에 비교적 이미지의 컨디션이 동일한 조건이라 학습에 필요한 전처리 과정이 거의 요구되지 않는다. 이에 패션 런웨이 사진을 수집, 온라인으로 공유하는 사이트 태그워크(www.tag-walk.com)에서 20개의 하이엔드 패션 브랜드가 5년 동안(2016 FW~2021 SS) 개최한

오프 꾸뛰르 및 프레타포르테 런웨이 사진 15,714장을 수집하였다.

2) 패션 잡지 이미지

하이엔드 패션 브랜드의 런웨이 사진은 브랜드와 디자이너의 정체성을 담기 마련이지만, 예술성 또한 높다. 반면 일반 소비자들이 평소에 주로 접하는 하이엔드 패션 브랜드의 사진은 보다 상업적으로 해석된 이미지가 많다. 이러한 점에 착안하여 고해상도의 패션 화보와 광고를 게재하는 글로벌 패션 잡지 『보그』의 온라인 아카이브(www.archive.vogue.com)에서 패션 사진을 추가로 수집하였다. 보그 아카이브는 1892년부터 매달 미국판 보그의 이슈를 수록하고 있다. 하지만 발행 기간 중 흑백 사진이 포함되어 있고, 컬러도 학습에 영향을 미치기 때문에 1971년 1월 1일 이후부터 2020년 10월 31일까지 약 50년간 게재된 컬러 사진으로 한정하여 하이엔드 패션 브랜드의 광고와 화보, 표지 이미지를 수집하였다. 검색결과가 없는 세계 브랜드(Off-White, Thom Browne, Vetements)를 제외하고 17개의 브랜드에서 총 25,613장의 패션 사진을 수집하였고, 이 중 전신의 착장이 잘 드러나는 10,640장의 사진만을 선별하여 지도 학습에 사용하였다.

IV. 연구결과

1. 하이엔드 패션 브랜드 감성 분류를 위한 지도 학습

패션 사진을 입력하였을 때, 분류한 11개의 패션 브랜드 감성 중 어느 클래스에 속하는지 각 감성을 확률의 분포로 출력하기 위해 <Fig. 1>과 같이 CNN 기반

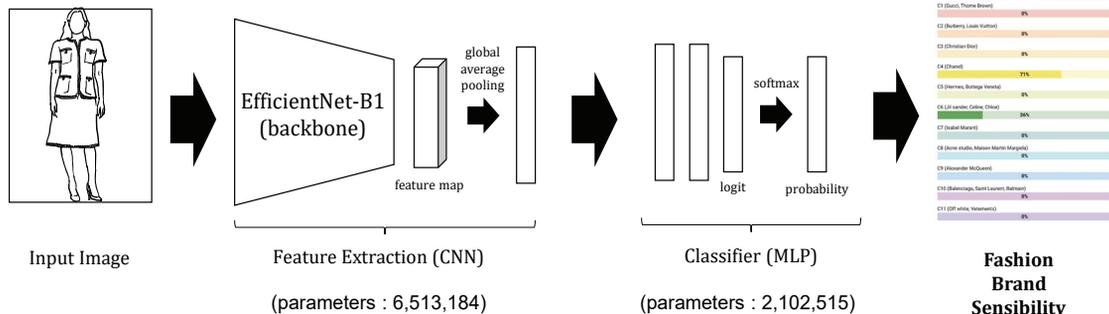


Fig. 1. Deep learning model for classification of fashion brand sensibility.

딥러닝 모델 EfficientNet(Tan & Le, 2019)의 세부 구조 B1을 사용하여 지도 학습을 수행하였다. EfficientNet은 현재까지 알려진 모델 중 모델의 크기 대비 성능이 가장 뛰어나고, 특히 고화질 이미지에 유연하게 대응할 수 있는 장점을 가진 알고리즘이다. 또한 학습의 시간 단축을 위해 대용량의 이미지 셋을 정확하게 분류하는 알고리즘을 선정하는 이미지 인식 경진 대회(ImageNet-ILSVRC) 데이터 셋에서 미리 학습이 된 모델을 가져와서 미세 조정(fine-tuning)하였다. 본 연구에서 11개의 패션 브랜드 감성을 분류하기 위해서 EfficientNet 모델의 가장 마지막 레이어에 3계층의 다층신경망을 추가하였으며, 이미지 분류 과업에 뛰어난 성능을 보이는 최신의 활성화 함수 Swish(Ramachandran et al., 2017)를 사용하였다. 예측 값과 실제 값의 손실(loss)을 최소화하기 위해 Adam의 최적화 알고리즘(Kingma & Ba, 2015)으로 손실 함수를 최적화했으며, 모델의 과적합(overfitting)을 방지하기 위해 학습용 데이터와 5%의 검증용 데이터를 사용하여 교차 검증하며 분류기의 성능을 높여 나갔다.

지도 학습을 위한 데이터의 출처와 수집 기간이 서로 다르기 때문에, 학습에 투입되는 데이터를 달리하여 두 가지 분류 모델을 구축했다. 먼저 R 모델은 태그 워크 내 런웨이 패션 사진만을 학습한 모델이다. 반면, RV 모델은 여기에 좀 더 상업적이고 소비자 접근성이 높은 보그 아카이브의 패션 사진을 추가로 학습한 모델이다. 최종 학습에 사용된 브랜드별, 사진 출처별 학

습 데이터의 수는 <Table 1>과 같다.

<Table 1>에서와 같이 글로벌 최대 패션 매거진인 『보그』의 50년 치 데이터와 2016년 이후 태그워크에 게시된 런웨이 전체를 모두 수집했음에도 불구하고, 비교적 최근에 등장한 브랜드거나, 하이엔드 브랜드의 광고에서 많이 다루지 않은 C7, C8, C9, C11 그룹의 데이터 수가 비교적 적었다. 이러한 점을 극복하고 보다 효과적으로 학습하기 위해서 이미지를 회전 변환하거나 좌우 반전 변환을 활용하는 등의 데이터 증강 기법을 적용하여 학습을 수행하였다. 하이엔드 패션 브랜드 감성 분류를 위한 유사 코드는 <Fig. 2>와 같다.

2. 하이엔드 패션 브랜드 감성 분류기의 성능 평가

모델 구축 및 평가를 위해서는 전체 데이터 셋을 학습을 위한 데이터와 모형 성능을 개선하기 위한 검증용 데이터, 모델 적합성 검증을 위한 평가용 데이터로 분리하여야 한다. 성능 평가의 첫 단계에서는 하이엔드 브랜드 감성을 정확히 판별하는 지 질적으로 검증하기 위해 특정 브랜드 감성이 잘 드러난 평가용 데이터를 추가로 수집하여 모델의 성능을 평가하였다. 패션 디자인 전문가에게 의뢰하여 20개의 하이엔드 패션 브랜드의 감성을 대표할 만한 런웨이 사진을 브랜드별 20개 이내로 선정하였고, 학습에 사용되지 않은 377장의 평가용 데이터 셋을 구축하였다.

브랜드별 평가용 이미지는 앞 단계에서 구축한 패

Table 1. Dataset of supervised learning for fashion brand sensibility

Class name	High-end fashion brand	Tagwalk (n)	Vogue US (n)	Total (N)
C1	Gucci, Thom Browne	2,041	1,546	3,587
C2	Burberry, Louis Vuitton	1,593	1,585	3,178
C3	Christian Dior	1,490	591	2,081
C4	Chanel	1,531	2,018	3,549
C5	Hermès, Bottega Veneta	1,343	1,060	2,403
C6	Jil sander, Celine, Chloé	2,257	970	3,227
C7	Isabel Marant	655	68	723
C8	Acne Studio, Maison Margiela	816	0	816
C9	Alexander McQueen	490	323	813
C10	Balenciaga, Saint Laurent, Balmain	2,862	2,479	5,341
C11	Off-White, Vetements	636	0	636
	Total	15,714	10,640	26,354

```

# Classification of fashion brand sensibility
class Hilda(nn.Module):
    def __init__(self, num_classes: int, arch: str, z_dim: int):
        super(Hilda, self).__init__()
        self.swish = Swish()
        self.cnn = EfficientNet.from_pretrained(f'efficientnet-{arch}')
        self.apool = nn.AdaptiveAvgPool2d((1, 1))
        self.mlp = nn.Linear(ARCH_TO_NUM_FEATURES[arch], z_dim)
        self.clf_fc1 = nn.Linear(z_dim, int(z_dim / 2))
        self.clf_fc2 = nn.Linear(int(z_dim / 2), int(z_dim / 4))
        self.clf_fc3 = nn.Linear(int(z_dim / 4), num_classes)
    def forward(self, x: t.Tensor) -> t.Tensor:
        f = self.apool(self.cnn.extract_features(x)).flatten(start_dim=1)
        v = self.mlp(f)
        v = self.swish(self.clf_fc1(v))
        v = self.swish(self.clf_fc2(v))
        return self.clf_fc3(v)

# Supervised Learning
model = Hilda(num_classes=11, arch=MODEL_ARCH, z_dim=Z_DIM)
for epoch in range(1, EPOCH + 1):
    for X, y in train_loader:
        loss = criterion(model(X.cuda()), y.cuda())
        optim.zero_grad()
        loss.backward()
        optim.step()
    
```

Fig. 2. Pseudo code for classification of fashion brands sensibility.

션 브랜드 감성 분류기에 투입하였고, 그 결과 <Fig. 1> 처럼 각 감성군에 속할 확률과 함께 <Table 2>~<Table 3>의 오차행렬을 얻었다. 각 감성군에 속할 확률은 감성별로 0~100% 사이의 값으로 도출되며, C1~C11의 속성 값을 모두 더하면 100%가 된다. 오차행렬 표에서 행은 딥러닝 수행 결과 예측된 값이며, 열은 지도 학습에서 정답으로 레이블링된 값으로 브랜드가 소속된 집단을 의미한다. 대각선은 레이블링과 예측 값이 일치한 횟수를 의미한다. <Table 2>에서 C1로 레이블링된 값을 C11로 잘못 예측한 경우는 4회, C5를 C8로 잘못 예측한 경우는 2회에 해당됨을 의미한다. 오차행렬을 바탕으로 F1-score, 정확도, 정밀도, 재현율을 계산하여 모델의 성능을 측정하였다. 여기서 정확도(accuracy)란 모델이 입력된 데이터에 대해 얼마나 정확하게 예측하는지를 나타내는 정도로 전체 데이터 중 예측 값(predicted class)과 실제 값(actual class)이 동일한 건수

이며, 정밀도(precision)는 모델의 예측이 얼마나 정확한지 예측 값에서 실제 값의 정답의 비율로 계산한다. 재현율(recall)은 실제 정답 중에서 모델이 정답을 정확히 예측한 비율이다. 즉, 정밀도나 재현율 모두 실제 정답을 정답으로 예측한 것이지만, 정밀도는 모델의 입장에서, 재현율은 실제 정답 데이터의 입장에서 정답을 맞힌 것이다. 마지막으로 F1-score는 정밀도와 재현율의 조화평균으로 계산된다. 정확도는 클래스에 속한 데이터 수 편차에 민감한 반면, F1-score는 클래스의 불균형에 덜 민감하다는 특징이 있다(Goutte & Gaussier, 2005).

학습 모델의 성능 평가 결과, R 모델은 377개 중 251개를 맞춰 F1-score는 .74, 정확도 66.58%, 정밀도 .77, 재현율 .73의 성능을 보였다. 특히 C9, C10의 판별 정확도가 높았으나, C5, C4의 경우 비교적 정확도가 떨어졌다. RV 모델에서는 377개 중 237개의 정답을 맞혔

**Table 2. Confusion matrix for R model**

		Predicted class											Recall
		C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	
Actual class	C1	23	0	1	0	0	1	1	0	0	4	4	.68
	C2	0	17	0	0	0	3	0	0	0	3	0	.74
	C3	1	1	11	0	0	0	0	0	0	1	0	.79
	C4	1	0	1	13	1	0	0	0	0	5	0	.62
	C5	0	2	0	0	29	0	4	2	0	6	7	.58
	C6	3	1	0	0	0	31	1	1	0	3	0	.78
	C7	0	0	0	0	3	0	12	0	0	0	0	.80
	C8	0	0	0	0	4	0	0	32	0	4	3	.74
	C9	1	0	0	0	0	0	0	0	18	0	0	.95
	C10	0	0	1	0	1	2	0	1	0	53	0	.91
	C11	2	0	0	0	1	0	1	1	0	3	12	.60
Precision		.74	.81	.79	1.00	.74	.84	.63	.86	1.00	.65	.46	.74

F1-score = .74, Accuracy = 66.58%, Precision = .77, Recall = .73

**Table 3. Confusion matrix for RV model**

		Predicted class											Recall
		C1	C2	C3	C4	C5	C6	C7	C8	C9	C10	C11	
Actual class	C1	20	1	0	0	0	0	0	1	0	1	1	.83
	C2	3	17	0	2	1	1	1	1	0	15	2	.40
	C3	0	0	11	0	0	0	0	0	0	0	0	1.00
	C4	0	0	1	11	0	2	0	0	0	8	0	.50
	C5	1	0	0	0	29	0	1	0	0	6	2	.74
	C6	3	0	0	0	4	33	2	1	1	7	4	.60
	C7	0	1	0	0	0	0	14	0	0	1	1	.82
	C8	0	0	0	0	0	1	0	34	0	0	1	.94
	C9	0	0	0	0	2	0	0	0	14	1	0	.82
	C10	2	2	2	0	0	0	0	0	3	41	2	.79
	C11	2	0	0	0	3	0	1	0	0	2	13	.62
Precision		.65	.81	.79	.85	.74	.89	.74	.92	.78	.50	.50	.74

F1-score = .74, Accuracy = 62.86%, Precision = .74, Recall = .73

으며 F1-score .74, 정확도 62.86%, 정밀도 .74, 재현율 .73의 성능을 보였다. 두 모델을 비교하였을 때 RV 모델에서는 C4를 제외하고는 R 모델보다 전체적인 정확도는 높았고 C3, C8의 정확도가 특히 높았다. 이를 다양한 관점에서 해석해 볼 수 있다. 우선 런웨이보다 패션 잡지나 화보가 다양한 배경과 포즈 등 학습 조건이 다양하기 때문에 평가용 데이터와 조건이 좀 더 유

사했을 것으로 예상된다. 뿐만 아니라 런웨이 사진은 시즌의 테마와 트렌드로 인해 디자인의 장식적 요소에 강하게 반영될 수 있으나, 화보나 광고는 대표적인 상업적 원천으로 소비자들에게 비교적 익숙한 전형성이 높은 디자인으로 평가용 데이터와 더 유사했을 것으로 추측된다.

시각 지능을 활용하여 이미지 인식의 정확도를 평가

하는 이미지 인식 대회 결과 보고에 따르면, 인공지능으로 이미지의 속성 값을 추론하는 과정에서 정답으로 예측한 5개 후보에 정답이 포함되지 않을 확률이 최근 2.25%까지 낮아졌다(Lee, 2018). 하지만 패션 제품과 같이 다양한 속성의 조합으로 이루어진 이미지의 경우, 이미지 인식의 정확도는 인간의 오류율을 넘어서지 못하는 것으로 알려져 있다. 실제 DeepFashion이라는 패션 데이터 셋을 이용하여 패션 이미지의 카테고리별 예측하는 WTBI, DARN, FashionNet, Deep-fashion 등 알고리즘의 경우에도 속성 값의 3개 후보 내 정답률은 44.73~88.42%에 불과하다(Park et al., 2019). 게다가 선행연구에서 언급된 오류율은 주로 객체 인식에 대한 평가 결과로 주관적 감성을 분류하고자 시도한 본 연구와 직접적인 비교가 어려울 것이다. 다만 사회과학 연구에서와 같이 실험 통제가 어렵고, 개념의 측정이 어려운 경우 40~60%의 설명력도 용인될 수 있다(Abu-Bader, 2021)는 점에서 패션 브랜드 감성이라는 주관적인 개념도 어느 정도 지도 학습과 분류가 가능하다고 볼 수 있다.

### 3. 하이엔드 패션 브랜드 감성 분류기의 확장: 매스 패션 브랜드로의 적용

패션 트렌드 전파 이론 중 하향전파(trickle-down) 이론은 상류층은 남다른 소비를 통해서 자신과 대중의 차이를 벌리려고 하고 대중은 상류층을 따라 함으로써 차이를 줄이려고 한다는 것이다. McCracken(1985)은 사회 속에서 권력을 가진 대상이 미적 전제(aesthetic proposition)가 되기 때문에 대중의 의복은 권력을 가진 의복에 영향을 받게 된다고 주장했다. 따라서 현대 사회 속에서 미적 전제가 될 수 있는 하이엔드 패션 브랜드의 감성은 매스 패션 브랜드에 영향을 미칠 것이라고 유추해볼 수 있다. 이러한 가정을 바탕으로 브랜드 감성 분류기의 확장성을 평가해 보기 위해 국내 패션 산업의 한 축을 이루는 매스 패션 브랜드의 패션 이미지를 패션 브랜드 감성 분류기로 분류할 수 있을지 실험해 보았다.

이에 여성복에 특화된 모 온라인 쇼핑몰에 의뢰하여 2020년 12월에 판매 중인 여성복 카테고리 내 상품 착장 사진 1,000여 장을 제공 받았고, 난수 생성기능으로 36장의 사진을 무작위로 뽑아 평가용 데이터 셋으로 구축하였다. 이를 비교적 모든 감성에서 고른 정확

도를 보인 패션 브랜드 감성 분류기의 RV 모델에 투입하여 브랜드 감성 속성 값으로 변환시켰다. 분류 결과의 정확도 평가 과정에서 매스 패션 상품은 하이엔드 브랜드 감성 값으로 레이블링하기가 어렵다. 따라서 패션 산업의 전문가 8명을 대상으로 인공지능이 분류한 패션 브랜드 감성에 동의하는 정도를 5점 만점의 리커트 척도(1점: 전혀 동의하지 않는다~5점: 아주 동의한다)로 측정하여 정확도를 추정하였다. 응답의 순서 효과를 차단하기 위해 사진의 배치 순서는 무작위로 설정하였다. 응답 종료 후, 각 사진별로 전문가들의 감성 동의 정도를 평균으로 구했고, 기계와의 비교가 용이하도록 이를 100점으로 환산하였다.

<Table 4>에서는 인공지능과 전문가가 도출한 결과를 브랜드 감성 속성 값을 기준으로 비교하였다. 그 결과 인공지능이 특정 브랜드 감성으로 판별하는 정도는 13.79~99.68%(평균 60.96%)였다. C3의 경우를 살펴보면, 인공지능은 착장 사진에서 C3 감성 정도는 13.79%로 낮다고 판별하였지만, 이조차도 다른 감성군과 비교해서 가장 높은 감성으로 판별된 것이었다. 또한 전문가들은 이 사진이 C3 브랜드 감성군으로 분류된 제시된 결과에 대해 72.5%로 동의한 것으로 해석할 수 있다. 평균적으로 전문가들은 인공지능의 판별 결과에 55.00~84.38%(평균 68.77%) 정도 동의하는 것으로 나타났다. 일부 전문가들의 동의 비율이 낮은 C1, C9 감성군은 인공지능의 감성 판별 비율도 비교적 낮았다. 따라서 해당 사진은 여러 브랜드 감성이 혼재되어 있는 상태로 추정된다. 이상의 결과를 종합하여 보면, 매스 패션도 하이엔드 브랜드의 감성을 학습한 분류기를 이용하여 브랜드 감성을 판별할 수 있음을 의미한다. 이를 통해 브랜드 감성 분류기의 확장성을 확인할 수 있었다.

## V. 결론 및 논의

빅데이터 분석 기술은 패션 제품의 생산, 유통, 판매 등의 전통적인 비즈니스 방식에 영향을 미치고 있다. 특히 유통과 판매 분야에서 패션 빅데이터 분석을 통한 추천 서비스가 판매 촉진 도구로 안착되며, 텍스트 뿐 아니라 패션 이미지까지 데이터화하기 위한 시각 지능 연구도 활발히 진행되고 있다(Chakraborty et al., 2020; Kiapour et al., 2014; Liu et al., 2016; Takagi et al., 2017). 특히 패션 산업은 패션 이미지에 담긴 기호

**Table 4. Comparison of AI machine and human experts about mass fashion images**

Predicted class (Brand name)	Top-1 brand sensibility (%)			Predicted class (Brand name)	Top-1 brand sensibility (%)		
	Average of machine <sup>a</sup>	Average of experts <sup>b</sup>	Machine -experts		Average of machine <sup>a</sup>	Average of experts <sup>b</sup>	Machine -experts
C1 (Gucci, Thom Browne)	45.11	55.00	-9.89	C7 (Isabel Marant)	92.11	76.25	15.86
C2 (Burberry, Louis Vuitton)	60.93	68.13	-7.20	C8 (Acne Studio, Maison Margiela)	21.08	84.38	-63.30
C3 (Christian Dior)	13.79	72.50	-58.71	C9 (Alexander McQueen)	22.72	55.00	-32.28
C4 (Chanel)	81.92	68.75	13.17	C10 (Balenciaga, Saint Laurent, Balmain)	91.06	61.67	29.39
C5 (Hermès, Bottega Veneta)	85.29	71.25	14.04	C11 (Off-White, Vetements)	56.88	64.38	-7.50
C6 (Jil Sander, Celine, Chloé)	99.68	79.17	20.51	Average	60.96	68.77	-7.81

a: accuracy of the predicted class by the RV model (0-100%)  
 b: agree ratio of the predicted class evaluated by experts (0-100%)

와 상징으로 커뮤니케이션해 왔기 때문에, 패션 사진을 보았을 때 객관적으로 구별 가능한 속성 외에도 패션 감성과 같은 주관적인 속성도 인공지능이 판별할 수 있는 수준에 다다랐는지 검증이 필요하였다. 이에 본 연구에서는 하이엔드 패션 브랜드의 사진들은 다양한 의미가 함축되어 패션 브랜드 감성을 유추할 수 있을 것이라는 전제 하에 패션 브랜드 감성 분류기를 지도 학습으로 구축하고, 분류 성능을 다각도로 평가해 보았다.

실증 연구의 결과는 다음과 같다.

첫째, 대표 브랜드 감성군에 해당하는 하이엔드 브랜드의 패션 사진을 런웨이와 패션 잡지에서 수집하고, 딥러닝 기법을 활용하여 브랜드 감성군을 지도 학습하였다. Tan and Le(2019)의 EfficientNet의 세부 구조 중 B1을 이용하여, ImageNet-ILSVRC 데이터 셋에서 미리 학습이 된 모델을 가져와서 미세 조정하였다. EfficientNet 모델의 가장 마지막 레이어에 3계층의 다층신경망을 추가하였으며, 활성화 함수로는 Swish를 사용하였다. 본 모델은 학습 데이터의 범위를 런웨이 사진으로만 한정된 ‘R 모델’과 사진의 배경이나 모델의 포즈, 메이크업 등으로 해당 브랜드의 감성을 투영하고 있는 보그 아카이브 내 표지, 광고 사진까지 학습한 ‘RV 모델’로 나누어 지도 학습을 수행하였다. 이러한 과정을 거쳐 패션 사진을 투입하면 브랜드 감성별

로 속성 값의 분포를 도출해내는 패션 브랜드 감성 분류기가 개발되었다.

둘째, 패션 브랜드 감성 분류기의 성능을 평가하기 위해 검증용 데이터 셋을 다각도로 구축하였고, 이를 R과 RV 모델에 투입하여 봄으로써 정확도 성능 지표를 얻었다. 먼저 분류기의 질적 성능을 평가하기 위해 해당 브랜드 감성을 잘 드러내고 있다고 판단되는 브랜드 감성의 전형성이 높은 사진을 평가용 데이터 셋으로 구축하고, R과 RV 모델의 성능을 평가해 보았다. 그 결과 두 모델 모두 정확도 74% 수준으로 성능은 큰 차이를 보이지 않았으나, RV 모델은 R 모델보다 모든 클래스에서 정확도가 좀 더 높은 것을 알 수 있었다. RV 모델의 경우 다양한 배경이나 포즈 등 학습 조건이 평가용 데이터와 유사해 정확도가 좀 더 높았을 수 있다. 향후 정확도 개선의 여지는 존재하지만, 이러한 결과를 바탕으로 인공지능이 사람을 대신하여 비교적 정확하고 일관성 있으며 빠른 속도로 패션 브랜드 감성을 분류할 수 있을 것으로 기대된다.

셋째, 하이엔드 브랜드의 감성이 매스 브랜드로 이어진다는 하향전파설의 가정에 입각하여 하이엔드 브랜드 감성을 매스 브랜드에도 적용이 가능한지 실험하여 보았다. 그 결과 기계(60.96%)가 판별한 결과에 대해 전문가들도 68.77% 동의하며, 매스 패션 브랜드 감성도 본 분류기를 통해 판별이 가능하다는 것을 확

인하였다.

본 연구는 딥러닝 기술의 발전으로 사람이 브랜드 감성을 분류하는 대신 기계가 학습 데이터 셋의 특성을 추론하며 빠른 시간 안에 비교적 높은 정확도로 감성을 분류하는 모델을 개발하였다는 점에서 학문적 의의를 지닌다. 특히 감성 분류기의 개발에 있어 컴퓨터 공학 분야의 최신 인공지능 기술을 접목하였지만, 감성 분류 기준의 체계화부터 학습 데이터의 구축에 이르기까지 학습의 전체 프로세스에서 패션 도메인의 지식이 기계로 전이된 융합 연구로서의 가치를 지닌다. 개발된 패션 브랜드 감성 분류기는 향후 하이엔드 패션 브랜드 감성이 매스 브랜드와 소비자로 전이되는 현상에 대한 연구, 또는 시즌별로 어떤 패션 브랜드 감성이 주로 트렌드로 도래하는지를 시계열적으로 확장하는 연구, 패션 브랜드 감성의 예측력을 높이는 연구의 기초 분석 도구가 될 것이다. 최근에는 생성적 대립 신경망(Generative Adversarial Networks; GAN)을 활용하여 인공지능이 해당 브랜드의 패션 사진을 충분히 학습하고 런웨이나 패션 상품에 선보이는 딥페이크(deep fake) 패션 디자인의 사례로 등장하고 있는데(Ahmed, 2021; Jung, 2021; Kim, 2021; Schwab, 2018), 특정 브랜드 감성을 기반으로 인공지능이 패션 디자인을 생성해내는 기술에도 확장 적용될 수 있을 것이다.

또한 개발된 패션 브랜드 감성 체계는 추상적인 개념인 감성을 기반으로 한 판별하는 도구로, 패션 빅데이터를 활용한 추천 서비스를 포함하여 코디네이션 서비스, 온라인 몰에서의 입점 브랜드 관리, 소비자 프로파일링 등에 다양하게 활용될 수 있을 것이다. 추천 서비스의 경우, 기존의 구매이력을 기반으로 한 유사 제품 서비스 추천을 넘어서, 패션 브랜드 감성을 활용하여 제품 감성과 소비자 감성의 일대일 개인 맞춤형 추천을 제공함으로써 패션 제품 추천이 더욱 정교해 질 것으로 기대된다. 또한 온라인 판매자 입장에서는 소비자 감성과 제품 감성의 연관성을 기반으로 회원 가입 설문지를 개발함으로써 자신의 브랜드와 감성을 공유하는 소비자를 타겟팅하고, 이들의 감성을 공략하는 제품을 기획할 수 있을 것이다.

본 연구에서 패션 도메인 지식을 바탕으로 포괄적인 학습용 데이터 셋을 구축하였음에도 불구하고 브랜드 감성 확장 및 정확도 개선의 여지가 있다. 현재 수준에서는 11가지 브랜드 감성군을 판별할 수 있지만, 여성복 중심으로 초기 감성 클래스를 생성하다 보니

최신의 젠더리스나 캐주얼, 스트리트 관련 감성 이미지가 부족하다. 뿐만 아니라 시대나 크리에이티브 디렉터에 따라 브랜드 감성이 변화하거나, 새로운 감성군이 주목받을 수 있으므로, 이를 고려하여 지속적인 브랜드 감성의 학습이 이루어져야 할 것이다. 또한 딥러닝 모델은 일반적으로 학습을 위해 많은 데이터를 필요로 하고, 데이터가 많을수록 모델의 성능이 더 좋아지는 것으로 밝혀졌기 때문에(Cheerla & Gevaert, 2019; Rashid & Louis, 2019) 학습 이미지 확장 구축을 통해 정확도가 개선되어야 할 것이다. 이와 더불어 인간과 기계의 브랜드 감성 판별 정확도를 비교해 보았을 때, 아직까지는 기계의 정확도가 떨어지는 구간이 일부 확인되었다. 이는 투입된 이미지의 브랜드 감성이 뚜렷하지 않은 경우에 더욱 발생하는 것으로 나타났으므로, 후속연구에서는 사전 선별 작업을 통해 브랜드 감성의 전형성이 높은 착장 사진을 지도 학습하는 전략을 시도를 해보아야 할 것이다. 동시에 본 연구에서 사용한 EfficientNet-B1 뿐 아니라 기타 학습 조건을 추가로 수행해 봄으로써 패션 브랜드 감성 판별 성능 개선에 기여해야 할 것이다.

본 연구에서는 패션 사진에 대한 시각적 학습에 효과가 좋다고 알려진 딥러닝 방식을 적용하여 패션 브랜드에 대한 감성을 학습하였기 때문에 기계가 판별한 브랜드 감성에 대한 인과관계가 마치 블랙박스과 같다. 다시 말해 어떠한 과정을 통해 결과를 도출했는지 확인할 방법이 없다. 이에 대한 후속연구로 CNN 모델에서 어떤 부분을 시각적으로 더 많이 인식했는지 밝히는 그라드캠(Grad-CAM) 연구나 전문가 인터뷰, 브랜드와 관련된 텍스트 빅데이터 분석 등을 다방면으로 수행해 봄으로써 패션 도메인 관점에서 브랜드 감성을 판별하는 결정요인을 밝혀볼 수 있을 것이다.

## References

- Aaker, J. L. (1997). Dimensions of brand personality. *Journal of Marketing Research*, 34(3), 347–356. doi:10.1177/002224379703400304
- Abu-Bader, S. H. (2021). *Using statistical methods in social science research: With a complete SPSS guide* (3rd ed.). New York, NY: Oxford University Press.
- Ahmed, O. (2021, June 7). Balenciaga just staged a deep-fake SS22 fashion show. *i-D*. Retrieved from [https://i-d.vice.com/en\\_uk/article/akg3bb/balenciaga-ss22-show-review](https://i-d.vice.com/en_uk/article/akg3bb/balenciaga-ss22-show-review)

- Aldamiz-echevarria, G. (2018, January 30). How we grew from 0 to 4 million women on our fashion app, with a vertical machine learning approach. *Medium*. Retrieved from <https://medium.com/hackernoon/how-we-grew-from-0-to-4-million-women-on-our-fashion-app-with-a-vertical-machine-learning-approach-f8b7fc0a89d7>
- An, H., Kwon, S., & Park, M. (2019). A case study on the recommendation services for customized fashion styles based on artificial intelligence. *Journal of the Korean Society of Clothing and Textiles*, 43(3), 349–360. doi:10.5850/JKSCT.2019.43.3.349
- Barron, L. (2021). The return of the celebrity fashion muse: Brand endorsement, creative inspiration and celebrity-influenced design communication. *Fashion Theory*, 25(6), 757–776. doi:10.1080/1362704X.2019.1656946
- Carpenter, J. M., Moore, M., & Fairhurst, A. E. (2005). Consumer shopping value for retail brands. *Journal of Fashion Marketing and Management*, 9(1), 43–53. doi:10.1108/13612020510586398
- Chae, J. M., & Kim, E. H. (2020). Sales pattern and related product attributes of T-shirts. *Journal of the Korean Society of Clothing and Textiles*, 44(6), 1053–1069. doi:10.5850/JKSCT.2020.44.6.1053
- Chakraborty, S., Hoque, S. M. A., & Kabir, S. M. F. (2020). Predicting fashion trend using runway images: application of logistic regression in trend forecasting. *International Journal of Fashion Design, Technology and Education*, 13(3), 376–386. doi:10.1080/17543266.2020.1829096
- Cheerla, A., & Gevaert, O. (2019). Deep learning with multimodal representation for pancreatic prognosis prediction. *Bioinformatics*, 35(14), i446–i454. doi:10.1093/bioinformatics/btz342
- Chen, H., Gallagher, A., & Girod, B. (2012). Describing clothing by semantic attributes. In A. Fitzgibbon, S. Lazebnik, P. Perona, Y. Sato, & C. Schmid (Eds.), *Computer vision – ECCV 2012 12th European Conference on Computer Vision, Florence, Italy, October 7–13, 2012, Proceedings, Part III* (pp. 609–623). Berlin and Heidelberg: Springer. doi:10.1007/978-3-642-33712-3\_44
- Cheng, C.-I., & Liu, D. S.-M. (2008). An intelligent clothes search system based on fashion styles. *Proceedings of 2008 International Conference on Machine Learning and Cybernetics*, 3, China, 1592–1597. doi:10.1109/ICMLC.2008.4620660
- Cho, E., & Fiore, A. M. (2015). Conceptualization of a holistic brand image measure for fashion-related brands. *Journal of Consumer Marketing*, 32(4), 255–265. doi:10.1108/JCM-07-2014-1063
- Choi, S.-L., Do, W.-H., & Lee, M.-S. (2018). Analysis of the constructional components of Chanel jacket design. *Fashion & Textile Research Journal*, 20(3), 266–278. doi:10.5805/SFTI.2018.20.3.266
- Clarke, D. W., Perry, P., & Denson, H. (2012). The sensory retail environment of small fashion boutiques. *Journal of Fashion Marketing and Management*, 16(4), 492–510. doi:10.1108/13612021211265872
- Cooper, G. (2019, October 3). New vision technologies for real-world applications. *Semiconductor Engineering*. Retrieved from <https://semiengineering.com/new-vision-technologies-for-real-world-applications/>
- Copeland, L., Ciampaglia, G. L., & Zhao, L. (2019). Fashion informatics and the network of fashion knockoffs. *First Monday*, 24(12). doi:10.5210/fm.v24i12.9703
- 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. doi:10.1080/17543266.2020.1732482
- Escalas, J. E., & Bettman, J. R. (2005). Self-construal, reference groups, and brand meaning. *Journal of Consumer Research*, 32(3), 378–389. doi:10.1086/497549
- Eshwar, S. G., Gautham Ganesh Prabhu, J., Rishikesh, A. V., Charan, N. A., & Umadevi, V. (2016). Apparel classification using convolutional neural networks. *Proceedings of 2016 International Conference on ICT in Business Industry & Government (ICTBIG), India*, 1–5. doi:10.1109/ICTBIG.2016.7892641
- Fionda, A. M., & Moore, C. M. (2009). The anatomy of the luxury fashion brand. *Journal of Brand Management*, 16(5-6), 347–363. doi:10.1057/bm.2008.45
- Goutte, C., & Gaussier, E. (2005). A probabilistic interpretation of precision, recall and *F*-score, with implication for evaluation. In D. E. Losada & J. M. Fernández-Luna (Eds.), *Advances in information retrieval: 27th European Conference on IR Research, ECIR 2005, Santiago de Compostela, Spain, March 21-23, 2005, Proceedings* (pp. 345–359). Berlin and Heidelberg: Springer. doi:10.1007/978-3-540-31865-1\_25
- Hines, T., & Bruce, M. (2007). *Fashion marketing: Contemporary issues* (2nd ed.). Oxford and Burlington: Butterworth-Heinemann.
- Hong, T., Kim, J., & Shin, J. (2016). A user sentiment classification using Instagram image and text analysis. *Smart Media Journal*, 5(1), 61–68.
- Israeli, A., & Avery, J. (2018, March 19). Predicting consumer tastes with big data at Gap. *Harvard Business School*. Retrieved from [https://mycourses.aalto.fi/pluginfile.php/1458535/mod\\_folder/intro/CASE%20GAP%20Predicting%20consumer%20tastes.pdf](https://mycourses.aalto.fi/pluginfile.php/1458535/mod_folder/intro/CASE%20GAP%20Predicting%20consumer%20tastes.pdf)



- by component (solutions and services), application(product recommendation, product search & discovery, and CRM), deployment mode, category, (apparel, accessories, and beauty & cosmetics), end user, and region - global forecast to 2024. *MarketsandMarkets*. Retrieved from <https://www.marketsandmarkets.com/Market-Reports/ai-in-fashion-market-144448991.html>
- McCracken, G. D. (1985). The trickle-down theory rehabilitated. In M. R. Solomon (Ed.), *The psychology of fashion* (pp. 39–54). Lexington, MA: Lexington Books.
- McQuarrie, E. F., & Phillips, B. J. (2008). It's not your father's magazine ad: Magnitude and direction of recent changes in advertising style. *Journal of Advertising*, 37(3), 95–106. doi:10.2753/JOA0091-3367370307
- Mello, P., Storari, S., & Valli, B. (2008). A knowledge-based system for fashion trend forecasting. In N. T. Nguyen, L. Borzemeski, A. Grzech, & M. Ali (Eds.), *New frontiers in applied artificial intelligence: 21st International Conference on Industrial, Engineering and Other Applications of Applied Intelligent Systems, IEA/AIE 2008 Wroclaw, Poland, June 18-20, 2008 Proceedings* (pp. 425–434). Berlin and Heidelberg: Springer. doi:10.1007/978-3-540-69052-8\_45
- Park, S., Shin, M., Ham, S., Choe, S., & Kang, Y. (2019). Study on fashion image retrieval methods for efficient fashion visual search. *Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), USA*, 316–319. doi:10.1109/CVPRW.2019.00042
- Phillips, B. J., McQuarrie, E. F., & Griffin, W. G. (2014). How visual brand identity shapes consumer response. *Psychology & Marketing*, 31(3), 225–236. doi:10.1002/mar.20689
- Ramachandran, P., Zoph, B., & Le, Q. V. (2017, October 27). Swish: A self-gated activation function. *Cornell University*. Retrieved from <https://arxiv.org/abs/1710.05941v1>
- Rashid, K. M., & Louis, J. (2019). Times-series data augmentation and deep learning for construction equipment activity recognition. *Advanced Engineering Informatics*, 47:100944. doi:10.1016/j.aei.2019.100944
- Ross, J., & Harradine, R. (2011). Fashion value brands: the relationship between identity and image. *Journal of Fashion Marketing and Management*, 15(3), 306–325. doi:10.1108/13612021111151914
- Sadeh, G., Fritz, L., Shalev, G., & Oks, E. (2019, June 15). Joint visual-textual embedding for multimodal style search. *Cornell University*. Retrieved from <https://arxiv.org/abs/1906.06620>
- Schneider, S., Greenberg, S., Taylor, G. W., & Kremer, S. C. (2020). Three critical factors affecting automated image species recognition performance for camera traps. *Ecology and Evolution*, 10(7), 3503–3517. doi:10.1002/ece3.6147
- Schwab, K. (2018, August 22). This AI designs Balenciaga better than Balenciaga. *Fast Company*. Retrieved from <https://www.fastcompany.com/90223486/this-ai-designs-balenciaga-better-than-balenciaga>
- Seo, Y., & Shin, K.-s. (2018). Business application of convolutional neural networks for apparel classification using runway image. *Journal of Intelligence and Information Systems*, 24(3), 1–19. doi:10.13088/jiis.2018.24.3.001
- Standish, J., & Ganapathy, V. (2018, December 27). Think tank: How AI can power the future of fashion. *WWD*. Retrieved from <https://wwd.com/business-news/business-features/jill-standish-think-tank-1202941433/>
- Svendsen, L. (2006). *Fashion: A philosophy* (J. Irons, Trans). London: Reaktion Books. (Original work published 2004)
- Takagi, M., Simo-Serra, E., Iizuka, S., & Ishikawa, H. (2017). What makes a style: Experimental analysis of fashion prediction. *Proceedings of 2017 IEEE International Conference on Computer Vision Workshops (ICCVW), Italy*, 2247–2253. doi:10.1109/ICCVW.2017.263
- Tan, M., & Le, Q. V. (2019). EfficientNet: Rethinking model scaling for convolutional neural networks. *Proceedings of the 36th International Conference on Machine Learning, USA*, 6105–6114.
- Taste graphs will transform fashion – Fashion Taste API. (2019, April 10). *Chicisimo*. Retrieved from <https://blog.chicisimo.com/2019/04/10/taste-graphs-fashion/>
- Teo, M. (2018, October 23). How Coco Chanel revolutionised women's fashion with just a jacket. *Lifestyle Asia*. Retrieved from <https://www.lifestyleasia.com/sg/style/fashion/how-coco-chanel-revolutionised-womens-fashion-with-just-a-jacket/>
- Tokumaru, M., Muranaka, N., & Imanishi, S. (2003). Virtual Stylist project - examination of adapting clothing search system to user's subjectivity with interactive genetic algorithms. *Proceedings of The 2003 Congress on Evolutionary Computation '03, 2, Australia*, 1036–1043. doi:10.1109/CEC.2003.1299782
- Wang, N., & Ai, H. (2011). Who Blocks Who: Simultaneous clothing segmentation for grouping images. *Proceedings of 2011 International Conference on Computer Vision, Spain*, 1535–1542. doi:10.1109/ICCV.2011.6126412
- Yun, S. Y., Kim, S., & Park, C. K. (2009). Development of an expert system for optimum fusible interlining. *Journal of the Korean Society for Clothing Industry*, 11(4), 648–660.
- Zhang, L., Hu, C., Chen, Q., Chen, Y., & Shi, Y. (2012). Domain knowledge based personalized recommendation model and its application in cross-selling. *Procedia Computer Science*, 9, 1314–1323. doi:10.1016/j.procs.2012.04.144

---

**장 세 윤**

서울대학교 생활과학연구소 책임연구원

**김 하 연**

군산대학교 의류학과 교수

**이 유 리**

서울대학교 의류학과 교수/  
서울대학교 생활과학연구소 겸무연구원

**설 진 석**

서울대학교 컴퓨터공학부 박사수료

**김 성 재**

서울대학교 컴퓨터공학부 대학원생

**이 상 구**

서울대학교 컴퓨터공학부 교수

---